

پیش‌بینی ظرفیت تبادل کاتیونی خاک‌های استان گیلان با استفاده از مدل‌های هوشمند

احمد بازوبندی، هادی قربانی¹، صمد امامقلی زاده و محمد رضا شعیبی نویریان

دانشجوی سابق کارشناسی ارشد دانشگاه صنعتی شاهرود؛ Ahmad.bazoo@yahoo.com

دانشیار دانشکده کشاورزی دانشگاه صنعتی شاهرود؛ ghorbani1969@yahoo.com

دانشیار دانشکده کشاورزی دانشگاه صنعتی شاهرود؛ s_gholizadeh517@yahoo.com

دانشجوی سابق کارشناسی ارشد دانشگاه تربیت مدرس؛ shoaibimohammadreza@gmail.com

دریافت: 95/2/26 و پذیرش: 96/3/3

چکیده

ظرفیت تبادل کاتیونی (CEC) یکی از مهم‌ترین ویژگی‌های خاک در ارتباط با نگهداری مواد غذایی، 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 پژوهش با کمک مدل‌های هوشمند و با استفاده از خصوصیات فیزیکی و شیمیایی خاک مانند توزیع اندازه ذرات، کربن آلی، میزان رس، شن، فسفر، نیتروژن، pH و EC به پیش‌بینی CEC خاک پرداخته شد. سه مدل هوشمند شامل شبکه‌های عصبی مصنوعی از نوع MLP، شبکه‌های عصبی مصنوعی از نوع RBF و مدل عصبی-فازی تطبیقی (ANFIS) برای پیش‌بینی مورد استفاده قرار گرفت. 250 نمونه‌ی خاک جمع‌آوری شده به دودسته‌ی آموزش (80 درصد داده‌ها) و صحت سنجی (20 درصد داده‌ها) تقسیم شدند. دقت پیش‌بینی مدل مورد استفاده به وسیله شاخص‌های آماری مانند میانگین قدر مطلق خطا (MAE)، ضریب تبیین (R^2) و ریشه دوم میانگین مربعات خطا (RMSE) مورد ارزیابی قرار گرفت. نتایج به دست آمده کارایی بالاتر مدل شبکه عصبی مصنوعی MLP را در مقایسه با دو مدل مذکور با مقادیر MAE، RMSE، R^2 به ترتیب برابر با 1/79، 2/54 و 0/81 نشان داد. همچنین آنالیز حساسیت انجام شده بر روی داده‌های ورودی به مدل نشان داد کربن آلی بیشترین و کمترین همبستگی را با ظرفیت تبادل کاتیونی دارند. با توجه به نتایج این مطالعه استفاده از شبکه عصبی مصنوعی برای تخمین ظرفیت تبادل کاتیونی خاک به خوبی امکان‌پذیر است و می‌تواند با کارایی مناسب در جهت سهولت در اندازه‌گیری و صرفه‌جویی در زمان و هزینه‌ها به کار گرفته شود.

واژه‌های کلیدی: خصوصیات زود یافت، شبکه‌ی عصبی مصنوعی، MLP، RBF، مدل عصبی-فازی تطبیقی (ANFIS)

¹ نویسنده مسئول، آدرس: شاهرود، دانشکده کشاورزی دانشگاه صنعتی شاهرود، گروه مهندسی آب و خاک

مقدمه

اندازه‌گیری ظرفیت تبادل کاتیونی خاک (CEC) در سطوح وسیع، معمولاً بسیار پرهزینه و وقت‌گیر است. ظرفیت تبادل کاتیونی یکی از ویژگی‌های مهم خاک است که بسیاری از عملکردهای اساسی خاک در ارتباط با نوسانات اسیدیته (pH) نگهداری آب، مواد غذایی و آلاینده‌ها را کنترل می‌نماید و به همین دلیل این پارامتر، یکی از شاخص‌های کلیدی در مدیریت حاصل خیزی خاک و بهره‌وری زمین محسوب می‌شود (کارو و همکاران، 2002). همچنین تعیین سطوح بحرانی آلاینده‌های شیمیایی در خاک و پالایش آن‌ها از خاک، بدون دسترسی به داده‌های CEC امکان‌پذیر نمی‌باشد. داده‌های CEC خاک‌های زراعی می‌تواند تفسیر روشن‌تر و کامل‌تری از فرایندهای تغذیه گیاه، کاربرد کودها و اصلاح شیمیایی خاک‌ها را در اختیار پژوهشگران قرار دهد.

دقیق‌ترین داده‌های CEC خاک‌ها در آزمایشگاه و از طریق اندازه‌گیری مستقیم به دست می‌آید، ولی روش‌های اندازه‌گیری این پارامتر به نسبت پزرحمت، پرهزینه و البته بسیار وقت‌گیر می‌باشند (مک براتی و همکاران، 2002). حال آنکه استفاده از مدل‌های هوشمند گامی نو در جهت پیش‌بینی و تخمین این پارامتر دیر یافت و پرهزینه با صرف هزینه و زمان کمتر است. تخمین پارامترهای دیر یافت خاک با استفاده از اطلاعات موجود خاک توابع انتقالی نامیده می‌شود جهت توسعه توابع انتقالی می‌توان از مدل‌های رگرسیون چند متغیره، شبکه‌ی عصبی مصنوعی و نرو فازی استفاده کرد. امروزه مدل‌های شبکه‌های عصبی مصنوعی در بخش‌های مختلف علوم به‌منظور مدل‌سازی روابط پیچیده غیرخطی به کار گرفته می‌شود و تا حدودی جایگزین مدل‌های آماری شده است زیرا شبکه‌های عصبی مصنوعی بدون نیاز به حل معادلات دیفرانسیل جزئی، غیرخطی بودن فرایند موردنظر را شبیه‌سازی می‌نمایند و حتی زمانی که مجموع داده‌های آموزشی حاوی داده‌های خطا دار باشد، عملکرد مناسبی را نشان می‌دهند و برخلاف مدل‌های چند متغیره رگرسیونی (مدل‌های آماری) نیاز به انتخاب اولیه شکل تابع ریاضی مرتبط کننده ورودی و خروجی سیستم وجود ندارد (دامنگیر، 1380).

