

مقایسه مدل‌های شبکه عصبی مصنوعی و توابع انتقالی رگرسیونی برای پیش‌بینی ظرفیت تبادل کاتیونی خاک‌های استان چهارمحال و بختیاری

مجتبی معاریان فرد^{۱*} - حبیب اله بیگی هرچگانی^۲

تاریخ دریافت: ۸۷/۱۲/۲۴

تاریخ پذیرش: ۸۸/۷/۵

چکیده

ظرفیت تبادل کاتیونی (CEC) یکی از مهمترین ویژگی‌های خاک در ارتباط با مواد غذایی، نگهداری آب در خاک و همچنین مدیریت آلودگی خاک می‌باشد. اندازه‌گیری CEC کاری دشوار و وقت‌گیر است. بنابراین تخمین آن از طریق خصوصیات زود یافت خاک مطلوب می‌باشد. در این مطالعه، توابع انتقالی برای پیش‌بینی ظرفیت تبادل کاتیونی از خصوصیات اساسی خاک مانند توزیع اندازه ذرات، کربن آلی، درصد رطوبت اشباع و pH توسعه داده شد و با استفاده از روش‌های شبکه عصبی مصنوعی و رگرسیونی چند متغیره خطی ارزیابی شد و سپس توانایی پیش‌بینی این دو روش با استفاده از آماره‌های ارزیابی مقایسه شد. کل ۲۰۰ نمونه خاک به دو دسته ۱۶۵ تایی برای توسعه مدل و ۳۵ تایی برای ارزیابی مدل تقسیم شدند. دقت پیش‌بینی بوسیله آماره‌های ضریب تعیین (R^2) و ریشه دوم میانگین مربعات خطا (RMSE) بین CEC اندازه‌گیری و پیش‌بینی شده ارزیابی شد. نتایج نشان داد هنگامی که از شبکه عصبی با یک لایه پنهان و هفت نرون در این لایه و ماده آلی، درصد رطوبت اشباع، درصد رس و شن به عنوان ورودی استفاده شد، CEC با $R^2=0.81$ و $RMSE=3.05$ سانتی مول بر کیلوگرم خاک بهتر از دیگر مدل‌ها پیش‌بینی شد. مقادیر R^2 و RMSE به ترتیب از ۰/۶۶ تا ۰/۶۹ و از ۴/۶۹ تا ۴/۲۶ برای روش رگرسیونی، و از ۰/۷۸ تا ۰/۸۱ و ۳/۲۹ تا ۳/۰۵ برای شبکه عصبی متغیر بود. نتایج نشان داد که پیش‌بینی شبکه عصبی بهتر از تابع‌های رگرسیونی می‌باشد.

واژه‌های کلیدی شبکه‌های عصبی مصنوعی، ظرفیت تبادل کاتیونی، چهارمحال و بختیاری

مقدمه

رگرسیونی چند متغیره خطی نیز به طور معمول در پیدا کردن ضرایب مدل مورد استفاده قرار می‌گیرند (۱۱ و ۳۱). در این خصوص محققان زیادی توابعی را برای برآورد ظرفیت تبادل کاتیونی از روی ویژگی‌های زود یافت خاک ارائه نموده‌اند. بل و وان کولن (۱) با تحقیقی که روی خاک‌های چهار منطقه از مکزیک انجام دادند تابعی برای برآورد CEC ارائه دادند که بیش از ۹۶ درصد از تغییرات را با استفاده از متغیرهای مستقل مقدار ماده آلی، رس و pH خاک بیان می‌کرد. داهیا و همکاران (۴) برای پیش‌بینی ظرفیت تبادل کاتیونی با استفاده از درصد اشباع (SP) از تعداد ۱۱۶۰ نمونه از ۲۵۰ پروفیل از خاک‌های شمال هند استفاده کردند. ظرفیت تبادل کاتیونی همبستگی خطی و مثبت با لگاریتم SP نشان داد ($r=0.957$). کروگ و همکاران (۱۱) از توابع انتقالی برای پیش‌بینی ظرفیت تبادل کاتیونی خاک‌های دانمارک به وسیله آنالیزهای رگرسیونی چند متغیره برای ۱۶۴۳ نمونه خاک استفاده کردند. نتایج نشان داد که ۹۰٪ از تغییرات در مقادیر CEC می‌تواند به وسیله استفاده از مقدار رس و مواد آلی به عنوان متغیرهای وابسته توجیه شود. میزان خطای پیش‌بینی این تخمین ۱/۹۹ cmol/kg بود. با این وجود مدل‌های توسعه داده شده برای یک

ظرفیت تبادل کاتیونی (Cation Exchange Capacity, CEC) از مهمترین خصوصیات خاک در ارتباط با توانایی خاک برای نگهداری آب و مواد غذایی و همچنین شاخص خوبی برای کیفیت و بهره‌وری خاک و مدیریت آلودگی است. همچنین، CEC اغلب یکی از مهمترین خصوصیات خاک است که در پایگاه داده‌ها مورد نیاز است (۱۳) و به عنوان ورودی در مدل‌های خاک و زیست محیطی مورد استفاده می‌باشد (۹). اندازه‌گیری CEC کاری دشوار بوده و نیازمند صرف زمان زیادی است. بنابراین تعیین آن از طریق دیگر خصوصیات زود یافت مطلوب می‌باشد. در سال‌های اخیر، توابع انتقالی گوناگونی در تخمین CEC از خصوصیات شیمیایی و فیزیکی اساسی خاک توسعه داده شده‌اند (۱)، ۳، ۱۳ و ۱۴). در اغلب این مدل‌ها CEC به عنوان تابع خطی از ماده آلی و مقدار رس خاک در نظر گرفته می‌شود (۳ و ۱۴). آنالیزهای

۱ و ۲- به ترتیب دانشجوی کارشناسی ارشد و استادیار گروه خاکشناسی دانشگاه شهر کرد

* - نویسنده مسئول: (Email: memarian@yahoo.com)

پرسپترون چند لایه برای تخمین ظرفیت تبادل کاتیونی در خاک‌های ناحیه چهارم‌حال و بختیاری در جنوب غربی ایران و ۲) مقایسه این مدل‌ها با توابع انتقالی رگرسیونی چند متغیره خطی از طریق ارزیابی عملکرد آنها.

