

مقایسه توابع انتقالی رگرسیونی و شبکه عصبی مصنوعی در برآورد گنجایش تبادل کاتیونی خاک‌های گیلان

سمیه معلمی^۱ و ناصر دوات‌گر^{۲*}

(تاریخ دریافت: ۱۳۸۸/۹/۲۴؛ تاریخ پذیرش: ۱۳۸۹/۸/۸)

چکیده

گنجایش تبادل کاتیونی یکی از ویژگی‌های شیمیایی مهم خاک بوده که اندازه‌گیری آن بسیار پرهزینه و وقت‌گیر است. توابع انتقالی، می‌تواند راه‌کاری مناسب در برآورد این پارامتر به جای اندازه‌گیری مستقیم باشد. هدف از این تحقیق، توسعه چند تابع انتقالی مناسب برای برآورد گنجایش تبادل کاتیونی خاک‌های استان گیلان با استفاده از دو روش رگرسیون خطی چندگانه و شبکه عصبی مصنوعی و تأثیر گروه‌بندی خاک‌ها بر پایه کلاس‌های بافتی و کربن آلی بر بهبود توانایی برآورد گنجایش تبادل کاتیونی به وسیله دو روش بود. برای این تحقیق از ۱۶۶۲ داده مربوط به خاک‌های استان گیلان از بانک اطلاعات آزمایشگاه شیمی خاک مؤسسه تحقیقات برنج کشور استفاده شد. نتایج نشان داد که کربن آلی مهم‌ترین متغیر در برآورد گنجایش تبادل کاتیونی در کل داده‌ها و کلیه کلاس‌های بافتی و کربن آلی در هر دو روش رگرسیون و شبکه عصبی بوده است. شبکه عصبی مصنوعی نسبت به روش رگرسیون در برآورد گنجایش تبادل کاتیونی در کل داده‌ها، کارایی بهتری داشت و گروه‌بندی داده‌ها تنها در کلاس‌های بافتی شن و شنی رسی لومی در روش شبکه عصبی مصنوعی، موجب بهبود محسوس پیش‌بینی‌ها نسبت به کل داده‌ها شد.

واژه‌های کلیدی: گنجایش تبادل کاتیونی، توابع انتقالی، شبکه عصبی مصنوعی، رگرسیون، ویژگی‌های خاک

۱. کارشناس ارشد خاک‌شناسی، دانشکده کشاورزی، دانشگاه گیلان، رشت

۲. استادیار پژوهشی، مؤسسه تحقیقات برنج کشور

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

مقدمه

گنجایش تبادل کاتیونی، CEC، از جمله ویژگی‌های شیمیایی خاک است که هر چند امکان اندازه‌گیری مستقیم آن وجود دارد، ولی این اندازه‌گیری پرهزینه و وقت‌گیر است. توابع انتقالی یک راه‌کار مفید در تخمین خواص دیرپافت خاک مانند گنجایش تبادل کاتیونی با استفاده از ویژگی‌های زودپافت خاک می‌باشد. اگرچه اغلب توابع انتقالی خاک برای برآورد خواص هیدرولیکی خاک ایجاد شده‌اند، ولی استفاده از این توابع به خواص هیدرولیکی محدود نشده و برای برآورد خواص فیزیکی، شیمیایی و بیولوژیکی خاک نیز به کار رفته‌اند (۱۶).

توابع انتقالی با استفاده از اطلاعات خواص پایه و سهل‌الوصول به‌عنوان عوامل برآورد کننده در ویژگی‌های از خاک که اندازه‌گیری‌شان پرهزینه و وقت‌گیر است، موجب افزایش ارزش آنها می‌شوند (۱۶). ایجاد توابع انتقالی جدید برای برآورد یک ویژگی دیرپافت با دقت قابل قبول در هر ناحیه دشوار بوده و منطقی است که از توابع انتقالی معتبر که از قبل ایجاد شده‌اند، استفاده شود. ولی، در بعضی از موارد از یک تابع انتقالی نمی‌توان در آن سوی ناحیه جغرافیایی یا تیپ خاک که توابع در آن شرایط ساخته شده است، استفاده کرد (۱۶). توابع انتقالی ایجاد شده از داده‌های منطقه‌ای، با اطمینان زیاد در مناطق با موقعیت و تیپ خاک و زمین‌نمای مشابه قابل استفاده هستند (۲۱). بنابراین لازم است قبل از هرگونه استفاده‌ای از این توابع، نسبت به تعیین اعتبار ناحیه‌ای آنها مبادرت نمود.

توابع انتقالی توسط شبکه‌های عصبی مصنوعی (Artificial Neural Network, ANN) نیز ساخته می‌شوند. شبکه‌های عصبی در پاره‌ای مواقع به‌عنوان توابع تقریب‌زننده همه منظوره که قادر به یادگیری هر تابع غیرخطی پیوسته هستند، تعریف می‌شوند. یک شبکه عصبی مصنوعی پیشرفته در مقایسه با توابع انتقالی مرسوم به مفاهیم از پیش تعیین شده از ارتباط بین داده‌های ورودی و خروجی نیازی ندارد. در جریان عملیات مکرر واسنجی، ارتباط مناسب بین داده‌های ورودی و خروجی پیدا شده و به‌طور خودکار اجرا می‌شود (۲۴ و ۲۵).

نقطه ضعف شبکه‌های عصبی مصنوعی، پیچیدگی تفسیر این روابط به‌دلیل ماهیت جعبه سیاه آنهاست (۲۴)؛ ولی به‌دلیل آن‌که شبکه‌های عصبی مصنوعی این امکان را به محقق می‌دهند که همراه با ورود مجموعه‌ای از متغیرهای مستقل دو یا چند متغیر وابسته را برآورد کند، باعث صرفه‌جویی در زمان و انرژی لازم برای شبیه‌سازی خواهد شد (۱۷). نتایج مطالعات مختلف صورت گرفته در پیش‌بینی ویژگی‌های هیدرولیکی خاک، اغلب برتری این‌گونه توابع را نسبت به روش‌های مرسوم نشان می‌دهد (۱۹ و ۲۱).