شبکه‌های عصبی مصنوعی در واقع از ساختار درهم و توده‌ای مغز پستانداران الهام گرفته شده است که در آن میلیون‌ها سلول عصبی (نورون) از طریق ارتباطاتی که با یکدیگر دارند (سیناپس‌ها)، به حل مسائل یا ذخیره‌سازی اطلاعات می‌پردازند. ساختار اصلی شبکه‌های

عصبی مصنوعی بر اساس دو جزء اصلی گره‌ها (نورون‌ها) و ارتباطات وزن‌دار (سیناپس‌ها) می‌باشد یادگیری در سیستم‌های طبیعی به‌صورت تطبیقی اتفاق می‌افتد. بدین معنی که در اثر یادگیری، در سیناپس‌ها تغییراتی رخ می‌دهد. عین همین مسئله نیز در مورد شبکه‌های عصبی مصنوعی صادق است. در این شبکه‌ها یادگیری از طریق مثال انجام می‌شود. بدین معنی که اغلب (و نه همواره) مجموعه‌ای از ورودی‌ها و خروجی‌های درست به شبکه عصبی داده می‌شود و شبکه عصبی با استفاده از این مثال‌ها، وزن‌های ارتباطات خود را به‌گونه‌ای تغییر می‌دهد که در صورت دادن ورودی‌های جدید پاسخ‌های درستی را تولید کند. در واقع دانش شبکه عصبی در وزن ارتباطات آن ذخیره می‌شود.

مدل دیگری که مورد استفاده قرار می‌گیرد سیستم استنتاج تطبیقی عصبی- فازی (ANFIS) است. این مدل اولین بار در سال 1993 توسط ژانگ (1993 و 1997) معرفی شد. این سیستم ابزاری جهانی جهت تخمین توابع پیوسته حقیقی در دامنه‌ای محدود می‌باشد که به ازای هر درجه‌ای از صحت قابل استفاده است. شبکه فازی- عصبی از نظر کارایی معادل سیستم استنتاج فازی می‌باشد.

در سال‌های اخیر، توابع انتقالی گوناگونی برای تخمین CEC، خصوصیات شیمیایی و فیزیکی اساسی خاک توسعه داده شده است. در اغلب این مدل‌ها CEC به‌عنوان تابع خطی از ماده آلی و مقدار رس خاک در نظر گرفته می‌شود (برووسما و همکاران 1986، مک بارتنی و همکاران 2002). قربانی و همکاران (2015) شبکه‌های عصبی MLP و RBF و مدل‌های ANFIS را برای تخمین ظرفیت تبادل کاتیونی خاک مورد استفاده قرار دادند و با مدل‌های سنتی خطی چندگانه مقایسه کردند. نتایج نشان داد که مدل ANFIS عملکرد بهتری در پیش‌بینی CEC دارد. مهاجر و همکاران (1388) از روش شبکه‌ی عصبی مصنوعی برای پیش‌بینی میزان ظرفیت تبادل کاتیونی خاک استفاده کردند و بیان کردند شبکه‌ی عصبی مصنوعی دارای دقت زیادی در برآورد ظرفیت تبادل کاتیونی خاک است. امینی و همکاران (2005) با استفاده از مقدار ماده آلی و رس میزان CEC خاک را به کمک شبکه عصبی مصنوعی و مدل‌های تجربی (که بر پایه روش‌های رگرسیونی می‌باشند) برآورد کردند. نتایج این محققان نشان داد که روش شبکه عصبی از برتری قابل‌قبولی نسبت به سایر روش‌ها برخوردار می‌باشد. مهربانیان و همکاران (1388) به مدل‌سازی ظرفیت تبادل کاتیونی خاک با شبکه‌ی عصبی مصنوعی، رگرسیون چند متغیره و توابع انتقالی پرداختند و گزارش آنان حاکی از این حقیقت

این اهداف و به‌منظور کاهش معضلات ذکرشده برنامه‌ریزی شد.

مواد و روش‌ها

منطقه‌ی مورد مطالعه

استان گیلان با مساحت 14711 کیلومترمربع در میان رشته‌کوه‌های البرز و تالش در شمال ایران جای گرفته است. این استان به واحد جغرافیایی جنوب دریای مازندران تعلق دارد و با استان‌های اردبیل در غرب، مازندران در شرق، زنجان در جنوب و کشور تازه استقلال‌یافته آذربایجان و دریای خزر در شمال هم‌مرز و همسایه است. استان گیلان بین 36 درجه و 36 دقیقه تا 38 درجه و 27 دقیقه‌ی عرض شمالی و 48 درجه و 25 دقیقه تا 50 درجه و 34 دقیقه‌ی طول شرقی از نصف‌النهار گرینویچ قرار دارد.

نمونه‌برداری از خاک و تجزیه‌ی فیزیکی و شیمیایی نمونه‌های خاک

در این آزمایش نمونه‌برداری از مناطق مختلف استان گیلان (شکل 1) از عمق (0-30 سانتیمتری) سطح خاک انجام شد پس از آماده‌سازی اولیه بافت خاک به روش هیدرومتری (بویوکوس 1962)، فسفر خاک به روش اولسن و همکاران (1982)، نیتروژن کل به روش کج‌دال (برمنز و مولوانی، 1982)، pH در خمیر اشباع (پیگ و همکاران 1982)، CEC به روش چاپمن (چاپمن 1965)، قابلیت هدایت الکتریکی در عصاره گل اشباع توسط هدایت سنج (مدل JENWAY 4310) (ریچاردز، 1954) و درصد کربن و ماده آلی به روش اکسایش با دی کرومات (والکلی-بلک 1934) اندازه‌گیری شدند (آزمایشگاه بخش خاکشناسی مرکز تحقیقات استان گیلان) که به‌طور خلاصه برخی شاخص‌های آماری مربوط به نمونه‌ها در جدول 1 آمده است.

بود که شبکه‌های عصبی مصنوعی دارای کیفیت لازم جهت تخمین ظرفیت تبادل کاتیونی است. مهربانیان و همکاران (1389) از مدل شبکه‌ی عصبی برای تخمین ظرفیت تبادل کاتیونی خاک‌های آهکی و گچی استان یزد استفاده کردند و با اندازه‌گیری پارامترهای اجزا بافت خاک و درصد کربن آلی خاک به پیش‌بینی ظرفیت تبادل کاتیونی با مدل‌های شبکه‌ی عصبی و رگرسیون خطی پرداختند، نتایج نشان داد مدل شبکه‌ی عصبی مصنوعی توانایی بیشتری در تخمین ظرفیت تبادل کاتیونی دارد. هزارجریبی و همکاران (2013) بیان کردند روش شبکه عصبی مصنوعی دارای دقت زیادی در برآورد ظرفیت تبادل کاتیونی خاک است. همان‌گونه که از منابع مشخص است نتایج متفاوتی از مدل‌سازی‌ها بسته به منطقه و پارامترهای موردنظر به‌دست آمده است.