مواد و روش‌ها

جمع آوری اطلاعات

داده‌های این پژوهش از سه دشت لردگان، کوه‌رنگ و شهرکرد در استان چهارم‌حال و بختیاری و به تعداد کل ۲۰۰ نمونه از عمق سطحی ۰-۳۰ سانتی‌متر به طور تصادفی جمع آوری شدند (جدول ۱). خصوصیات اندازه‌گیری شده خاک در این مطالعه شامل توزیع اندازه ذرات، مقدار ماده آلی، درصد کربنات کلسیم معادل (آهک)، pH، درصد رطوبت اشباع (SP) و ظرفیت تبادل کاتیونی (CEC) بود. دامنه مقادیر خصوصیات اندازه‌گیری شده برای سه دشت در جدول ۱ نشان داده شده است. خاک‌ها ابتدا هواخشک شده و قبل از آنالیز از الک ۲ میلی‌متری عبور داده شدند. توزیع اندازه ذرات خاک به روش پیپت (۷)، مواد آلی به روش والکی-بلک (۱۸) و ظرفیت تبادل کاتیونی به روش استات سدیم (pH=۲/۸) اندازه‌گیری شد (۲۹). داده‌های هر سه دشت با هم مخلوط شده و سپس به دو دسته تقسیم شدند. در این مرحله ابتدا داده‌ها نرمال شدند. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای اجتناب از چنین شرایطی و همچنین به منظور یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی داده‌ها استاندارد (نرمال) شدند. این کار مانع از کوچک شدن بیش از حد وزن‌ها می‌گردد و همچنین این کار بدین علت صورت می‌گیرد که داده‌ها به اعدادی ما بین صفر تا ۱ تبدیل گردند، زیرا خروجی اکثر توابع آستانه اعدادی بین صفر تا یک می‌باشد. داده‌ها با استفاده از فرمول زیر نرمال شدند و به مقادیر بین صفر تا یک تبدیل شدند:

$$x_{normal} = (x_{max} - x_i) / (x_{max} - x_{min}) \quad (1)$$

که در آن x_{max} ماکزیمم داده‌ها، x_{min} حداقل داده‌ها و x_i داده مشاهده‌ای است.

یک دسته از داده‌ها به منظور واسنجی مدل‌های شبکه عصبی و اشتقاق مدل رگرسیونی و دسته دیگر به منظور آزمون مدل‌ها مورد استفاده قرار گرفت. تقسیم داده‌ها بوسیله تصادفی کردن نمونه‌ها و سپس انتخاب تصادفی ۲۰٪ از داده‌ها به منظور آزمون مدل و ۸۰٪ باقیمانده برای واسنجی مدل بود.

ناحیه ممکن است نتواند تخمین مناسبی برای یک ناحیه دیگر فراهم کنند (۳۰).

شبکه‌های عصبی مصنوعی یکی از روش‌های هوشمند پردازش داده‌ها هستند که اخیراً به وسیله پاپسکی و همکاران (۲۱)، شاپ و بوتن (۲۴) و تاماری و همکاران (۲۷) مورد استفاده قرار گرفته‌اند. شبکه‌های پیش‌خور پس انتشار خطای مورد استفاده قرار گرفته به وسیله این تحقیقات قادر به تخمین توابع غیرخطی پیوسته با هر درجه از دقت می‌باشند (۱۶). اخیراً شبکه‌های عصبی به طور فراگیر و موفقیت آمیزی در پیش‌بینی بسیاری از خصوصیات دیربافت خاک مورد استفاده قرار گرفته‌اند (۵، ۱۰، ۱۲، ۱۵ و ۲۳). یکی از مزیت‌های استفاده از شبکه‌های عصبی مصنوعی نسبت به مدل‌های قدیمی این است که نیازمند تعیین یک تابع خاص برای بیان رابطه میان داده‌های ورودی و خروجی نیست. رابطه بین داده‌های ورودی و خروجی از طریق فرایند آموزش به دست می‌آید (۲۴).


پاپسکی و همکاران (۲۱) با بررسی شبکه‌های عصبی و مدل‌های رگرسیونی روی ۲۳۰ نمونه خاک گزارش کردند که مدل‌های شبکه عصبی با دقت بهتر و خطای کمتری ظرفیت نگهداری آب در خاک را برآورد کردند. فریت و همکاران (۶) از شبکه‌های عصبی مصنوعی با ساختار پرسپترون چند لایه با دو لایه پنهان و تابع عملگر سیگموئید به منظور برآورد رطوبت خاک استفاده کردند و دریافتند که شبکه‌های عصبی که از چنین ساختاری بهره می‌برند ابزار مناسبی برای تخمین رطوبت خاک هستند. تانگ و همکاران (۲۸) از شبکه‌های عصبی توابع پایه شعاعی برای پیش‌بینی CEC استفاده کردند و دریافتند که شبکه‌های عصبی ظرفیت تبادل کاتیونی را با دقت بیشتر نسبت به مدل‌های رگرسیونی چند متغیره پیش‌بینی می‌کنند. نستور (۱۹) از مدل شبکه عصبی پرسپترون چند لایه در پیش‌بینی نفوذپذیری خاک در فیلیپین استفاده کرد. شبکه‌های مورد استفاده به طور متوسط دارای ضریب تعیین بالایی با میانگین $R^2 = 0/911$ بودند. آنالیز حساسیت نشان داد که رطوبت خاک و هدایت هیدرولیکی فاکتورهای مؤثر در پیش‌بینی مدل نفوذ با استفاده از شبکه‌های عصبی می‌باشند.

یک نوع از شبکه‌های عصبی مصنوعی، شبکه‌های پرسپترون چند لایه (Multi-layer perceptron, MLP) می‌باشد که از یک الگوریتم آموزش پس انتشار خطا استفاده می‌کند و از آن برای توسعه بسیاری از توابع انتقالی شبکه عصبی استفاده شده است (۱۷، ۲۰، ۲۳ و ۲۶). پژوهشگرانی مانند نیلسون و سینکو در سال ۱۹۸۷ و سپس هارنیک در ۱۹۹۱ نشان دادند که شبکه MLP دارای یک لایه میانی با تابع تبدیل سیگموئید و یک تابع تبدیل خطی در لایه خروجی، قادر به تقریب تمامی پدیده‌های مورد نظر است به شرط اینکه دارای نرون کافی در لایه میانی باشد (۳۰).