در سال‌های اخیر، توابع انتقالی مختلفی برای تخمین CEC از ویژگی‌های فیزیکی و شیمیایی خاک ایجاد شده است (۴، ۱۱، ۱۵ و ۱۶). در بیشتر این مدل‌ها CEC تابعی خطی از مواد آلی و مقدار رس است (۹). اگرچه مواد جامد خاک به درجات مختلف در ایجاد مکان‌های تبادل کاتیونی نقش دارند، اما این خصوصیت در بیشتر خاک‌ها در بخش رس و مواد آلی آنها متمرکز است (۱۶، ۱۸ و ۲۶). در حقیقت بخش اعظم CEC خاک اختصاص به مواد آلی خاک دارد و با افزایش درجه هوموسی شدن افزایش می‌یابد (۵). از سوی دیگر گنجایش تبادل کاتیونی رس‌ها به علت تفاوت در منشأ بار الکتریکی منفی سطح کانی‌ها بسیار متغیر بوده و مقدار آن بسته به نوع بار (دایم یا وابسته به pH) متفاوت است (۱۸ و ۲۹). گنجایش تبادل کاتیونی خاک‌ها تابع pH خاک نیز هست (۱۸). گنجایش تبادل کاتیونی تمامی هوموس، رس‌های اکسیدی و بخشی از رس‌های سیلیکاته تابع pH محیط است (۲۶). بل و ون‌کنولن (۱۱) pH خاک را به‌عنوان یکی از متغیرهای مستقل در ایجاد توابع پیش‌بینی کننده CEC در خاک‌های مکزیک مؤثر دانسته‌اند. ذرات شن و سیلت هم دارای بار الکتریکی منفی خنثی نشده هستند، اما به‌علت سطح ویژه کم، آثار بسیار ناچیزی در گنجایش تبادل کاتیونی خاک‌ها ایجاد می‌کنند. سی‌بولد و همکاران (۲۶) در ایجاد مدل‌های جامع پیش‌بینی کننده CEC از مقدار کربن آلی، رس، سیلت و pH خاک به‌عنوان متغیرهای غالب و مستقل استفاده کردند. هورن و همکاران (۱۲) مقدار

توسط توابع انتقالی

مواد و روش‌ها

۱. اندازه‌گیری متغیرها

برای این تحقیق از ۱۶۶۲ داده خاک مربوط به استان گیلان از بانک اطلاعات آزمایشگاه شیمی خاک مؤسسه تحقیقات برنج کشور استفاده گردید. روش‌های اندازه‌گیری متغیرهای استفاده شده برای پیش‌بینی گنجایش تبادل کاتیونی عبارت بودند از: pH خاک در گل اشباع، کربن آلی به روش والکلی و بلاک، توزیع اندازه ذرات به روش هیدرومتر و پیپت و گنجایش تبادل کاتیونی به روش استات سدیم در pH ۲/۲ (۱ و ۲). در این بانک اطلاعات، داده‌های کمی مرتبط با نوع کانی‌های سیلیکاته رسی وجود نداشت.

۲. رگرسیون چندمتغیره

بعد از مشخص نمودن آمار توصیفی که خلاصه آن به تفکیک مجموعه داده‌های آموزش و آزمون در جدول ۱ نشان داده شده‌اند، نرمال بودن داده‌ها با استفاده از آزمون معنی‌دار بودن چولگی و کشیدگی بررسی شد. پس از نرمال نمودن توزیع داده‌ها و تصحیح همراستایی بین متغیرهای مستقل، از روش رگرسیون چند متغیره گام به گام (Stepwise) برای برآورد گنجایش تبادل کاتیونی در کل داده‌ها و همچنین در کلاس‌های تفکیک شده بر مبنای بافت و کربن آلی استفاده شد. در گروه‌بندی بر مبنای بافت خاک‌ها بر پایه بیشترین فراوانی در مثلث بافت خاک آمریکا خاک‌ها به ۹ کلاس بافتی: شامل بافت‌های شنی، لوم شنی، لوم، لوم سیلتی، لوم رسی شنی، لوم رسی، لوم رسی سیلتی، رس سیلتی و رسی و بر مبنای کربن آلی به ۳ کلاس با دامنه ۰ تا ۲، ۲ تا ۴ و ۴ تا ۶ درصد کربن آلی تفکیک شدند (شکل ۱).

برای ایجاد بهترین تابع انتقالی پیش‌بینی کننده در هر دو روش رگرسیون چند متغیره و شبکه عصبی مصنوعی، ابتدا داده‌ها، پس از تصادفی نمودن، به دو گروه مجزا تقسیم شدند. دو سوم

رس و کربن آلی، پارفیت و همکاران (۲۲) مقدار کربن آلی، رس و نوع کانی‌های رسی، نوربخش و همکاران (۷) درصد ماده آلی، درصد اندازه ذرات و pH و میرخانی و همکاران (۶) مقدار رس، سیلت و کربن آلی را در پیش‌بینی مقدار گنجایش تبادل کاتیونی مؤثر دانسته‌اند.


سی بولد و همکاران (۲۶) برای افزایش دقت تخمین CEC، خاک‌های مورد مطالعه را به گروه‌های همگون‌تر بر مبنای مقدار کربن آلی، pH، ترکیب کانی‌شناسی و رده خاک‌ها تفکیک نمودند. سیرز و همکاران (۲۲) گزارش کردند که گوناگونی خاک‌های بررسی شده بدون در نظر گرفتن شباهت‌های میان آنها، مانند همگونی در ترکیب کانی‌شناسی، منجر به کاهش قدرت پیش‌بینی خواص آن خاک‌ها می‌شود. پاچپسکی و راولز (۲۱) نیز به این نتیجه رسیدند که گروه‌بندی خاک‌ها بر پایه شباهت در منشا یا ویژگی‌های خاک‌ها، دقت مدل‌های پیش‌بینی کننده را بهبود می‌بخشد. اسدو و آکامیگیو (۱۰) نشان دادند گروه‌بندی داده‌ها بر پایه رده‌های خاک‌ها، موجب بهبود در پیش‌بینی گنجایش تبادل کاتیونی می‌شود.