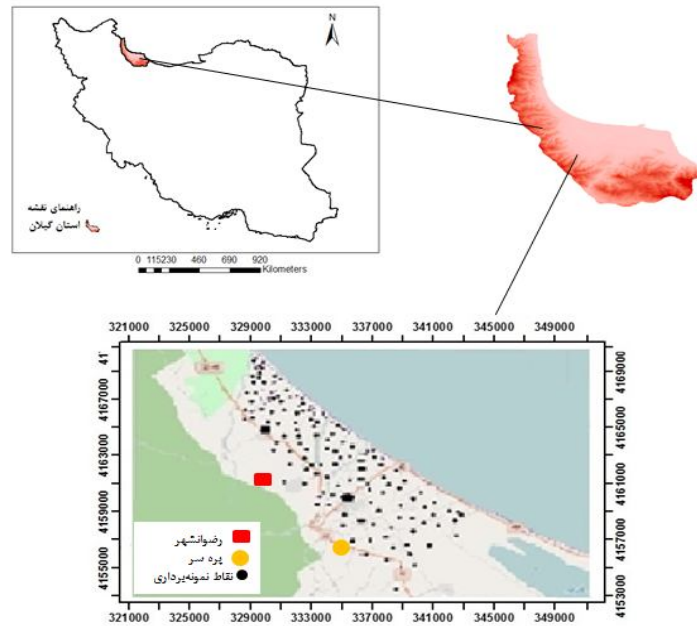
مناطق مرطوب

خاک‌های مناطق مرطوب معمولاً تحت شرایط اشباع از آب در دوره‌ای خاص و دارای خواص اکسیدی‌اند، درصد بالایی از مواد آلی را دارا می‌باشند همچنین جرم مخصوص حقیقی کم ولی ظرفیت تبادل کاتیونی و مواد غذایی زیاد و خاصیت اسیدی دارند. ظرفیت تبادل کاتیونی بالای این خاک‌ها برگرفته از مواد آلی نسبتاً بالا و همچنین میزان رس بالا در این خاک‌هاست، اما خاک‌های مناطق مرطوب ایران معمولاً به دلیل آهکی بودن مواد مادری خاصیت اسیدی کمتری از خود نشان می‌دهند. به دلیل ظرفیت تبادل کاتیونی بالا و اهمیت اندازه‌گیری این پارامتر تأثیرگذار همچنین مسئله صرف هزینه و زمان در روش اندازه‌گیری ظرفیت تبادل کاتیونی در این‌گونه خاک‌ها و این واقعیت که در سال‌های اخیر موردتوافق شمار زیادی از محققین قرا گرفته است که مدل‌های هوشمند توانایی جایگزین شدن با یک سری از کارهای آزمایشگاهی را دارا می‌باشند مطالعه‌ی حاضر با

جدول 1- پارامترهای آماری داده‌های استفاده شده در مدل نرو فازی، شبکه‌ی عصبی و رگرسیون چند متغیره.

پارامتر آماری	pH	فسفر (mg kg ⁻¹)	کربن آلی (درصد)	شن (درصد)	رس (درصد)	نیتروژن (mg kg ⁻¹)	CEC (cmol _c /kg)	EC (dSm ⁻¹)
میانگین	6/61	11/75	1/49	33/29	37/80	0/58	29/48	2/76
واریانس	0/06	13/96	0/11	49/71	43/83	0/017	36/94	0/37
چولگی	-0/23	0/707	-0/51	0/460	-1/34	-1/01	-0/17	-0/64
کمترین	6/5	0/6	0/7	20	19	0/23	16	1/50
بیشترین	7/5	20	2	53	45	0/75	45	3/60
میانگین	6/29	12/28	1/41	27/6	36/25	0/55	27/81	2/76
واریانس	0/08	11/21	0/09	150/82	57/69	0/02	32/70	0/253
چولگی	-0/72	0/92	-0/45	1/33	-0/504	-0/23	-0/36	-0/79
کمترین	6/1	7	0/60	10	12	0/14	9	1/20
بیشترین	7/7	23/50	2	68	54	0/84	45	3/80

CEC: Cation Exchange Capacity- EC: Electrical Conductivity



شکل 1- موقعیت مکان نمونه‌برداری در منطقه مورد مطالعه

مدل‌سازی داده‌ها را به دودسته تقسیم کرده به طوری که 80 درصد داده‌ها برای آموزش و 20 درصد برای صحت سنجی اختصاص داده شد (امینی و همکاران 2005، منهاج 2009). برای این منظور دودسته داده به طور تصادفی تعیین شد به طوری که از نظر معیارهای آماری از قبیل میانگین و انحراف معیار تا حد ممکن شبیه یکدیگر بودند همچنین دو گروه داده تفاوت معنی‌داری در سطح 5 درصد نداشتند (توماسلا و همکاران 2000، سرمیدیان و همکاران، 2009). برای انتخاب داده‌های آزمون و صحت سنجی از آزمون تی تست استفاده شد. در این آزمون اگر بین داده‌های صحت سنجی و آموزش تفاوت معنی‌داری وجود نداشته باشد می‌توان انتظار نتایج بهتری را از مدل داشت در جدول 1 معیارهای آماری مربوط به داده‌های تست و آموزش ارائه شده است. برای انجام همه مدل‌سازی‌ها از نرم‌افزار MATLAB 2013 استفاده شد.