اهداف این مطالعه عبارتند از: (۱) توسعه مدل‌های شبکه عصبی

(جدول ۱) - توصیف آماری متغیرهای منطقه مورد مطالعه

ظرفیت تبادل کاتیونی cmol.kg ⁻¹	pH	آهک (%)	درصد اشباع	مواد آلی (%)	رس (%)	سیلت (%)	شن (%)	تعداد نمونه	خصوصیات
۱۷-۴۱	۷/۴-۸/۳	۷-۶۴	۳۵-۶۹	۰/۲۸-۵/۴	۱۳-۴۴	۳۹-۷۹	۲-۴۱	۸۰	شهرکرد
۱۵-۴۴	۷/۳-۵/۸	۴-۶۲	۲۹-۶۷	۰/۲۸-۵/۴	۸-۶۱	۲۱-۷۳	۲-۶۷	۶۰	لردگان
۱۶-۴۲	۷-۷/۹	۹-۵۸	۲۹-۶۹	۰/۳۸-۴/۳	۱۹-۴۶	۳۷-۷۷	۲-۳۷	۶۰	کوههرنگ



(شکل ۱) - ساختار یک شبکه عصبی پیشخور پس انتشار خطا

طراحی شبکه عصبی

شبکه پرسپترون چند لایه توسعه داده شده در این مطالعه یک شبکه پیش خور با الگوریتم پس انتشار خطا بود که از سه لایه از نرون‌ها (نرون‌های لایه ورودی، پنهان و خروجی) در آن استفاده شد (شکل ۱).

این شبکه‌ها از سه لایه ورودی، پنهان و خروجی تشکیل شده است که اصطلاحاً به آن شبکه عصبی پرسپترون (Perceptron) گفته می‌شود. هر یک از لایه‌ها می‌توانند از تعدادی نرون تشکیل شده باشند که هر نرون به کلیه نرون‌های لایه دیگر متصل است. نرون‌های لایه ورودی مکان قرار گرفتن پارامترهای ورودی است و تعداد نرون‌های لایه ورودی و خروجی به ترتیب برابر با تعداد پارامترهای ورودی و خروجی مدل است. تعداد نرون‌های لایه پنهان نیز با توجه به پیچیدگی مدل و پارامترهای خروجی توسط طراح انتخاب می‌شود. تعیین تعداد نرون‌های لایه پنهان یکی از مراحل مهم توسعه شبکه‌های عصبی است و نقش معنی‌داری در عملکرد مدل شبکه عصبی دارد (۱۶).

نحوه عمل شبکه عصبی پرسپترون به این صورت است که ابتدا هر یک از نرون‌های لایه ورودی x_l ($l=1, \dots, N_i$) به وسیله اتصالات

سازگار شونده W_{jl} که به آن وزن می‌گویند به کلیه نرون‌های لایه پنهان منتقل می‌شوند Z_j ($j=1, \dots, N_h$). تعداد لایه‌های پنهان و N_i تعداد واحدهای ورودی است. در نرون‌های لایه پنهان، متغیرهای ورودی و وزن‌ها در هم ضرب شده و با یکدیگر جمع می‌شوند:

$$Z_j = \sum_{l=1}^{N_i} w_{jl} x_l + w_{j0} \quad (2)$$

واحدهای پنهان شامل ورودی‌های وزن گرفته و یک بایاس (w_{j0}) است. بایاس یک وزن ساده با ورودی ثابت یک است که وظیفه آن اضافه کردن یک مقدار ثابت به وزن است. ورودی‌ها به منظور ورود به لایه پنهان از تابع فعال ساز f عبور داده می‌شوند:

$$r_j = f \left(\sum_{l=1}^{N_i} w_{jl} x_l + w_{j0} \right) \quad (3)$$

توابع فعال‌ساز به منظور منطبق کردن روابط غیر خطی ورودی‌ها و خروجی‌ها طراحی شده‌اند. تابع معمول یک تابع سیگموئیدی یا تانژانت هایپربولیک است.

$$f(z) = \tanh(z) = 1 - \frac{2}{1 + \exp(2z)} \quad (4)$$

خروجی‌های عبور کرده از واحدهای پنهان دوباره از لایه دیگری

از فیلترها عبور می‌کنند:

$$v_k = \sum_{j=1}^{N_h} u_{kj} r_j + u_{k0} = \sum_{j=1}^{N_h} u_{kj} f \left(\sum_{l=1}^{N_l} w_{jl} x_l + w_{j0} \right) + u_{k0} \quad (5)$$

خروجی پیش‌بینی شده توسط شبکه پس از عبور از تابع فعال‌ساز f تولید می‌شود:

$$y = (k = 1, \dots, N_0):$$

$$y_k = F(v_k) = F \left[\sum_{j=1}^{N_h} u_{kj} f \left(\sum_{l=1}^{N_l} w_{jl} x_l + w_{j0} \right) + u_{k0} \right] \quad (6)$$

مراحل بالا برای چندین مرتبه تکرار می‌شود. وزن‌ها پارامترهای قابل تنظیم شبکه‌اند و به طور مرتب در طول فرایند آموزش شبکه تنظیم می‌شوند (۱۶، ۱۷ و ۲۰). یک مسئله که معمولاً در طی آموزش شبکه اتفاق می‌افتد مسئله بیش برآزش یا کم برآزش می‌باشد. این مسئله هنگامی مشکل ساز خواهد شد که فرایند آموزش برای مدت طولانی تکرار شود و این خود زمانی اتفاق می‌افتد که مدل شبکه عصبی برای مسئله مورد مطالعه خیلی پیچیده باشد (۲۳). هر چند در این حالت هدف نشان دادن مطابقت نزدیک بین داده‌های آموزشی و پیش‌بینی مدل است ولی با این وجود چنین مدلی احتمالاً هنگام ارزیابی به طور ضعیف اجرا می‌شود. بورگسن و شاپ (۲) برای جلوگیری از عمل بیش آموزش پیشنهاد کردند که می‌توان: ۱- مقادیر ضرایب درون شبکه را کاهش داد، ۲- تعداد نرون‌های لایه پنهان را کاهش داد و ۳- از تکنیک توقف سریع استفاده کرد که در این تکنیک محدود کردن تعداد تکرارها به وسیله مقایسه عملکرد شبکه با استفاده از یک دسته داده آزمون انجام می‌گیرد.