اگرچه بیشتر پژوهش‌های صورت گرفته در خصوص مقایسه میزان کارایی شبکه‌های عصبی مصنوعی نسبت به سایر توابع انتقالی در مورد شبیه‌سازی پارامترهای هیدرولیکی خاک می‌باشد، ولی این شبکه‌ها در شبیه‌سازی دیگر پارامترهای دیرپافت خاک چون مقدار رواناب (۱۴)، هدررفت نیترات (۲۷)، مقدار کربن آلی خاک (۲۸) و شناسایی و طبقه‌بندی آلودگی روی، مس و سرب در خاک (۸) و گنجایش تبدالی خاک (۹) نیز استفاده شده‌اند. اهداف این تحقیق عبارت بودند از:

- ۱) تعیین مهم‌ترین متغیرهای مستقل مؤثر در برآورد گنجایش تبادل کاتیونی
- ۲) مقایسه روش‌های رگرسیون چند متغیره و شبکه عصبی مصنوعی در برآورد گنجایش تبادل کاتیونی
- ۳) بررسی اثر گروه‌بندی خاک‌ها بر مبنای کلاس‌های بافتی و کربن آلی در افزایش توانایی برآورد گنجایش تبادل کاتیونی

جدول ۱. خلاصه آمار توصیفی خواص فیزیکی و شیمیایی اندازه‌گیری شده در خاک‌های مورد مطالعه به تفکیک داده‌های آموزشی و آزمون

آزمون (۵۵۳ داده)				آموزش (۱۱۰۹ داده)				متغیر (واحد)
حدافل	میانگین	حداکثر	ضریب تغییرات	حدافل	میانگین	حداکثر	ضریب تغییرات	
۶۱/۲	۶/۹۷	۸/۲۸	۱۰/۶۵	۳/۵۰	۶/۹۴	۸/۸۰	۱۲/۲۴	pH
۰/۰۰	۲/۰۸	۷/۷۱	۶۲/۶۴	۰/۰۰	۲/۱۶	۸/۱۱	۷۲/۹۷	کربن آلی (%)
۰/۱۰	۲۳/۹۱	۹۷/۰۰	۷۹/۹۱	۱/۰۰	۲۶/۰۱	۹۹/۰۰	۶۹/۶۷	شن (%)
۲/۱۰	۴۲/۹۵	۶۸/۰۰	۲۷/۹۱	۱/۰۰	۴۱/۳۰	۷۱/۰۰	۲۶/۶۳	سیلت (%)
۰/۰۰	۳۳/۰۷	۶۹/۸۰	۴۳/۶۹	۰/۰۰	۳۲/۶۲	۷۴/۰۰	۴۲/۹۵	رس (%)
۲/۲۹	۲۷/۳۹	۵۸/۸۰	۳۶/۳۱	۲/۹۳	۲۵/۹۴	۵۶/۰۰	۳۳/۸۸	CEC (cmol(+)/kg)



شکل ۱. نمایش تفکیک کل داده‌های خاک به دو گروه کلاس بافتی و کربن آلی به منظور ایجاد گروه‌های همگون در تخمین گنجایش تبادل کاتیونی

لایه پنهان - لایه خروجی) استفاده شد. نحوه عمل شبکه عصبی پرسپترون به این صورت است که ابتدا هر یک از نرون‌های متعلق به متغیرهای لایه ورودی به وسیله اتصالات سازگار شونده W_{ij} که به آن وزن (Weight) می‌گویند، به کلیه نرون‌های لایه پنهان متصل می‌شوند. در نرون‌های لایه پنهان متغیرهای ورودی و وزن‌ها در هم ضرب شده و با اریب لایه (b_i) جمع می‌شوند. سپس خروجی از یک تابع فعال‌ساز (f) (Transfer function) عبور می‌کند، تابع فعال‌ساز می‌تواند سیگموییدی، تانژانت هیپربولیک یا خطی باشد. نرون‌های لایه

از کل داده‌ها و به همین ترتیب در هر گروه به عنوان داده‌های آموزشی و یک سوم داده‌ها به عنوان داده‌های آزمون مورد استفاده قرار گرفتند. علاوه بر کل داده‌ها برای هر یک از کلاس‌های بافتی و گروه‌های کربن آلی نیز یک تابع انتقالی منحصر به فرد رگرسیونی توسعه یافت.

۳. شبکه عصبی مصنوعی

برای ایجاد شبکه عصبی مصنوعی، ANN، از نرم افزار NeuroSolution5 و ساختار پرسپترون سه لایه (لایه ورودی -

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad [1]$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad [2]$$

$$ME = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)}{N} \quad [3]$$

در این آمارها y_i مقادیر واقعی داده‌ها، $\hat{y}_i$ مقادیر برآورد شده توسط مدل، $\bar{y}$ میانگین مقادیر واقعی و N تعداد کل مشاهدات است. از آماره برتری نسبی (RI) برای تعیین بهترین مدل ایجاد شده به روش رگرسیون چند متغیره خطی و شبکه عصبی و همچنین مشخص نمودن اندازه برتری توابع انتقالی در هر گروه نسبت به کل داده‌ها استفاده شد (۹):

$$RI = \frac{RMSE_a - RMSE_b}{RMSE_a} \times 100 \quad [4]$$

$RMSE_a$: ریشه دوم میانگین مربعات خطای مربوط به مدل a

$RMSE_b$: ریشه دوم میانگین مربعات خطای مربوط به مدل b

RI: برتری نسبی مدل b بر a

نتایج و بحث

۱. آمار توصیفی

پارامترهای آمار توصیفی برای متغیرهای فیزیکی و شیمیایی خاک‌های استفاده شده در مجموعه داده‌های آموزش و آزمون در جدول یک نشان داده شده‌اند. pH خاک‌ها در دامنه ۲/۶۱ تا ۸/۸ قرار دارد. pH کم و اسیدی مربوط به خاک‌های زیر کشت گیاه چای و pH زیاد عمدتاً مربوط به خاک‌های بازی مربوط به باغ‌های زیتون است. کربن آلی خاک‌ها در دامنه ۰/۰۰ تا ۸/۱۱ درصد قرار دارد و ضریب تغییرات آن زیاد است، مقدارهای ناچیز کربن آلی عمدتاً مربوط به اراضی شنی ساحلی و خاک‌های مربوط به باغ‌های زیتون و مقادیر زیاد آن عمدتاً در اراضی پست شالیزاری مشاهده می‌شود که احتمالاً در بخش عمده‌ای از طول سال غرقاب هستند. ضریب تغییرات (CV) که معیاری از تغییرپذیری نسبی است، برای متغیرهای کربن آلی،


خروجی نیز مانند نرون‌های لایه پنهان عمل کرده و مقادیر را وزن (W_{out}) ضرب کرده و از تابع فعال‌ساز عبور می‌دهند و در نهایت خروجی‌ای (θ) به دست می‌آید که در حقیقت مقدار تخمین زده شده پارامتر خروجی، CEC، است (شکل ۲) (۱۳).