مدل ریاضی شبکه عصبی مصنوعی

شبکه‌ی عصبی مصنوعی شبیه سیستم نوروهای طبیعی است (کوئک کوئک و بولتینیک 1999). به هنگام مدل کردن اعصاب، از پیچیدگی‌های آن‌ها صرف‌نظر می‌شود و تنها به مفاهیم پایه‌ای بها داده می‌شود، چراکه در غیر این صورت رویکرد مدل‌سازی بسیار دشوار خواهد شد. در یک نگاه ساده، مدل یک عصب باید شامل ورودی‌هایی باشد که در نقش سیناپس انجام وظیفه کنند. این ورودی‌ها در وزن‌هایی ضرب می‌شوند تا قدرت

شاخص‌های آماری محاسبه شده از داده‌های اندازه‌گیری شده از منطقه مورد مطالعه که در جدول 1 مشخص شده است، نشان می‌دهد، با توجه به میانگین پ هاش اندازه‌گیری شده، اسیدیته خاک‌ها تقریباً در حالت اسیدی بوده و همچنین همان‌گونه که انتظار می‌رود با توجه به مرطوب بودن منطقه، ماده آلی خاک زیاد بوده و حدود 2 درصد است. بافت خاک تقریباً سنگین و نزدیک به رسی و از نظر شوری مساعد است و در بیشترین میزان، قابلیت هدایت الکتریکی خاک (EC) برابر 3/8 دسی زیمنس بر متر است که نزدیک به حد بحرانی شوری است. میزان ظرفیت تبادل کاتیونی با توجه به بافت خاک و میزان ماده آلی موجود در خاک زیاد است. در آمار و نظریه احتمالات چولگی نشان‌دهنده میزان عدم تقارن توزیع احتمالی است. اگر داده‌ها نسبت به میانگین متقارن باشند، چولگی برابر صفر خواهد بود چولگی در تمام پارامترها بین 1 و 1- است و نشان از کشیدگی و نامتقارن بودن داده‌هاست که با توجه به پیچیده بودن خاک امری کاملاً طبیعی است. همچنین در نظریه احتمالات و آمار واریانس نوعی سنجش پراکندگی است و نشان می‌دهد چگونه یک سری داده حول مقدار میانگین پخش می‌شوند که هرچه کمتر باشد نشان از پراکنش کم داده‌ها حول میانگین است، در داده مطالعه حاضر میزان رس، شن و ظرفیت تبادل کاتیونی دارای واریانس نسبتاً زیاد بودند که نشان‌دهنده پراکندگی زیاد این داده‌ها است. به‌منظور

مشهورترین این توابع می‌توان به تابع‌هایی نظیر سیگموئید، هایپربولیک تانژانت، هایپربولیک سکانت اشاره کرد. همچنین تعداد گره‌های ورودی می‌تواند متغیر باشد. البته با زیاد شدن تعداد این گره‌ها، به‌وضوح تعیین وزن‌ها را با مشکل روبرو می‌کند. لذا باید به دنبال روش‌هایی برای حل این موضوع باشیم. روند تعیین وزن‌های بهینه و تنظیم مقادیر آن‌ها عمدتاً به‌صورت بازگشتی انجام می‌شود. بدین منظور شبکه را با استفاده از قواعد و داده‌ها آموزش داده و با استفاده از قابلیت یادگیری شبکه، الگوریتم‌های متنوعی پیشنهاد می‌شود که همگی سعی در نزدیک کردن خروجی تولیدشده توسط شبکه به خروجی ایدال و مورد انتظار دارند (کاشی و همکاران 1392).

سیگنال را تعیین کنند. نهایتاً یک عملگر ریاضی تصمیم‌گیری می‌کند که آیا نورون فعال شود یا خیر و اگر جواب مثبت باشد، میزان خروجی را مشخص می‌سازد. بنابراین شبکه عصبی مصنوعی با استفاده از مدل ساده‌شده عصب واقعی به پردازش اطلاعات می‌پردازد. جدای از ساده‌سازی‌های اعمال‌شده، تفاوت اصلی این مدل با واقعیت در این است که در شبکه واقعی، ورودی‌ها سیگنال‌های زمانی هستند حال‌آنکه در این مدل، اعداد حقیقی ورودی هستند. در مدل ارائه‌شده در شکل 2، تنوع‌های بسیاری وجود دارد. از جمله این‌که وزن‌های یک شبکه عصبی، که مقدار خروجی را منتقل می‌کنند، می‌توانند مثبت یا منفی باشند. از طرفی، توابع مورد استفاده برای آستانه گذاری می‌توانند بسیار متنوع باشند. از جمله



شکل 2- مدل ریاضی ساده‌شده عصبی واقعی. (weight: وزن، Thresholdin: آستانه، Input: ورودی، Output: خروجی)


پرسپترون چندلایه

داده‌ها، تأثیر متفاوتی بر روی شبکه گذاشته، به صورتی که برخی از نورون‌ها خیلی زود به حد فعال‌سازی رسیده، درحالی‌که برخی دیگر از نورون‌ها حتی به آستانه فعالیت نیز نرسیده‌اند (منهاج 2009). لازم به ذکر است نرم‌افزار MATLAB2013 داده‌ها را با رابطه‌ی 1 بین 0/9-0/1 نرمال می‌سازد.

$$(1) \quad 0.15 + 0.7 * \frac{x - x_{min}}{x_{max} - x_{min}}$$

که در آن X داده نرمال نشده و X_{min} کوچک‌ترین داده X_{max} بزرگ‌ترین داده است. با توجه به شکل 3 ملاحظه می‌شود که کمترین مقدار RMSE در پیش‌بینی ظرفیت تبادل کاتیونی مربوط به شبکه‌ای با 10 نورون در لایه‌ی مخفی می‌باشد و قابل ذکر است که تغییرات RMSE دارای روند مشخصی نیست چون در شبکه عصبی وزن‌ها به‌طور تصادفی انتخاب می‌شوند و نمی‌توان روند موجود را به‌طور کامل توضیح داد و تنها باید با سعی و خطا بهترین ساختار را به دست آورد.