ارزیابی کارایی مدل‌ها

عملکرد مدل‌ها به وسیله یک دسته از داده‌های آزمون که در آموزش شبکه استفاده نشده‌اند ارزیابی شد. معیارهای مورد استفاده در ارزیابی مدل‌ها مجذور میانگین مربعات خطا (RMSE)، ضریب کفایت (R^2) بین مقادیر پیش‌بینی شده و اندازه‌گیری شده بود. فاکتور RMSE دقت و اعتبار دسته داده‌های آموزشی و آزمون را اندازه‌گیری می‌کند (۳۲) و با استفاده از فرمول زیر تعیین می‌شود:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (7)$$

مقادیر ضریب تعیین (R^2) نیز که یکی از آماره‌هایی است که در مقالات شبکه‌های عصبی به فراوانی از آن استفاده شده است با استفاده از فرمول زیر بدست آمد:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (8)$$

که در آنها: y_i مقادیر اندازه‌گیری شده، \hat{y}_i مقادیر پیش‌بینی شده، \bar{y}_i میانگین مقادیر اندازه‌گیری شده و N تعداد کل مشاهدات است.

درصد برتری نسبی (RI) ریشه میانگین مجذور خطای بهترین مدل ورودی (اندیس b) نسبت به ریشه میانگین مجذور خطای هر یک از مدل‌های دیگر (اندیس a) با استفاده از معادله زیر تعیین شد:

$$RI = \frac{RMSE_a - RMSE_b}{RMSE_a} \times 100 \quad (9)$$

در این تحقیق توابع انتقالی رگرسیونی چند متغیره خطی با استفاده از نرم افزار Statistica 6.0 توسعه داده شد. نرم افزار Neural Works Professional II/Plus.5.23 نیز برای ایجاد و شبیه سازی شبکه‌های عصبی مصنوعی مورد استفاده قرار گرفت.

نتایج و بحث

خلاصه آماری داده‌ها

خلاصه آماری خصوصیات خاک‌های مورد استفاده برای واسنجی و آزمون مدل‌ها در جدول ۲ ارائه شده است. همانگونه که مشاهده می‌شود خاک‌های مورد مطالعه دامنه گسترده‌ای از توزیع اندازه ذرات را نشان می‌دهند. دامنه تغییرات ذرات رس از ۸ تا ۶۱ درصد در ناحیه مورد مطالعه متغیر می‌باشد، مقدار ماده آلی خاک نیز بین ۵/۴ تا ۳۰/۳ با میانگین ۱/۵۵ درصد در ناحیه مورد مطالعه متغیر است. ضریب تغییرات (CV) ماده آلی خاک بالا و بعد از شن دارای بیشترین تغییرات است. این تغییرات بزرگ در ماده آلی می‌تواند در اثر کاربرد کود، کمپوست و اصلاح خاک در ناحیه مورد مطالعه باشد. ضریب همبستگی بین متغیرها در جدول ۳ ارائه شده است. نتایج نشان داد که CEC خاک با درصد رس ($r=0/39$)، درصد مواد آلی ($r=0/54$) و درصد رطوبت اشباع ($r=0/21$) همبستگی مستقیم و با درصد شن خاک ($r=-0/16$) همبستگی معکوس و معنی دار دارد. همبستگی منفی بین درصد شن و CEC به این دلیل است که با افزایش شن ذراتی که دارای توانایی ایجاد بار منفی هستند کاهش می‌یابد. میان سایر پارامترها ارتباط معنی داری با CEC دیده نشد.

(جدول ۲) - خلاصه آماری داده‌های مورد استفاده در آموزش و آزمون شبکه‌های عصبی و مدل رگرسیونی

داده‌های ارزیابی n=۳۵				داده‌های آموزش n=۱۶۵				واحد	متغیر
ضریب تغییرات	میانگین	حداکثر	حداقل	ضریب تغییرات	میانگین	حداکثر	حداقل		
۸۳/۵	۱۳/۸	۶۵/۵	۱/۸	۸۲/۱	۱۴	۶۷/۳	۱/۶	%	شن
۱۹/۲۶	۵۷/۲	۷۴/۵	۲۱/۴	۱۶/۴	۵۸/۷	۷۹/۳	۲۱/۶	%	سیلت
۳۴/۱	۲۹	۴۹/۴	۱۱/۹	۳۴/۰۴	۲۷/۴	۶۱/۴	۸	%	رس
۵۷/۱	۱/۴۹	۳/۷۳	۰/۳۵	۵۴/۴	۱/۵۸	۵/۳	۰/۲۸	%	ماده آلی
۱۶/۹	۴۸/۵	۶۴/۶	۲۹	۱۹/۲	۴۹/۱	۶۸/۷	۲۹/۴	-	درصد اشباع
۴۷/۷	۲۷	۶۵	۹/۲	۵۲/۷	۲۸/۲	۶۷/۴	۱/۱	%	آهک
۳/۶	۷/۷۶	۸/۲	۷/۰۸	۳/۴۷	۷/۷۶	۸/۴	۷/۱	-	pH
۲۶/۹	۲۶/۴	۴۱/۷	۱۷/۷۲	۲۴/۰۸	۲۶/۴	۴۳/۷	۱۵/۳	cmol.kg ⁻¹	CEC

(جدول ۳) - ضریب همبستگی پیرسون بین متغیرها در منطقه مورد مطالعه

pH	شن (%)	سیلت (%)	رس (%)	آهک (%)	درصد اشباع	ماده آلی (%)	متغیر
-۰/۰۶	-۰/۱۶ ^a	-۰/۱۴	۰/۳۹ ^a	-۰/۱	۰/۲۱ ^a	۰/۵۴ ^a	ظرفیت تبادل کاتیونی
-۰/۱۲	-۰/۰۶	-۰/۱۸ ^a	۰/۳۱ ^a	-۰/۰۹	۰/۳۱ ^a	۱	ماده آلی
-۰/۲۲ ^a	-۰/۲۷ ^a	-۰/۰۴	۰/۴۳ ^a	-۰/۱۹ ^a	۱		رطوبت اشباع
۰/۷۰ ^a	۰/۱۳	-۰/۰۳	-۰/۱۸	۱			آهک
-۰/۱۴	-۰/۵۶ ^a	-۰/۳۶ ^a	۱				رس
-۰/۰۷	-۰/۴۳ ^a	۱					سیلت
۰/۰۰۸	۱						شن

a- روابط در سطح ۵٪ (L=۰/۹۵) معنی دار هستند

سیلت به دلیل اینکه همبستگی معنی‌داری با CEC نداشتند در این مدل وارد نشدند. این معادله رگرسیونی به صورت زیر است:

$$CEC = a_0 + a_1 \text{ Sand} + a_2 \text{ SP} + a_3 \text{ Clay} + a_4 \text{ OC} \quad (۱۳)$$