در فرایند آموزش، تعداد بهینه لایه پنهان به ترتیب با استفاده از ۱، ۲ و ۳ لایه مورد ارزیابی قرار گرفت و تعداد نرون‌های هر یک از این لایه‌ها برابر ۴ در نظر گرفته شد. لایه پنهان اطلاعات مفید را از لایه ورودی دریافت کرده و از آنها برای تخمین پارامتر خروجی استفاده می‌کند. بهترین تابع فعال‌ساز شبکه عصبی نیز با مقایسه و ارزیابی برآوردهای CEC در توابع تانژانت هایپربولیک و تانژانت هایپربولیک خطی انتخاب شد (نتیجه مقایسه‌ها نشان داده نشده‌اند). تعداد نرون‌ها در لایه ورودی و خروجی شبکه به ترتیب برابر با تعداد پارامترهای ورودی و خروجی شبکه در نظر گرفته شد. مناسب‌ترین آرایش‌ها از راه ارزیابی صحت برآورد برای برآورد گنجایش تبادل کاتیونی انتخاب شدند.

برای کل داده‌ها و در هر یک از گروه‌ها، لایه ورودی شامل برخی پارامترهای فیزیکی و شیمیایی مانند pH، درصد کربن آلی، درصد‌های شن، سیلت و رس بودند. در شبکه عصبی مصنوعی از چهار مدل مختلف از پارامترهای ورودی استفاده شد: (۱) مدل اول شامل همه پارامترها (شن، رس، سیلت، کربن آلی و pH)، (۲) مدل دوم شامل درصد اندازه ذرات معدنی (شن، سیلت و رس)، (۳) مدل سوم شامل کربن آلی و رس (۴) در مدل چهارم از پارامترهای ورودی مشابه با پارامترهای انتخاب شده به روش رگرسیون چند متغیره گام به گام برای کل داده‌ها و به تفکیک هر گروه.

۴. آماره‌های ارزیابی توابع انتقالی

برای تعیین صحت و اعتبار مدل‌ها از آماره‌های ارزیابی ضریب تبیین (R^2)، میانگین خطا (ME)، ریشه دوم میانگین مربعات خطا (RMSE) استفاده شد (۱۷):




شکل ۲. طرح کلی از شبکه عصبی پرسپترون سه لایه

۲. توسعه توابع انتقالی رگرسیونی بر پایه کلاس‌های بافتی مقایسه آماره‌های ارزیابی $RMSE$ و R^2 در بین داده‌های آموزش و آزمون برای کل داده‌ها و همچنین کلاس‌های تفکیک شده بر حسب بافت و کربن آلی، نشان داد که مقدار این آماره‌ها برای داده‌های آموزشی، به ترتیب بیشتر و کمتر از داده‌های آزمون می‌باشد (جدول‌های ۲ تا ۵). این نتایج نشان دادند که همیشه ارتباط نزدیکی میان صحت و اعتبار توابع انتقالی ایجاد شده وجود ندارد. پاپچسکی و همکاران (۲۱) نیز نشان دادند که در تخمین رطوبت حجمی، رابطه‌ای نزدیک میان آماره‌های داده‌های آموزش و آزمون وجود ندارد.

بهترین مدل‌های رگرسیونی برای کل داده‌ها و به تفکیک کلاس بافتی برای مجموعه داده‌های آموزشی به همراه آماره‌های ارزیابی و ضریب رگرسیون جزئی استاندارد شده (β) (Standardized partial regression coefficient) در جدول دو نشان داده شده است. ضریب β بیانگر اهمیت نسبی اثر هر

شن و رس بالاتر از ۳۵٪ است که بر اساس طبقه‌بندی ویلدینگ و درس (۳۱) در گروه متغیرهای با ضریب حداکثر طبقه‌بندی می‌شوند. بالا بودن ضریب تغییرات، نشان‌دهنده آن است که متغیرهای فوق بیشتر تحت تأثیر کاربری و عملیات مدیریت زراعی قرار گرفته‌اند. ضریب تغییرات برای متغیر pH کمتر از ۱۵٪ و برای سیلت بین ۱۵-۳۵٪ بوده که بر اساس طبقه‌بندی ویلدینگ و درس به ترتیب در گروه متغیرهای با ضریب حداقل و متوسط طبقه‌بندی می‌شوند.

توزیع اندازه ذرات معدنی خاک‌های مورد مطالعه در برآورد گنجایش تبادل کاتیونی در خاک‌های استان گیلان، نشان می‌دهد که خاک‌های منطقه از تنوع بافتی گسترده برخوردار بوده و کلاس‌های بافتی غالب آن به ترتیب رس سیلتی، لوم رسی سیلتی، لوم رسی و لوم سیلتی می‌باشند (شکل ۳). گنجایش تبادل کاتیونی نمونه‌ها نیز متناسب با بافت آنها دارای محدوده گسترده‌ای است (جدول ۱).



شکل ۳. نمایش توزیع اندازه ذرات معدنی خاک برای مجموع داده‌ها در نمودار مثلث بافت خاک آمریکا

همگونی نمونه خاک‌ها از نظر منشأ و نوع کانی‌های رسی بیشتر باشد.

۳. توسعه توابع انتقالی رگرسیونی بر پایه کلاس‌های کربن آلی

گروه‌بندی خاک‌ها به تفکیک کربن آلی نشان داد که ارزش آماره‌های $RMSE$ و R^2 برای برآورد CEC به روش رگرسیون کمتر از ارزش این آماره‌ها به تفکیک کلاس بافتی بود که نشان‌دهنده عدم موفقیت این نوع گروه‌بندی در ایجاد جامعه همگون‌تر به منظور بهبود در برآورد CEC است (جدول ۳). تنها آماره $RMSE$ که معیاری از صحت برآورد است، برای گروه خاک‌های با کربن آلی بیش از ۲ درصد در مجموعه داده‌های آموزش کمتر از کل داده‌هاست. ضریب β نشان داد که در خاک‌های با کربن آلی بزرگ‌تر از ۲ درصد، متغیر رس بیشترین نقش را در بین متغیرهای ورودی برای برآورد CEC دارد. اثر رس بر CEC را می‌توان به سطح ویژه و تراکم

یک از متغیرهای مستقل در مدل رگرسیون چندمتغیره است و هر متغیر مستقل که قدر مطلق ضریب β در آن بیشتر باشد، درجه اثر آن بر متغیر وابسته بیشتر است (۳). این نتایج نشان دادند که در همه گروه‌های بافتی، متغیر کربن آلی در میان متغیرهای مستقل، بیشترین اثر را بر گنجایش تبادل کاتیونی دارد. در مطالعات امینی و همکاران (۹) و مانریکو و همکاران (۱۵) بیش از ۵۰٪ تغییرات گنجایش تبادل کاتیونی مربوط به دو متغیر کربن آلی و رس بوده است. اثر کربن آلی بر CEC را می‌توان به سطح ویژه و گروه‌های عاملی زیاد آن نسبت داد.