انتخاب معماری شبکه در محاسبات مربوط به شبکه عصبی مصنوعی با سعی و خطا انجام می‌شود. در این گام با استفاده از تعداد مختلف لایه‌های پنهان و نورون‌های مربوط، می‌توان شبکه با عملکرد بهینه یا نزدیک به بهینه را تعیین نمود. پارامترهای آماری داده‌های ورودی در جدول 1 نشان داده‌شده‌اند. لازم به ذکر است نرم‌افزار MATLAB قادر است خروجی را بر اساس تعداد تکرار بهینه تولید نماید. تابع محرک هایپربولیک سکانت در تمام مدل‌سازی‌ها به کار گرفته شد. تعداد گره‌های ورودی مدل (لایه اول شبکه) انتخاب شد (7 گره) و تعداد گره‌های موجود در لایه مخفی به کمک سعی و خطا تعیین شد. در این مطالعه، برای هر یک از الگوهای ورودی، تعداد مختلفی گره در لایه مخفی (10) در نظر گرفته شد و یک گره برای لایه خروجی در نظر گرفته شد. پس از تعیین مجموع داده‌های تست و آموزش، داده‌های ورودی به شبکه را باید استانداردسازی کرد. در صورتی‌که داده‌ها به‌صورت خام وارد شبکه شود، به دلیل تغییرات زیاد



شکل 3- مقادیر RMSE (ریشه دوم میانگین مربعات خطا) حاصل از به‌کارگیری تعداد نرون‌های متفاوت برای تخمین ظرفیت تبادل کاتیونی خاک

به‌اختصار MLP می‌باشد. یک شبکه‌ی پرسپترون چندلایه معمولاً شامل یک‌لایه‌ی ورودی که داده‌ها برای شبکه معرفی می‌شود، یک یا چندلایه‌ی مخفی که اطلاعات را از ورودی گرفته و برای پیش‌بینی خروجی استفاده می‌کند و لایه‌ی خروجی که نتیجه را نشان می‌دهد می‌شود (اسچاپ و بوتن 1996). تعداد بخش‌های ورودی و خروجی بستگی به شمار متغیرهای ورودی و خروجی در داده‌ها دارد. تعداد لایه مخفی معمولاً به‌صورت تجربی به دست می‌آید (هیجت-نلسن 1991). شکل 4 شمای یک شبکه پرسپترون سه لایه را نشان می‌دهد. به‌سادگی می‌تواند استنباط نمود که تعداد نرون‌های هر لایه، مستقل از تعداد نرون‌های دیگر لایه‌ها هست.

هرچند نحوه مدل کردن نرون جزء اساسی‌ترین نکات کلیدی در کار آبی شبکه عصبی می‌باشد اما نحوه برقراری اتصالات و چیدمان (توپولوژی) شبکه نیز فاکتور بسیار مهم و اثرگذاری است (کشاورزی و همکاران 2015). باید توجه داشت که توپولوژی مغز انسان آن‌قدر پیچیده است که نمی‌توان از آن به‌عنوان مدلی برای اعمال به شبکه عصبی استفاده نمود، چراکه مدلی که ما استفاده می‌کنیم، یک مدل ساده شده است درحالی‌که چیدمان مغز از المان‌های بسیار زیادی استفاده می‌کند. یکی از ساده‌ترین و درعین‌حال کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی عصب‌های واقعی، مدل پرسپترون چندلایه (Multilayer perceptron) یا



شکل 4- پرسپترون 3 لایه با اتصالات کامل (Input layer: لایه‌ی ورودی، Hidden Layer: لایه‌ی مخفی، Output Layer: لایه‌ی خروجی)


توابع پایه‌ی شعاعی

برای انجام مدل‌سازی به روش (RBF) از نرم‌افزار Matlab استفاده شد و پارامترها همانند شبکه‌ی MLP مقادیر درصد شن و رس، کربن آلی، نیتروژن کل، pH، میزان فسفر و هدایت الکتریکی به‌عنوان پارامترهای ورودی و مقدار ظرفیت تبادل کاتیونی به‌عنوان خروجی انتخاب شدند. در این مدل‌سازی نیز 80% داده‌ها به‌عنوان آموزش و 20% داده‌ها به‌عنوان داده‌های صحت‌سنجی به‌نرم‌افزار معرفی شدند. توابع پایه‌ی شعاعی به‌طور گسترده‌ای برای تخمین توابع چندبعدی از طریق مجموعه‌ای محدود از اطلاعات آموزشی به کار می‌رود. این شبکه‌ها به‌واسطه‌ی آموزش سریع و فراگیر بسیار جالب و مفید هستند و موردتوجه خاصی قرار گرفته‌اند. در سال 1990 میلادی بود که اثبات کردند که شبکه‌های تابع مدار شعاعی تقریب سازهای بسیار قدرتمندی هستند به‌طوری‌که با داشتن تعداد نورون‌های کافی در لایه مخفی قادر به تقریب سازی هر تابع پیوسته و با هر درجه دقت می‌باشند (هارتمن و همکاران، 1990). نکته بسیار جالب آن است که این شبکه‌ها تنها با داشتن یک‌لایه‌ی مخفی، دارای چنین خاصیتی هستند. شبکه‌های تابع مدار شعاعی بیشترین الهام را از روش‌های آماری طبقه‌بندی الگوها گرفته‌اند که اساساً به‌عنوان گونه‌ای از شبکه‌های عصبی، حیاتی‌نویافته‌اند و مزیت عمده آن‌ها طبقه‌بندی الگوهای که دارای فضای غیرخطی هستند می‌باشد. با قرار دادن این شبکه برای طبقه‌بندی اصلی شبکه‌های عصبی، به فراوانی به کار گرفته شده‌اند این شبکه‌ها اغلب با شبکه‌های پس انتشار خطا مقایسه می‌شود.

مدل سیستم استنتاج تطبیقی عصبی - فازی (ANFIS)

در این ساختار مجموعه‌های فازی را می‌توان به‌عنوان وزن، ارتباطات و متغیرهای ورودی و خروجی را به‌عنوان نورون‌ها تفسیر کرد و الگوریتم یادگیری ساختارها، پارامترها و یا هردوی آن‌ها را اصلاح می‌کند. شبکه‌ی عصبی فازی ترکیبی از شبکه عصبی و سیستم فازی است که از قدرت یادگیری شبکه‌ی عصبی برای نقش‌های اگر - آنگاه استفاده کرده تا با توابع عضویت