که در این معادله درصد شن و SP درصد رطوبت اشباع است. هر سه تابع انتقالی برای نمونه‌های خاک ناحیه مورد مطالعه با استفاده از دسته داده‌های واسنجی توسعه داده شده و سپس با استفاده از دسته داده‌های ارزیابی مورد آزمون قرار گرفتند. نتایج آماری توابع انتقالی رگرسیونی چند متغیره خطی در جدول ۴ آورده شده است. همانگونه که مشاهده می‌شود به نظر می‌رسد که تفاوت آماری معنی‌داری بین این مدل‌ها وجود ندارد. اضافه کردن درصد شن و رطوبت اشباع به مدل (تابع ۳) تنها به میزان ناچیزی توانست دقت مدل را بهبود بخشد.

پیش‌بینی CEC با استفاده از شبکه‌های عصبی مصنوعی

به منظور توسعه مدل‌های شبکه‌های عصبی در این تحقیق متغیرهایی به عنوان ورودی به شبکه استفاده شد که همبستگی معنی‌داری با ظرفیت تبادل کاتیونی داشتند. بدین منظور سه مدل شبکه عصبی مصنوعی پیشخور با الگوریتم پس انتشار خطا به منظور

توسعه توابع انتقالی رگرسیونی چند متغیره خطی

از توابع انتقالی رگرسیونی کلاسیک مورد استفاده در پیش‌بینی CEC، از سه تابع مورد استفاده توسط محققان مختلف استفاده شد. در نخستین تابع انتقالی (تابع ۱) از مقدار کربن آلی و رس (بر حسب درصد وزنی) به عنوان متغیرهای مستقل برای پیش‌بینی ظرفیت تبادل کاتیونی استفاده شد. این رابطه به صورت زیر می‌باشد:

$$CEC = a_0 + a_1 \text{ OC} + a_2 \text{ Clay} \quad (۱۱)$$

این تابع توسط هورن و همکاران (۸) توسعه داده شده است. در این تابع OC درصد کربن آلی و Clay درصد رس خاک است. دومین تابع انتقالی (تابع ۲) تابع بدست آمده از تحقیقات مکیراتنی و همکاران (۱۴) در پیش‌بینی CEC است. شکل این تابع به صورت زیر می‌باشد:

$$CEC = a_0 + a_1 \text{ Clay} + a_2 \text{ Clay} \times \text{OC} \quad (۱۲)$$

از آنجا که ممکن است تحت تأثیر عواملی چون pH و درصد رطوبت اشباع قرار گیرد، و یا ممکن است بخش کوچکی از کانی‌های موجود در بخش سیلت نیز سهم اندکی در CEC داشته باشند، و همچنین در یک جامعه آماری بزرگ از خاک‌ها، همبستگی معکوسی بین CEC و درصد شن خاک‌ها وجود داشته باشد از دیگر متغیرهای ورودی نیز در پیش‌بینی CEC استفاده شد (تابع ۳). pH و

مقایسه شبکه‌های عصبی مصنوعی با توابع انتقالی رگرسیونی

در این مرحله به منظور ارزیابی کارایی مدل‌ها و همچنین مقایسه مدل‌های شبکه عصبی و توابع انتقالی رگرسیونی از دسته داده‌های آزمونی برای پیش‌بینی ظرفیت تبادل کاتیونی استفاده شد. مقادیر ظرفیت تبادل کاتیونی پیش‌بینی شده در مقابل اندازه‌گیری شده برای داده‌های آزمونی در هر سه مدل رسم شد (شکل ۳). همانگونه که از شکل مشاهده می‌شود ضریب تعیین بین مقادیر اندازه‌گیری شده و پیش‌بینی شده برای هر سه مدل شبکه عصبی بالاتر از توابع انتقالی رگرسیونی نظیر آن است. ضریب تعیین ظرفیت تبادل کاتیون تخمین زده شده بوسیله مدل ANN₃ (که در آن از چهار ورودی کربن آلی، درصد اشباع، درصد رس و شن استفاده شده) در مقایسه با دیگر مدل‌ها بالاترین مقدار R² را دارا بود و بنابراین بهترین مدل برای پیش‌بینی ظرفیت تبادل کاتیونی خاک‌های استان چهارمحال و بختیاری شناخته شد. نتایج آماری این مقایسه‌ها در جدول ۵ ارائه شده است. کمترین مقدار RMSE نیز با استفاده از مدل ANN₃ بدست آمد و این در حالی بود که بیشترین مقدار RMSE به وسیله تابع انتقالی ۱ بدست آمد. بهبود نسبی هر مدل در مقایسه با تابع انتقالی شماره یک که معمولترین تابع انتقالی برای محاسبه CEC است بدست آمد. نتایج جدول ۵ نشان می‌دهد که مدل ANN₃ به طور معمول دارای بهبود نسبی (RI) بالاتری نسبت به دیگر مدل‌ها می‌باشد. کاربرد روش‌های شبکه عصبی و رگرسیونی در تخمین CEC با استفاده از متغیرهای زود یافت توانست به ترتیب حدود ۸۰ و ۷۰ درصد تغییرات در این مطالعه را توجیه کند. فاکتورهای مختلفی می‌تواند بر جوابگویی نسبتاً متعادل این مدل‌ها دخیل باشند که از جمله می‌توان به متفاوت بودن نوع و مورفولوژی رس در نواحی نمونه برداری (۲۵) و همچنین تغییر پذیری مکانی بالای خصوصیات خاک در نواحی مورد مطالعه اشاره کرد.

پیدا کردن تعداد بهینه ورودی‌ها مورد استفاده قرار گرفت. در هر سه مدل تابع فعالساز از لایه ورودی به پنهان تابع سیگموئید و از لایه پنهان به خروجی تابع خطی انتخاب شد.