متغیرهای رس، سیلت، کربن آلی و pH بر پایه ضریب تبیین (R^2) ۵۴ درصد ($P < 0/01$) از تغییرات CEC را در کل داده‌ها تشریح می‌نمایند. تفکیک داده‌ها در کلاس‌های بافتی به‌منظور ایجاد گروه‌های همگون‌تر خاک، فقط در کلاس‌های بافتی لومی و لوم رسی شنی منجر به افزایش R^2 ، کاهش $RMSE$ و در نتیجه بهبود در برآورد CEC توسط روش رگرسیون چند متغیره خطی شد (جدول ۲). به نظر می‌رسد در این دو کلاس،

جدول ۲. مقادیر ضریب تبیین (R^2)، میانگین خطا (ME) و ریشه میانگین مربعات خطا (RMSE) برای بهترین مدل‌های انتخاب شده در گروه‌های بافتی بر پایه داده‌های آموزشی

داده‌های آموزشی									
ضریب R^2									
R^2	RMSE	ME	Sand	Silt	Clay	OC	pH	مدل تابع انتقالی رگرسیونی	گروه‌های بافتی
۰/۵۴	۵/۹۸	-۰/۰۵	-	-۰/۰۸	۰/۶۱	۰/۶۱	-۰/۰۹	$N/4113 + 0.3783 \text{ pH} + 9.587 \text{ OC}^{*15} - 0.903 \text{ Clay} - 0.003 \text{ Silt}^{*17}$	۱۱۰۹ کل داده‌ها
۰/۳۸	۳/۹۲	۰/۰۰	-	-	-	۰/۶۲	-	$10/882 + 6.916 \text{ Log OC}$	۲۵ شنی
۰/۴۹	۵/۹۷	۲/۳۳	-۰/۳۰	-	-	۰/۵۳	-	$15/349 + 8.7741 \text{ OC}^{*15} - 0.001 \text{ Sand}^{*11}$	۵۴ لوم شنی
۰/۵۷	۴/۱۷	-۰/۰۱	-	-	۰/۱۷	۰/۷۲	-	$10/041 + 3.221 \text{ OC} + 0.23 \text{ Clay}$	۱۷۲ لوم
۰/۲۷	۷/۲۲	۰/۰۰	-	-	-	۰/۵۲	-	$-1/807 + 1.8412 \text{ OC}^{*13}$	۱۳۳ لوم سیلتی
۰/۶۸	۷/۹۷	۰/۲۶	-۰/۶۹	-۱/۰۵	-	۰/۶۲	-	$55/628 + 3.2313 \text{ OC} - 0.902 \text{ Silt} - 0.033 \text{ Sand}^{*16}$	۲۱ لوم رسی شنی
۰/۳۸	۵/۵۰	-۰/۰۱	-	-	۰/۱۶	۰/۶۷	-۰/۱۵	$11/503 + 9.2387 \text{ OC}^{*15} + 0.36 \text{ Clay} - 1/413 \text{ pH}$	۱۵۹ لوم رسی
۰/۴۶	۶/۷۷	-۰/۰۲	-	-	۰/۲۶	۰/۵۸	-۰/۱۷	$7/140 + 11/206 \text{ OC}^{*15} + 0.163 \text{ Clay}^{*13} - 1/897 \text{ pH}$	۱۸۲ لوم رسی سیلتی
۰/۲۸	۵/۲۳	۰/۰۵	-	-۰/۱۷	-	۰/۴۶	-۰/۲۷	$42/817 + 7/349 \text{ OC}^{*15} - 2/129 \text{ pH} - 0.046 \text{ Silt}^{*14}$	۱۵۴ رس سیلتی
۰/۳۷	۵/۳۸	۰/۱۱	-	-	۰/۴۴	۰/۶۴	-	$N/594 + N/075 \text{ OC}^{*15} + 0.061 \text{ Clay}^{*14}$	۲۰۹ رسی

جدول ۳. مقادیر ضریب تبیین (R^2)، میانگین خطا (ME) و ریشه میانگین مربعات خطا (RMSE) برای بهترین مدل‌های انتخاب شده در گروه‌های کریز آلی

داده‌های آموزشی									
ضریب R^2									
R^2	RMSE	ME	Sand	Silt	Clay	OC	pH	مدل تابع انتقالی رگرسیونی	گروه‌های بافتی
۰/۵۴	۵/۹۸	-۰/۰۵	-	۰/۰۸	۰/۶۱	۰/۶۱	-۰/۰۹	$N/4113 + 0.3783 \text{ pH} + 9.587 \text{ OC}^{*15} - 0.903 \text{ Clay} - 0.003 \text{ Silt}^{*17}$	۱۱۰۹ کل داده‌ها
۰/۱۵	۸/۴	۰/۰۶	۰/۱۳	-	-	۰/۱۶	-۰/۳۷	$45/037 - 3/688 \text{ pH} + 7/509 \text{ OC} + 1/614 \text{ Sin Sand}$	۶۲۹ $0 < \text{OC} \leq 2$
۰/۳۷	۵/۵۴	۰/۰۱	-	-	۰/۵۷	۰/۳۱	-	$5/278 + 0.386 \text{ Clay} + 24/139 \text{ Log OC}$	۳۴۰ $2 < \text{OC} \leq 4$
۰/۴۹	۳/۷۷	۰/۰۰	-	-	۰/۶	۰/۳۹	-	$-11/323 + 0.004 \text{ Clay} + 4/028 \text{ Log OC}$	۱۳۸ $4 < \text{OC} \leq 6$

جدول ۲. مقادیر ضریب تبیین (R^2)، میانگین خطا (ME) و ریشه میانگین مربعات خطا (RMSE) برای بهترین مدل‌های انتخاب شده در گروه‌های بانفی بر پایه داده‌های آموزشی در روش رگرسیون چندمتغیره گام به گام