مناسب اجزا را آموزش داده و نتیجه‌ی پایانی مناسبی را منتج شود (تای و ژانگ 2000، عزمت ... و همکاران، 2009). الگوریتم استنتاج فازی به‌عنوان شالوده‌ای از ANFIS روشی است که در آن نقش‌های فازی برای استنباط یک تقریب جدید مجموعه‌ی فازی که مجموعه‌ی فازی را اثبات می‌کند به کار گرفته شده‌اند (خوشنویسان و همکاران، 2014). سیستم استنتاج فازی عمدتاً برای مسائلی که یا مدل کردن دقیق سیستم مشکل است یا توصیف مسئله مورد مطالعه مبهم و دوپهلوی است به کار گرفته می‌شود (یانگ و همکاران 2011). ANFIS برای ویژگی‌های ورودی نقشه، ویژگی‌های ورودی تابع عضویت ورودی، تابع عضویت ورودی برای If- Then نقش‌های If- Then نقش‌های خروجی، ویژگی‌های خروجی تابع عضویت خروجی و تابع عضویت خروجی برای خروجی که انتخاب شده یا تصمیمی که با خروجی مربوط شده استفاده می‌شود (حیاتی و همکاران، 2011، رضایی و همکاران، 2012). از زمانی که پروفیسور لطفی زاده (1973) برای اولین بار تئوری منطق فازی را برای سیستم‌های پیچیده ارائه داد، این نظریه به‌طور گسترده‌ای در مسائل مختلف با موفقیت استفاده شده است. نکته مهم منطق فازی امکان برقراری ارتباط بین فضای ورودی به فضای خروجی می‌باشد و مکانیسم اولیه برای انجام این کار است که قانون نامیده می‌شوند. در فرایند آموزش، این قوانین به‌صورت If-Then لیستی از جملات موازی ارزیابی و تعیین می‌شوند. از طرف دیگر، شبکه‌های عصبی دارای توانایی آموزش از محیط جفت‌های ورودی -خروجی می‌باشد. برای اولین بار با مدنظر قرار دادن توانایی‌های تئوری فازی و شبکه عصبی، در سال 1993، جانگ مدل سیستم استنتاج تطبیقی عصبی فازی را ارائه داد. مدل استنتاج تطبیقی عصبی - فازی (ANFIS) به شبکه‌ای چندلایه، متشکل از گره‌ها و کمان‌های اتصال‌دهنده گره‌ها گفته می‌شود ساختار مدل ANFIS به‌صورت شماتیک در شکل 5 نشان داده شده است.



شکل 5- شماتیک شبکه استنتاج تطبیقی عصبی فازی با 5 لایه (جانگ 1993). Layer 1: لایه ی ورودی، Layer 2 و 3: لایه های میانی، Layer 4: تابع جمع کننده، Layer 5: تابع تبدیل

آنالیز حساسیت

به منظور تعیین اثر هر کدام از پارامترهای ورودی بر ظرفیت تبادل کاتیونی لازم است آنالیز حساسیت انجام می‌گیرد. این کار 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 داشته 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 این کار در هر مرحله از بین محاسبه 7 پارامتر ورودی، یکی از آن‌ها حذف شده و مقدار RMSE محاسبه گردید.

ارزیابی مدل‌ها

به منظور مقایسه عملکرد مدل‌های شبکه عصبی MLP و RBF و همچنین مدل ANFIS از پارامترهای آماری مانند ضریب تبیین (R^2) مطابق رابطه (2)، میانگین خطای مطلق (MAE) مطابق رابطه (3)، مجذور میانگین مربعات خطا (RMSE) مطابق رابطه (4) استفاده شد (وستن و همکاران، 2001).

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

$$MAE = \frac{1}{n} \sum_{j=1}^n \left| \hat{y}_j - y_j \right| \quad (3)$$


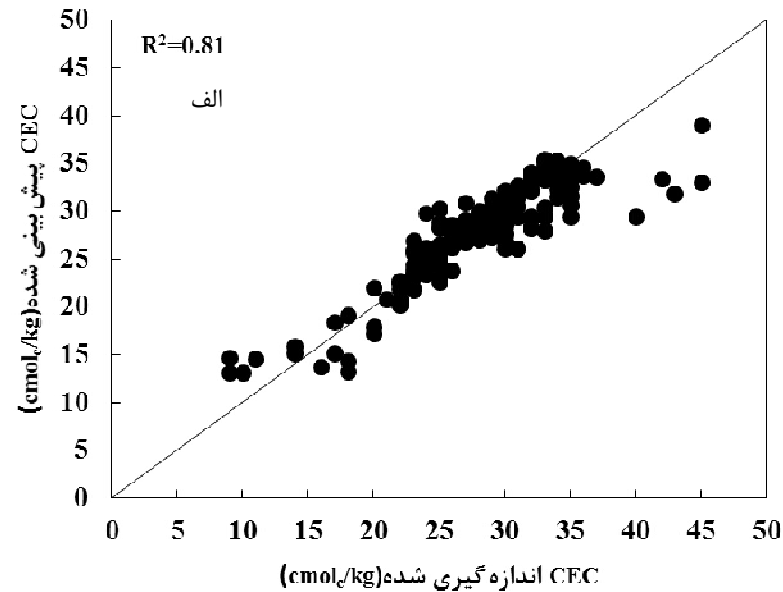
$$RMSE = \left[\frac{\sum_{j=1}^n (\hat{y}_j - y_j)^2}{n} \right]^{\frac{1}{2}} \quad (4)$$

که در این روابط n تعداد کل نمونه‌ها، y_i مقادیر مشاهده شده، \hat{y} خروجی پیش‌بینی شده، \bar{Y} میانگین مقدار پیش‌بینی شده است. مقدار RMSE و MAE نشان می‌دهد که پیش‌بینی‌ها تا چه حد، اندازه‌گیری را بیشتر یا کمتر تخمین زده‌اند. در شرایطی که مقادیر پیش‌بینی شده و اندازه‌گیری شده باهم برابر باشند RMSE و MAE برابر صفر خواهد بود. ضریب تبیین نیز از برازش خط بین داده‌های پیش‌بینی شده در مقابل داده‌های اندازه‌گیری شده به دست می‌آید.

نتایج و بحث

مدل شبکه عصبی MLP

همان‌طور که در شکل 6 مشخص شده است داده‌ها پراکنندگی مناسبی دارند به عبارتی میزان پیش‌بینی ظرفیت تبادل کاتیونی بسیار نزدیک به میزان اندازه‌گیری شده است و پراکنندگی نسبت به خط برازش داده شده بسیار کم است. ضریب تبیین بالا مؤید عملکرد قابل قبول مدل شبکه عصبی (MLP) در تخمین میزان ظرفیت تبادل کاتیونی است. همان‌گونه که مشخص شده ضریب تبیین در مراحل آموزش و صحت سنجی برابر است که خود نشان از آموزش مناسب مدل است.