در اولین مدل (ANN₁) تنها از کربن آلی و رس به عنوان ورودی استفاده شد. در مدل دوم (ANN₂) از درصد رس و حاصلضرب مقدار رس در کربن آلی (ورودی‌های مورد استفاده در تابع انتقالی ۲) به عنوان ورودی استفاده شد. در نهایت در مدل سوم (ANN₃) چهار ورودی ماده آلی، رس، درصد رطوبت اشباع و درصد شن به عنوان متغیرهای ورودی مورد استفاده قرار گرفته است. در هر سه مدل ظرفیت تبادل کاتیونی به عنوان تنها خروجی در نظر گرفته شد. مدل‌ها ابتدا با دسته داده‌های آموزشی آموزش داده شده و سپس مقادیر خطای پیش‌بینی هر سه شبکه در مقابل تعداد نرون‌های لایه پنهان رسم شد (شکل ۲).

همانگونه که مشاهده می‌شود اضافه کردن درصد رطوبت اشباع و درصد شن به ورودی‌های ماده آلی و درصد رس توانست باعث کاهش خطای شبکه شود (خط چین). پیدا کردن تعداد بهینه نرون‌ها در لایه پنهان یکی از مراحل مهم در توسعه شبکه‌های عصبی پیشخور می‌باشد. در طراحی شبکه عصبی تعداد نسبتاً زیاد واحدهای مخفی باعث بیش برآزش می‌شود، در حالی که تعداد کم واحدهای مخفی باعث زیر برآزش می‌شود. به منظور پیدا کردن تعداد بهینه نرون‌های مخفی از روش سعی و خطا استفاده شد و مقادیر به‌دست آمده در مقابل تعداد نرون‌های لایه پنهان برای هر سه مدل رسم شد (شکل ۲).

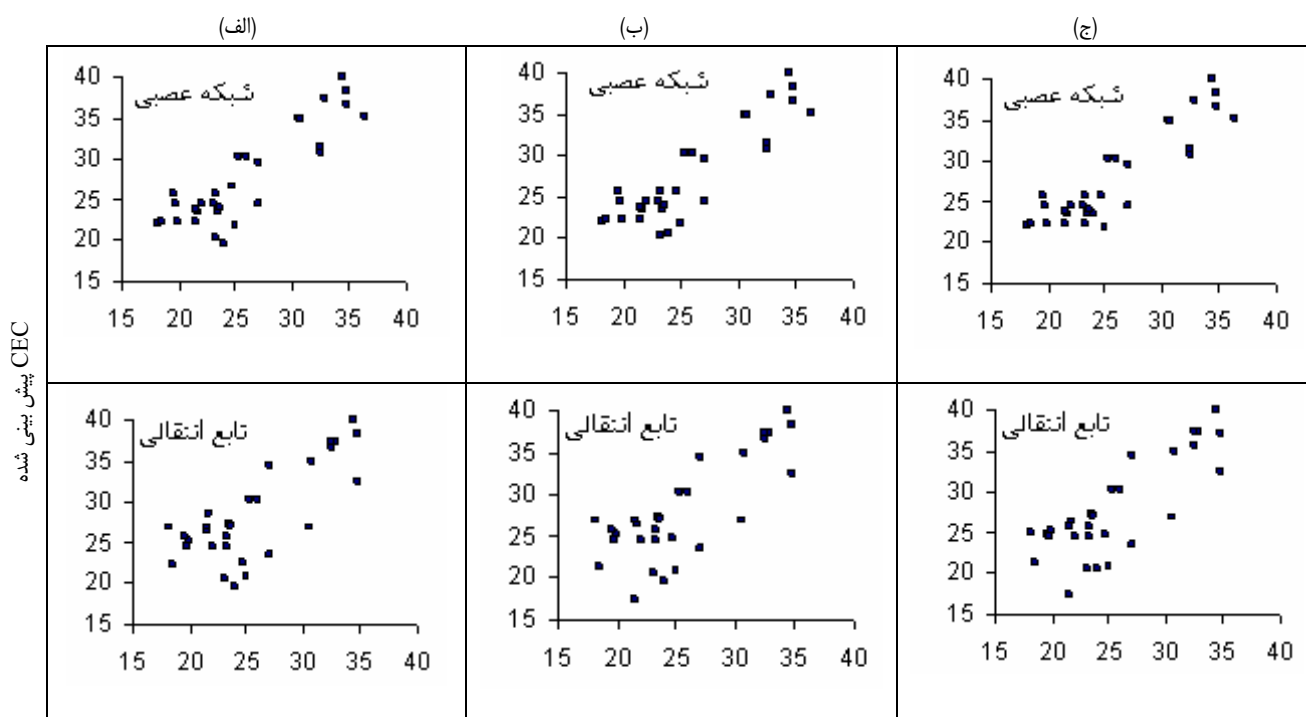
همانگونه که مشاهده می‌شود مدل ANN₁ و مدل‌های ANN₂ و ANN₃ به ترتیب با ۴،۴ و ۷ نرون در لایه پنهان بالاترین دقت و کمترین خطا را نشان دادند. همانگونه که از شکل ۲ مشاهده می‌شود اضافه کردن تعداد بیشتر نرون‌ها در لایه پنهان نتوانست دقت مدل را بهبود ببخشد.

(جدول ۴) - نتایج آماری توابع انتقالی توسعه داده شده برای داده‌های آموزشی و ارزیابی

شماره تابع	ضرایب واسنجی	داده‌های آموزشی		داده‌های ارزیابی	
		RMSE (cmol/kg)	R ²	RMSE (cmol/kg)	R ²
۱	a ₀ = ۱۲/۵۶ ، a ₁ =۴/۹ ، a ₂ = ۰/۳	۴/۶۰	۰/۶۵	۴/۶۹	۰/۶۶
۲	a ₀ = ۱۵/۵۹ ، a ₁ =۰/۱۴ ، a ₂ = ۰/۲	۴/۶۴	۰/۶۸	۴/۵۲	۰/۶۷
۳	a ₀ = ۶/۵ ، a ₁ =۰/۱۶ ، a ₂ = ۰/۳۵ ، a ₃ = ۶/۳۲	۴/۲۰	۰/۶۸	۴/۲۶	۰/۶۹



(شکل ۲) - پاسخ شبکه به تعداد ورودی‌ها و نرون‌های لایه پنهان مدل شبکه عصبی



CEC اندازه گیری شده

(شکل ۳) - نمودار ظرفیت تبادل کاتیونی اندازه‌گیری شده در مقابل پیش‌بینی شده برای الف) مدل شبکه عصبی ANN₁ و تابع انتقالی ۱ (ب) مدل شبکه عصبی ANN₂ و تابع انتقالی ۲ و ج) مدل شبکه عصبی ANN₃ و تابع انتقالی ۳.