ضریب β									
داده‌های آموزشی					مدل تابع انتقالی رگرسیونی				
R^2	RMSE	ME	Sand	Silt	Clay	OC	pH	تعداد داده‌ها	گروه‌های بانفی
۰/۵۴	۵/۹۸	-۰/۰۵	-	-۰/۰۸	۰/۶۱	۰/۶۱	-۰/۰۹	۱۱۰۹	کل داده‌ها
۰/۳۸	۳/۹۲	۰/۰۰	-	-	۰/۶۲	-	۱۰/۸۲+۶/۹۱۶ log OC	۲۵	شنی
۰/۴۹	۵/۹۷	۲/۳۳	-۰/۳۰	-	۰/۵۳	-	۱۵/۳۴۹+۸/۷۴۱ OC ^{-۱/۵} - ۰/۰۰۱ Sand ^{۱/۱}	۵۴	لوم شننی
۰/۵۷	۴/۱۷	-۰/۰۱	-	-	۰/۷۲	-	۱۰/۰۴۱+۳/۲۲۱ OC + ۰/۲۳ Clay	۱۷۲	لوم
۰/۲۷	۷/۲۲	۰/۰۰	-	-	۰/۵۲	-	-۱/۸۰۷+۱/۴۱۲ OC ^{-۱/۲}	۱۳۳	لوم سیلتی
۰/۶۸	۲/۹۷	۰/۲۶	-۰/۶۹	-۱/۸۵	۰/۶۲	-	۵۵/۶۲۸+۳/۳۱۳ OC - ۰/۹۰۲ Silt - ۰/۰۳۳ Sand ^{۱/۵}	۲۱	لوم رسی شننی
۰/۳۸	۵/۵۰	-۰/۰۱	-	-	۰/۱۶	۰/۶۷	-۰/۱۵ ۱۱/۵۰۳+۹/۳۸۷ OC ^{-۱/۵} + ۰/۳۶ Clay - ۱/۴۱۳ pH	۱۵۹	لوم رسی
۰/۴۶	۶/۷۷	-۰/۰۲	-	-	۰/۲۶	۰/۵۸	-۰/۱۷ ۷/۱۴۰+۱۱/۲۰۶ OC ^{-۱/۵} + ۰/۱۶۳ Clay ^{۱/۲} - ۱/۸۹۷ pH	۱۸۲	لوم رسی سیلتی
۰/۲۸	۵/۲۳	۰/۰۵	-	-۰/۱۷	۰/۴۶	-۰/۲۷	۴۲/۸۱۷+۷/۴۳۹ OC ^{-۱/۵} - ۲/۱۲۹ pH - ۰/۰۴۶ Silt ^{۱/۲}	۱۵۴	رس سیلتی
۰/۳۷	۵/۳۸	۰/۱۱	-	-	۰/۴۴	۰/۶۴	- ۸/۵۹۹+۸/۰۷۵ OC ^{-۱/۵} + ۰/۰۶۱ Clay ^{۱/۲}	۲۰۹	رسی

جدول ۳. مقادیر ضریب تبیین (R^2)، میانگین خطا (ME) و ریشه میانگین مربعات خطا (RMSE) برای بهترین مدل‌های انتخاب شده در گروه‌های کربن آلی بر پایه داده‌های آموزشی در روش رگرسیون چندمتغیره گام به گام

ضریب β									
داده‌های آموزشی					مدل تابع انتقالی رگرسیونی				
R^2	RMSE	ME	Sand	Silt	Clay	OC	pH	تعداد داده‌ها	گروه‌های بانفی
۰/۵۴	۵/۹۸	-۰/۰۵	-	۰/۰۸	۰/۶۱	۰/۶۱	-۰/۰۹	۸/۴۱۳+۰/۳۸۳ pH+۹/۵۸۷ OC ^{-۱/۵} - ۰/۹۰۴ Clay - ۰/۰۰۳ Silt ^{۱/۲}	کل داده‌ها
۰/۱۵	۸/۴	۰/۰۶	۰/۱۳	-	-	۰/۱۶	-۰/۳۷	۴۵/۰۳۷-۳/۶۸۸ pH+۲/۵۰۹ OC+۱/۶۱۴ Sin Sand	۶۲۹
۰/۳۷	۵/۵۴	۰/۰۱	-	-	۰/۵۷	۰/۳۱	-	۵/۲۷۸+۰/۳۸۶ Clay+۲۴/۱۳۹ Log OC	۳۴۰
۰/۴۹	۳/۲۷	۰/۰۰	-	-	۰/۶	۰/۳۹	-	-۱۱/۳+۳/۰۰۴ Clay+۴۰/۹۳۸ Log OC	۱۳۸

بارالکتريکی آن نسبت داد.

۴. بهینه‌سازی شبکه عصبی مصنوعی بر پایه کلاس‌های بافتی و کربن آلی

شبکه عصبی مصنوعی ساخته شده در کل داده‌ها و کلاس‌های تفکیک شده بر پایه بافت و کربن آلی، نشان داد که نمی‌توان از یک الگوی ورودی مشخص و ساختار مشابه در ایجاد شبکه عصبی برای همه کلاس‌ها استفاده نمود (جدول‌های ۴ و ۵). شبکه عصبی مصنوعی با چهار مدل ورودی و در هر مدل با سه لایه پنهان و در هر لایه با دو تابع فعال‌ساز آموزش دید و سپس بهترین ورودی و ساختار شبکه عصبی مصنوعی برای کل داده‌ها و کلاس‌های تفکیک شده با استفاده از آماره‌های ارزیابی $RMSE$ و R^2 انتخاب و اعتبارسازی شد.

۵. مقایسه توابع انتقالی ایجاد شده به روش رگرسیون با شبکه عصبی مصنوعی (الف) مقایسه در کلاس‌های بافتی

توابع انتقالی توسعه یافته از راه رگرسیون (در کل داده‌ها و به تفکیک گروه‌های بافتی) با شبکه عصبی مصنوعی، ANN، در مجموعه داده‌های آزمون مقایسه شدند (جدول ۴). ارزش آماره ME نشان داد که در کل داده‌ها و گروه‌های تفکیک شده بر پایه بافت، مقدار اریب در روش ANN نسبت به روش رگرسیون کمتر است. ارزش آماره ME در کل داده‌ها و برای هر دو روش ANN و رگرسیون، منفی بود که نشان‌دهنده آن است که CEC برآورد شده توسط هر دو روش کمتر از مقدار واقعی بود. بیشترین اریب در ANN در گروه بافتی رس سیلتی دیده شد.