شکل 6- نمودار پراکنش مربوط به مدل شبکه‌ی عصبی MLP برای تخمین ظرفیت تبادل کاتیونی خاک در مرحله‌ی آموزش (الف) و صحت سنجی (ب)



توابع پایه‌ی شعاعی (RBF)

حاکمی از پراکنندگی زیاد داده‌ها باشد، همچنین احتمال عدم یکنواختی در داده‌ها نیز وجود دارد که می‌تواند بر کارایی مدل خاص تأثیر گذارد. در منابع این میزان زیاد از کاهش میزان R^2 و افزایش میزان خطا در مورد این مدل گزارش نشده است با احتمال خطا در مدل‌سازی چندین مرتبه این کار تکرار شد که تفاوتی در خروجی

همان‌گونه که در شکل 7 مشخص است. هرچند در مرحله‌ی آموزش مدل به‌خوبی پیش‌بینی را انجام داد و میزان R^2 برابر 0/97 است اما در مرحله‌ی صحت سنجی کارایی مدل به‌شدت کاهش یافته و R^2 به 0/76 کاهش پیدا کرد. دلیل کاهش شدید در میزان ضریب تبیین می‌تواند

می‌تواند سایر خصوصیات خاک را تحت‌الشعاع قرار دهد

نداشت این موضوع نشانگر این اصل است که خاک محیطی پویا و همراه با پیچیدگی‌های بسیار است که



شکل 7- نمودار پراکنش مربوط به نتایج مدل شبکه‌ی عصبی RBF برای تخمین ظرفیت تبادل کاتیونی خاک در مرحله‌ی آموزش (الف) و صحت‌سنجی (ب)

جدول 2- ویژگی‌های مدل ANFIS انتخابی برای پیش‌بینی ظرفیت تبادل کاتیونی خاک



پارامتر پیش‌بینی شده	روش یادگیری	نوع تابع عضویت	تکرار	تعداد توابع عضویت
ظرفیت تبادل کاتیونی خاک	هیبرید	گوسی 2	1000	7

مدل عصبی فازی (ANFIS)

هیبرید که یکی از کاراترین روش‌ها در مدل است طرح‌ریزی شده است نوع تابع عضویت مدل با آزمون و خطا گاوسی 2 به دست آمد که با تکرار راه‌اندازی مدل 1000 مرتبه و تعداد 7 تابع عضویت بهترین خروجی از مدل استحصال شد چگونگی سنجش کیفیت خروجی با استفاده از پارامترهای سنجش مدل مشخص شد و بر همین مبنا بهترین خروجی با بالاترین ضریب تبیین و کمترین میزان خطا به دست آمد.

نتایج و خصوصیات مدل به‌کاررفته برای پیش بینی میزان ظرفیت تبادل کاتیونی در جدول 2 و چگونگی پراگندگی داده‌ها در شکل 8 ارائه شده است. بهترین ساختار با توجه به معیارهای آماری اعم از MAE و RMSE تعیین شد.

همان‌طور که در جدول 2 مشخص است مدل از ANFIS از نظر چند پارامتر بهینه شد، با روش یادگیری



شکل 8- نمودار پراکنش مربوط به نتایج مدل نرو فازی (ANFIS) برای تخمین ظرفیت تبادل کاتیونی خاک در مرحله‌ی آموزش (الف) و صحت سنجی (ب)

جدول 3- نتایج به‌دست‌آمده از تخمین ظرفیت تبادل کاتیونی خاک با استفاده از مدل‌های شبکه‌ی عصبی (MLP)، (RBF)، نرو فازی

مدل	مرحله‌ی محاسباتی	R ²	RMSE	MAE
شبکه‌ی عصبی (MLP)	آموزش	0/81	2/49	1/73
	صحت سنجی	0/81	2/54	1/79
نرو فازی (ANFIS)	آموزش	0/90	1/83	1/27
	صحت سنجی	0/80	2/67	1/83
شبکه عصبی (RBF)	آموزش	0/97	0/49	0/95
	صحت سنجی	0/75	2/87	1/73


MAE: میانگین قدر مطلق خطا - RMSE: ریشه دوم میانگین مربعات خطا - R²: ضریب تبیین

ارزیابی مدل‌ها

پیش‌بینی‌شده‌ی شبکه‌ی عصبی مصنوعی (MLP)، (RBF) و نرو فازی آورده شده است. همان‌طور که در این شکل‌ها مشاهده می‌شود مدل MLP با کمترین پراکندگی نسبت به برآزش داده‌شده بالاترین ضریب تبیین و کمترین میزان RMSE و MAE را نشان می‌دهد؛ و کمترین دقت در پیش‌بینی مربوط به مدل توابع پایه شعاعی (RBF) است که ضریب تبیین آن 0/75 است میزان خطا نیز به‌شدت افزایش پیدا کرده است به‌گونه‌ای که RMSE برابر با 2/87 و MAE برابر با 1/73 است کمترین میزان RMSE در مرحله صحت سنجی در مدل شبکه‌ی عصبی MLP مشخص شده است. همان‌طور که در شکل 9 مشخص شده است ضرایب تبیین برای هر یک از مدل‌ها محاسبه شده است که نشان از کارایی بهتر مدل شبکه‌ی عصبی (MLP) است.

نتایج مربوط به ANFIS و شبکه‌ی عصبی مربوط به پارامترهای مورداندازه‌گیری در جدول 3 آورده شده است. با توجه به این جدول ملاحظه می‌شود که در کل بهترین عملکرد مربوط به شبکه‌ی عصبی (MLP) با ضریب تبیین 0/81 و RMSE و MAE به ترتیب برابر با 2/54 و 1/73 می‌باشد.