(جدول ۵) - نتایج بدست آمده از آزمون مدل‌ها

ANN ₃	ANN ₂	ANN ₁	تابع انتقالی ۳	تابع انتقالی ۲	تابع انتقالی ۱	آماره‌های ارزیابی
۰/۸۱	۰/۷۹	۰/۷۸	۰/۶۹	۰/۶۷	۰/۶۶	ضریب تعیین
۳/۰۵	۳/۲۵	۳/۲۹	۴/۲۶	۴/۵۲	۴/۶۹	مجذور مربعات خطا
۳۴	۳۰	۲۹	۹	۳	۰	درصد برتری نسبی

(جدول ۶) - نتایج آنالیز حساسیت و تعیین درجه حساسیت پارامترهای ورودی

پارامترهای ورودی	پارامتر حذف شده	RMSE (سانتی مول بر کیلوگرم)	درجه حساسیت
کربن آلی، رس، شن، درصد اشباع	—	۳/۰۵	—
رس، شن، درصد اشباع	کربن آلی	۹/۲۴	۱
کربن آلی، شن، درصد اشباع	رس	۶/۳۲	۲
کربن آلی، رس، شن	درصد اشباع	۴/۴۵	۳
کربن آلی، رس، درصد اشباع	شن	۳/۷۵	۴

بررسی آنالیز حساسیت مدل شبکه عصبی

به منظور تعیین اثر هر کدام از پارامترهای ورودی بر ظرفیت تبادل کاتیونی لازم است آنالیز حساسیت انجام گیرد. اینکار در شبکه عصبی به دو روش حذف یا اضافه کردن پارامتر ورودی در مدل انجام می‌شود. بر این اساس هر پارامتری که اضافه کردنش بیشترین کاهش را در RMSE یا حذفش بیشترین افزایش را در RMSE داشته باشد، حساسترین پارامتر می‌باشد. در این تحقیق از روش دوم برای انجام آنالیز حساسیت استفاده شد. برای اینکار در هر مرحله از بین چهار پارامتر ورودی، یکی از آنها حذف شده و مقدار RMSE محاسبه گردید. نتایج این کار در جدول ۶ ارائه گردیده است. با توجه به جدول ۶ مشاهده می‌شود که با حذف مقدار کربن آلی، بیشترین افزایش در RMSE ایجاد شده است. بنابراین کربن آلی به عنوان حساسترین پارامتر محسوب می‌شود که نشان دهنده تأثیر زیاد مواد آلی بر افزایش CEC به دلیل سطح ویژه زیاد و داشتن گروه‌های عامل می‌باشد (۱۳).

با حذف درصد شن از مدل ورودی کمترین تغییر در RMSE ایجاد شده است. بنابراین درصد شن خاک به عنوان پارامتری با کمترین حساسیت در بین پارامترهای ورودی بر CEC محسوب می‌شود. درجه حساسیت همه پارامترها در جدول ۶ ارائه شده است. در این جدول درجه ۱ برای پارامتری است که بیشترین حساسیت را دارد و درجه ۴ برای پارامتری است که کمترین حساسیت را دارا می‌باشد.

نتیجه گیری

مدل‌های رگرسیونی چند متغیره خطی و سه مدل شبکه عصبی پیشخور برای پیش‌بینی ظرفیت تبادل کاتیونی به وسیله خصوصیات قابل استفاده خاک در خاک‌های استان چهارمحال و بختیاری توسعه داده شدند. عملکرد مدل‌های شبکه عصبی و رگرسیونی چند متغیره با استفاده از دسته داده‌های آزمونی مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل شبکه عصبی پس انتشار خطای توسعه داده شده با چهار ورودی کربن آلی، رطوبت اشباع، درصد رس و شن با هفت نرون در لایه پنهان توانست ظرفیت تبادل کاتیونی را بهتر از مدل‌های رگرسیونی و دیگر مدل‌های شبکه عصبی پیش‌بینی کند. بهبود نسبی این مدل نسبت به مدل رگرسیونی بیش از ۳۴٪ بود. مدل‌های شبکه عصبی به طور معمول برای تشخیص روابط غیر خطی بین متغیرها مناسب می‌باشند. در این مطالعه رابطه بین CEC با رس و مواد آلی به صورت برجسته خطی بود ولی به نظر می‌رسد رابطه بین درصد رطوبت اشباع و CEC به صورت غیر خطی بوده و توسط شبکه عصبی قابل تشخیص می‌باشد. نتایج آنالیز حساسیت نشان داد که کربن آلی یکی از مهمترین پارامترهای ورودی برای پیش‌بینی CEC خاک‌های استان چهارمحال و بختیاری است. مدل‌های آزمون شده در این مطالعه توانست ۸۰٪ تغییرات در CEC خاک‌های این استان را توجیه کند.

منابع

- 1- Bell M.A. and Van Kullen H. 1995. Soil pedotransfer function for four Mexican soils. Soil. Sci. Soc. Am. J., 59: 865-871.
- 2- Borgeson C., and Schaap M.G. 2005. Point and parameter pedotransfer functions for water retention predictions for Danish soils. Geoderma, 127:154-167.
- 3- Breeuwsma A., Wosten J.H.M., Vleeshouwer J.J., Van Slobbe A.M., and Bouma J. 1986. Derivation of land qualities to assess environmental problems from soil surveys. Soil. Sci. Am. J., 50:186-190.
- 4- Dahiya I.S., Shanwal A.V., Dahya D.J., and Laura R.D. 1988. A statistical model for estimating cation exchange capacity of soils from their saturation percentage. International Journal of Tropical Agriculture, 6(10):26-30.
- 5- Dawson C.W., and Wilby R. 1998. An artificial neural network approach to rainfall-runoff modeling. Hydrol. Sci. J. 43:47-66.
- 6- Frate F.D., Ferrazoli P., and Schiavon G. 2003. Retrieving soil moisture and agricultural variables by microwave