بر پایه آماره RI در کل داده‌ها، شبکه عصبی مصنوعی نسبت به رگرسیون از ۲۴ درصد برتری نسبی برخوردار بود (داده‌ها نشان داده نشده‌اند). این برتری به ویژه برای کلاس‌های بافتی مانند شن (۵۰٪) و لوم رسی شنی (۷۴٪) قابل ملاحظه بود. امینی و همکاران (۹) نیز در مقایسه بین دو مدل از شبکه عصبی

با توابع انتقالی ایجاد شده به روش رگرسیون، برتری ۲۵ درصدی شبکه‌های عصبی را نسبت به رگرسیون گزارش کردند. برآزش مقادیر برآورد شده CEC در مقابل مقادیر اندازه‌گیری شده آن در نمودار ۱:۱ با استفاده از دو روش رگرسیون و ANN در مجموعه داده‌های آزمون، نشانگر برتری نسبی شبکه عصبی مصنوعی نسبت به رگرسیون است (شکل ۴). در برآورد گنجایش تبادل کاتیونی، به ویژه برای مقادیر بزرگ‌تر از ۳۰ سانتی‌مول بر کیلوگرم، رگرسیون در مقایسه با ANN از اشتباه بیشتری برخوردار بود.

به استثنای کلاس‌های بافتی تک مد مانند شن و رس و کلاس لوم سیلتی که در بین متغیرهای ورودی دو روش ANN و رگرسیون تفاوت وجود داشت، در دیگر گروه‌های بافتی و کل داده‌ها بهترین برآوردها در هر دو روش ANN و رگرسیون با متغیرهای ورودی مشابه به‌دست آمد (جدول‌های ۲ و ۴). نکته مشترک در هر دو روش رگرسیون و ANN، وجود کربن آلی به عنوان متغیر ورودی در تمام کلاس‌های بافتی است؛ در مطالعه نلتون و همکاران (۲۰) و رشیدی و سیل‌سپور (۲۳) نیز کربن آلی به تنهایی به ترتیب ۶۹ و ۷۴ درصد از تغییرات گنجایش تبادل کاتیونی را تشریح می‌کند.

(ب) مقایسه در کلاس‌های کربن آلی

مقایسه توابع انتقالی توسعه یافته از راه رگرسیون با شبکه عصبی مصنوعی در گروه‌های تفکیک شده بر پایه کربن آلی در جدول پنج نشان داده شده است. آماره ME در هر سه کلاس کربن آلی برای ANN کمتر از توابع رگرسیونی بود که نشان می‌دهد برآوردهای ANN در هر سه کلاس نسبت به رگرسیون از اریب کمتری برخوردار است. مقایسه آماره‌های ارزیابی $RMSE$ و R^2 برای هر دو روش رگرسیون و ANN در مجموعه داده‌های آزمون نشان داد که برآورد گنجایش تبادل کاتیونی با استفاده از ANN در مقایسه با رگرسیون از اعتبار بیشتری برخوردار بود. مقایسه این آماره‌ها برای برآورد CEC به روش ANN و رگرسیون در کل داده‌ها و تفکیک آنها به هر یک از



شکل ۴. همبستگی بین مقدار برآورد شده گنجایش تبادل کاتیونی در مقابل مقدار اندازه گیری شده در نمودار ۱:۱ به روش (۱) رگرسیون، (۲) شبکه عصبی

گروه بافتی سیلت، گروه بندی به ویژه بر پایه کلاس های بافتی خاک، قدرت پیش بینی گنجایش تبادل کاتیونی به وسیله شبکه عصبی مصنوعی را نسبت به کل داده ها افزایش داد.

از میان متغیرهای مستقل استفاده شده که شامل pH، کربن آلی و توزیع اندازه ذرات است، گنجایش تبادل کاتیونی بیشترین همبستگی را با متغیر کربن آلی و بعد از آن با متغیر رس نشان داد. در میان توابع رگرسیونی، کارایی این تابع در کلاس بافتی شن در مقایسه با دیگر کلاس های بافتی از اعتبار بیشتری برخوردار بود. شبکه عصبی مصنوعی نیز در کلاس های بافتی شن و لوم رسی شنی بیشترین کارایی را داشت.

در این تحقیق گروه بندی داده ها بر پایه کلاس های بافتی و یا کربن آلی به منظور همگون نمودن داده ها، منجر به افزایش چشمگیر کارایی توابع انتقالی در برآورد CEC نگردید. به نظر می رسد، گنجایش تبادل کاتیونی علاوه بر بافت و کربن آلی زیر اثر نوع کانی های رسی نیز قرار دارد و در صورت وجود داده های کافی از مقدار کمی کانی های رس در بانک داده ها، برآورد CEC با صحت بیشتری انجام گیرد. اما در هر صورت متغیر کمیت کانی های سیلیکات رس جزء متغیرهای سهل الوصول خاک محسوب نمی شود.

گروه های با درصد متفاوت از کربن آلی نشان داد که گروه بندی بر پایه کربن آلی نتوانسته است در ایجاد همگونی بیشتر برای برآورد بهتر داده ها سودمند باشد (جدول ۵). بیشتر خاک های عضو کلاس های بافتی شن دارای کربن آلی کمتر از دو درصد هم بودند. هرگاه در مورد یک خاک خاص بیش از یک تابع انتقالی برای تخمین پارامتر مورد نظر وجود داشته باشد، تابعی ارجح تر است که دارای صحت بیشتری باشد (۲۱ و ۲۶). آماره RMSE برای برآورد CEC توسط ANN در کلاس بافتی شن برابر با ۱/۵۶ و در گروه خاک های با کربن آلی کمتر از دو درصد برابر با ۶/۳۴ است. بنابراین در انتخاب تابع انتقالی مناسب در یک خاک دارای بافت شنی و کربن آلی کمتر از دو درصد، اولویت در استفاده از تابع انتقالی ایجاد شده برای کلاس بافت شن می باشد.

نتیجه گیری

مقایسه آماره های ارزیابی در دو روش رگرسیون و ANN برای کل داده ها و در هر یک از کلاس ها نشان دهنده برتری شبکه عصبی مصنوعی نسبت به روش رگرسیون بوده و به غیر از

اگرچه توابع ایجاد شده نمی‌توانند جایگزین کاملی برای اندازه‌گیری‌های مستقیم باشند، اما می‌توان از آنها در مطالعات یا شرایطی که نیاز به دانستن مقدار دقیق گنجایش تبادل کاتیونی نباشد و همچنین در مواردی که احتمال برآورد آن می‌تواند در فرایندهای مدل‌سازی و تصمیم‌گیری مؤثر باشد، استفاده نمود.