- radiometry using neural network. *Remote Sensing of Environment*, 84:174-183.
- 7- Gee G.W., and Bauder J.W. 1986. Particle size analysis. Pp. 383-411. In: A. Klute (Ed.), *Methods of Soil Analysis. Part 1*. Am. Soc. Agron., Madison, Wisconsin, USA.
 - 8- Horn A.L., Daring R.A., and Gath S. 2005. Comparison of the prediction efficiency of two pedotransfer functions for soil cation exchange capacity. *J. Plant Nutr. Soil Sci.*, 168-372.
 - 9- Keller A., Von Steiger B., Van der Zee S.T., and Schuline R. 2001. A stochastic empirical model for regional heavy metal balances in agroecosystems. *J. of Environ Qual*, 30:1976-1989.
 - 10- Koekkoek E.J.W., and Booltink H. 1999. Neural network models to predict soil water retention. *Eur. J. Soil Sci.* 50: 489-495.
 - 11- Krogh L., Madsen H.B., and Greve M.H. 2000. Cation exchange capacity pedotransfer functions for Danish soils. *Acta Agric. Scand., Sect. B, Soil and Plant Sci.*, 50:1-12.
 - 12- Landeras g., Ortiz-Barredo A., and Lopez J.J. 2008. Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). *Agricultural Water Management*, 95:553-565.
 - 13- Manrique L.A., Jones C.A., and Dyke P.T. 1991. Predicting cation exchange capacity from soil physical and chemical properties. *Soil. Sci. Soc. Am. J.* 55:787-794.
 - 14- McBratney A.B., Minasny B., Cattle S.R., and Vervoort R.W. 2002. From pedotransfer function to soil inference systems. *Geoderma*, 93:225-253.
 - 15- Merdun H., Meral O.C., and Apan R.M. 2006. Comparison of artificial neural network and regression Pedotransfer functions for predict of water retention and saturated hydraulic conductivity. *Soil and Tillage Research*, 90:108-116.
 - 16- Minasny B., and Mcbratney A.B. 2002. The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil. Sci. Soc. Am. J.*, 66:352-361.
 - 17- Minasny B., Mcbratney A.B., and Bristow K.L. 1999. Comparison of different approaches to the development of pedotransfer functions for water-retention curves. *Geoderma*, 93:225-253.
 - 18- Nelson D.W., and Sommers L.P. 1986. Total carbon, organic carbon and organic matter. pp. 539-579. in: A. C. page(ED.), *Methods of Soil Analysis. Part 2*. Am. Soc. Agron., Madison, Wisconsin, USA.
 - 19- Nestor S.Y. 2006. Modelling the infiltration process multi-layer perceptron artificial network. *Hydrol. Sci. J.* 51(1): 3-20.
 - 20- Pachepsky Y.A., and Rawls W.J. 1999. Accuracy and reliability of pedotransfer function as affected by grouping soils. *Soil. Sci. Am. J.*, 63:1748-1757.
 - 21- Pachepsky Y.A., Timlin D., and Varallyay G. 1996. Artificial neural networks to estimate soil water retention from easily measurable data. *Soil. Sci. Soc. Am. J.*, 60:727-733.
 - 22- Persson M., and Bertacchi U.C. 2003. Estimating soil solution electrical conductivity from time domain reflectometry measurements using neural networks. *J. Hydrol.* 273: 249-256.
 - 23- Schaap M.G., Leij F.J., and Van Genuchten M.T. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil. Sci. Soc. Am. J.*, 62:847-855.
 - 24- Schaap M.G., and Bouten W. 1996. Modelling water retention curves of sandy soils using neural networks. *Water resou. Res.* 32:3033-3040.
 - 25- Stewart W.M., and Hossner L.R. 2001. Factors affecting ratio of cation exchange capacity to clay content in lignite overburden. *J of Environ Qual*, 30:1143-1149.
 - 26- Sunil K, Sinha M., and Wang C. 2008. Artificial Neural Network Prediction Models for Soil Compaction and Permeability. *Geotech Geol Eng*, 26:47-64.
 - 27- Tamari S., Wosten J.H.M., and Ruize J.C. 1996. Testing an arificial neural networks for predicting soil hydraulic conductivity, *Soil. Sci. Soc. Am J.* 60: 1732-1741.
 - 28- Tang L., Zeng G.M., Nourbakhsh F., and Shen G.L. 2008. Artificial neural network approach for predicting cation exchange capacity in soil based on physico-chemical properties. *Environ. Eng. Sci.* 26(2): 1-10.
 - 29- Thomas G.W. 1982. Exchangable cation. In: Page, A. L. (Ed.), *Method of soil analysis. part2*. Agron. Monograph 9, ASA, WI:159-165.
 - 30- Wagner B., Tranawski V.R., Hennings V., Muller U., Wessolek G., and Playge R. 2001. Evaluation of pedo-transfer function for unsaturated soil hydraulic conductivity using an independent data set. *Geoderma*, 102: 275-279.
 - 31- Wang Q.R., and Klassen W. 2005. Determination of cation exchange capacity on low to highly calcareous soils. *Communications in Soil Science and Plant Analysis.* 36:1479-1498.
 - 32- Wosten J.H.M., Pachepsky Y.A., and Rawls W.J. 2001. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *Journal of Hydrology*, 251:123-150.

Comparison of artificial neural network and regression transfer functions models for prediction of soil cation exchange capacity in Chaharmahal - Bakhtiari province

M. Memarian Fard^{1*} – H. Beigi Harchagani²

Abstract

Cation Exchange Capacity (CEC) is an important characteristic of soil in terms of nutrient and water holding capacities and contamination management. Measurement of CEC is laborious and time-consuming. Therefore, CEC estimation through other easily - measured properties is desirable. In this study, PTFs for estimation of cation exchange capacity from basic soil properties such as particle-size distribution, organic carbon, percentage saturation and pH were developed and validated using artificial neural network (ANN) and multiple-linear regression methods and the predictive capabilities of the two methods was compared using some evaluation criteria. Total of 200 soil samples was divided into two groups as 165 for the development and 35 for the validation of PTFs. Accuracy of the predictions was evaluated by the criteria of coefficient of determination (R^2) and the root mean square error (RMSE) between the measured and predicted CEC values. Clay (%), OC (%), SP and sand (%) predicted CEC better than other models with an $R^2=0.81$ and $RMSE=3.05 \text{ cmol.kg}^{-1}$ when a neural networks model with one hidden layer and seven nodes was used. The R^2 and RMSE varied from 0.66 to 0.69 and from 4.26 to 4.69 for regression, and varied from 0.78 to 0.81 and from 3.05 to 3.29 for ANN, respectively. Results showed that neural networks predictions is better than regression-based functions.

Key words: Artificial neural networks, Cation Exchange Capacity, Chaharmahal - Bakhtiari

1 , 2 - MSc. Student and Assistant prof., Soil Science Department, Share kord University, Respectively
(* - Corresponding author Email: memarian@yahoo.com)