منابع مورد استفاده

۱. احيایي، م. ۱۳۷۶. شرح روش‌های تجزیه شیمیایی خاک. جلد دوم، مؤسسه تحقیقات خاک و آب، تهران.
۲. احيایي، م. و ع. ا. بهبهانی‌زاده. ۱۳۷۲. شرح روش‌های تجزیه شیمیایی خاک. جلد اول، مؤسسه تحقیقات خاک و آب، تهران.
۳. دوات‌گر، ن. م. کاووسی، م. ح. علی‌نیا و م. پیکان. ۱۳۸۴. بررسی وضعیت پتاسیم و اثر خواص فیزیکی و شیمیایی خاک بر آن در شالیزارهای استان گیلان. مجله علوم و فنون کشاورزی و منابع طبیعی ۷۱:۴-۸۹.
۴. کریمیان، ن. ع. ۱۳۷۵. سهم رس و مواد آلی در ظرفیت تبادل کاتیونی خاک‌های آهکی استان فارس. پنجمین کنگره علوم خاک ایران، کرج.
۵. محمودی، ش. و م. حکیمیان (مترجمان). ۱۳۷۷. مبانی خاک‌شناسی. چاپ دوم، انتشارات دانشگاه تهران.
۶. میرخانی، ر. م. شعبانپور و س. سعادت. ۱۳۸۴. استفاده از فراوانی نسبی ذرات و درصد کربن آلی برای برآورد ظرفیت تبادل کاتیونی خاک‌های استان لرستان. مجله علوم خاک و آب ۲۳:۱۹-۲۴۲.
۷. نوربخش، ف. ا. جلالیان و ح. شریعتمداری. ۱۳۸۲. تخمین گنجایش تبادل کاتیونی خاک با استفاده از برخی ویژگی‌هایی فیزیکو-شیمیایی خاک. مجله علوم و فنون کشاورزی و منابع طبیعی ۱۰۷:۳-۱۱۷.
8. Amegashie, F., J.Q. Shang, E.K. Yanful, W. Ding and S. Al Martini. 2006. Using complex permittivity and artificial neural networks to identify and classify copper, zinc, and lead contamination in soil. *Can. Geotech. J.* 43: 100-109.
9. Amini, M., K.C. Abbaspour, H. Khademi, N. Fathianpour, M. Afyuni, and R. Schuln. 2005. Neural Network Models to Predict Cation Exchange Capacity in Arid Regions of Iran. *Eur. J. Soil Sci.* 56:551-559.
10. Asadu, C.L.A. and F.O.R. Akamigbo. 1990. Relative contribution of organic matter and clay fractions to cation exchange capacity of soils in southern Nigeria. *Samaru. J. Agric. Res.* 7: 17-23.
11. Bell, M. A. and H. van Keulen. 1995. Soil pedotransfer functions for four Mexican soils. *Soil Sci. Soc. Amer. J.* 59: 865-871.
12. Horn, A. L., R.A. Düring and S. Gäth. 2005. Comparison of the prediction efficiency of two pedotransfer functions for soil cation-exchange capacity. *J. Plant Nutr. Soil Sci.* 168:372-374.
13. Jana, R.B., B.P. Mohanty and E.P. Springer. 2007. Multiscale pedotransfer functions for soil water retention. *Vadose Zone J.* 6: 868-878.
14. Licznar, P. and M.A. Nearing. 2003. Artificial neural networks of soil erosion and runoff prediction at the plot scale. *Catena* 51:89-114.
15. Manrique, L.A., C.A. Jones and P.T. Dyke. 1991. Predicting cation-exchange capacity from soil physical and chemical properties. *Soil Sci. Soc. Amer. J.* 50:787-794.
16. McBratney, A.B., B. Minasny, S.R. Cattle and R.W. Vervoort. 2002. From pedotransfer functions to soil inference systems. *Geoderma* 109:41-73.
17. Merdun, H., Ö. Çınar, R. Meral and M. Apan. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil & Tillage Res.* 90: 108-116.
18. Miller, W.F. 1970. Inter-regional predictability of cation-exchange capacity by multiple regressions. *Plant Soil* 33:721-725.
19. Minasny, B. and A.B. McBratney. 2002. The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Sci. Soc. Amer. J.* 66:352-361.
20. Nettleton, W.D., S.H. Brownfield, E.C. Benham, R. Burt, K. Hipple, C.L. McGrath and H.R. Sinclair, Jr. 2001. Predictive models for selected chemical properties of Andisols. *Soil Survey Horizons* 42:99-111.

21. Pachepsky, Y.A. and W.J. Rawls. 1999. Accuracy and reliability of pedotransfer functions as affected by grouping soils. *Soil Sci. Soc. Amer. J.* 63:1748-1757.
22. Parfitt, R.L., D.J. Giltrap and J.S. Whitton. 1995. Contribution of organic matter and clay minerals to the cation exchange capacity of soil. *Commun. Soil Sci. Plant A.* 26: 1343–1355.
23. Rashidi, M. and M. Seilspour. 2008. Modeling of soil cation exchange capacity based on soil organic carbon. *ARN J. Agric. Bio. Sci.* 3: 41-45.
24. Schaap, M.G. and F.J. Leij. 1998. Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil & Tillage Res.* 47: 37-42.
25. Schaap, M.G., F.J. Leij, and M.Th. van Genuchten. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Sci. Soc. Amer. J.* 62: 847–855.
26. Seybold, C.A., R.B. Grossman, and T.G. Reinsch. 2005. Predicting Cation Exchange Capacity for Soil Survey Using Linear Models. *Soil Sci. Soc. Amer. J.* 69:856-863.
27. Sharma, V., S.C. Negi, R.P. Rudra and S. Yang. 2003. Neural networks for predicting nitrate-nitrogen in drainage water. *Agric. Water Manag.* 63:169-183.
28. Somaratne, S., G. Seneviratne and U. Coomaraswamy. 2005. Prediction of Soil Organic Carbon across Different Land-use Patterns: A Neural Network Approach. *Soil Sci. Soc. Amer. J.* 69:1580–1589.
29. Sparks, D.L. 1953. *Environmental Soil Chemistry*. Academic Press. Inc., London.
30. Syers, J.K., A.S. Campbell and T.W. Walker. 1970. Contribution of organic carbon and clay to cation exchange capacity in a chronosequence of sandy soils. *Plant Soil* 33:104–112.
31. Wilding, L.P. and L.R. Dress. 1983. Spatial variability and pedology. PP: 83-116. *In*: L. P. Wilding, N. E. Smeck and G. F. Hall (Eds.), *pedogenesis and soil taxonomy. I. Concepts and interactions*. Elsevier Sci. Pub., North Holland.