نتایج حاصل از مرحله‌ی آموزش نشان‌دهنده‌ی این است که هرچند مدل RBF در این مرحله به‌خوبی پیش‌بینی را انجام داده است. اما در مرحله‌ی صحت سنجی توانایی پایین این مدل مشخص شده است قابل‌ذکر است که در مدل شبکه‌ی عصبی با مقایسه‌ی میزان RMSE و MAE بهترین تابع برای پیش‌بینی ظرفیت تبادل کاتیونی تابع هاپربولیک سکانت و گاوسی بوده است. در شکل‌های 5 تا 7 پراکنش داده‌های اندازه‌گیری شده و



شکل 9- نمودار ضریب تبیین مدل‌های مختلف در پیش‌بینی ظرفیت تبادل کاتیونی خاک

آنالیز حساسیت

نتایج آنالیز حساسیت در جدول 4 ارائه گردیده است. با توجه به جدول 4 مشاهده می‌شود که با حذف مقدار کربن آلی، بیشترین افزایش در RMSE ایجاد شده است. بنابراین کربن آلی به‌عنوان حساس‌ترین پارامتر محسوب می‌شود که نشان‌دهنده تأثیر زیاد مواد آلی برافزایش CEC به دلیل سطح ویژه زیاد و داشتن گروه‌های عامل می‌باشد (مانریک و همکاران 1991). هزارجریبی و همکاران (2013) بیان کردند که بافت و مقدار ماده آلی خاک مهم‌ترین فاکتورهای مؤثر بر ظرفیت تبادل کاتیونی خاک در منطقه می‌باشند. در بین پارامترهای حساس مدلی با پارامترهای ورودی درصد رس، سیلت و شن، لگاریتم میانگین هندسی و انحراف معیار هندسی اندازه ذرات به‌عنوان بهترین مدل پیش‌بینی کننده ظرفیت تبادل کاتیونی خاک از نظر دقت و سهل‌الوصول بودن انتخاب گردید. با حذف میزان pH از مدل ورودی کمترین تغییر در RMSE ایجاد شده است. بنابراین میزان pH خاک به‌عنوان پارامتری با کمترین حساسیت در بین پارامترهای ورودی بر CEC محسوب می‌شود. اگرچه میزان pH یکی از مهم‌ترین و تأثیرگذارترین پارامترها بر میزان بار منفی رس‌ها و مواد آلی است که این دو پارامتر مهم‌ترین عامل مؤثر بر میزان ظرفیت تبادل کاتیونی‌اند، اما به دلیل نوسان کم میزان pH و تغییر کم این پارامتر در خاک‌های منطقه مورد مطالعه مدل کمترین حساسیت را به این پارامتر نشان داد. درجه حساسیت همه پارامترها در جدول 4 ارائه شده است. در این جدول درجه 1 برای پارامتری است که بیشترین حساسیت را دارد و درجه 7 برای پارامتری است که کمترین حساسیت را دارا می‌باشد. نتایج آنالیز حساسیت خاک در شکل 10 نشان داده شده است. بر اساس نتایج حاصل، درصد کربن آلی و درصد رس بالاترین تأثیرگذاری را بر میزان ظرفیت تبادل کاتیونی دارند این امر به وجود سطح ویژه و بار سطحی زیاد رس‌ها و مواد آلی و تأثیر مستقیم این عوامل بر ظرفیت تبادل کاتیونی برمی‌گردد. در مطالعه‌ی حاضر با استفاده از شبکه‌ی عصبی (MLP)، (RBF) و نرو فازی مقادیر ظرفیت تبدالی خاک برآورد گردید. پس از تعیین ساختار بهینه‌ی هر یک از مدل‌ها با استفاده از معیارهای آماری MAE، RMSE و R^2


اقدام به پیش‌بینی CEC با استفاده از مدل مربوط گردید. نتایج بررسی نشان داد که در این مطالعه شبکه‌ی عصبی مصنوعی (MLP) نسبت به RBF و نرو فازی کارایی بهتر داشته زیرا احتمالاً از یک طرف کارایی توابع انتقالی به‌دست آمده در مناطق مختلف باهم متفاوت‌اند و از طرف دیگر بر طبق نظر اسپچاپ و همکاران (1998) در طراحی شبکه‌های عصبی نوعی خاص از معادلات لازم نیست و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست پیدا کرد. نتایج مطالعات گذشته نشان می‌دهد که شبکه‌های MLP متداول‌ترین نوع شبکه‌های عصبی در مدل‌سازی سیستم‌های مختلف می‌باشند. اما نتایج این بررسی نشان از عملکرد بهتر شبکه‌ی عصبی RBF است.

نتایج این بررسی با نتایج بررسی ارشد و همکاران (1388)، پائولو و همکاران (2002) و یلماز و کاینار (2011) که در آن به کارایی بالاتر شبکه MLP نسبت به شبکه RBF رسیدند، در تناقض است. شبکه عصبی RBF به دلیل داشتن تنها یک‌لایه مخفی تقریباً ساختار ساده‌تری نسبت به شبکه عصبی MLP دارد و همین پیچیدگی زیاد در مدل شبکه عصبی MLP می‌تواند باعث کاهش عملکرد آن در این مطالعه شده باشد. اما کاشی و همکاران (1392)، دهقانی و همکاران (1388)، صیادی و همکاران (1388)، کریستین و همکاران (2012) و جورج و همکاران (2010) در مطالعات خود در مقایسه دو مدل شبکه عصبی RBF و MLP گزارش کردند که مدل شبکه‌ی RBF عملکرد بالاتری نسبت به مدل شبکه‌ی MLP دارد که حاکی از عملکرد قابل قبول این مدل در مطالعه‌ی حاضر است. سرمدیان و همکاران (1388) در مطالعه‌ی گزارش کرد که مدل ANFIS عملکرد بهتری نسبت به شبکه‌ی عصبی مصنوعی دارد اما نتایج این مطالعه نشان از کارایی بالاتر هر دو مدل شبکه عصبی نسبت به مدل ANFIS دارد. علت این تناقض را می‌توان در پراکندگی متفاوت داده‌ها دانست چراکه تغییر در پراکندگی داده‌ها و همچنین تعداد پارامترهای ورودی می‌تواند نتایج مدل‌ها را تحت تأثیر قرار دهد همچنین با توجه به وجود عدم قطعیت در پدیده‌های مرتبط با خاک این تناقض‌ها را می‌توان متأثر از عواملی از این دست دانست.

جدول 4- نتایج آنالیز حساسیت و تعیین درجه حساسیت

درجه‌ی حساسیت	RMSE	پارامتر حذف شده
-	2/54	-
1	7/41	کربن آلی
2	6/14	رس
3	6/06	نیتروژن کل
4	5/14	فسفر کل
5	4/41	EC
6	3/57	شن
7	3/14	همه به‌جز pH

RMSE: ریشه دوم میانگین مربعات خطا



شکل 10- آنالیز حساسیت پارامترهای مختلف و درصد تأثیرگذاری آن‌ها در مدل MLP

نتیجه‌گیری

توانایی بالاتر و میزان خطای کمتری برخوردار بوده است. در پایان باید اذعان داشت که یکی از دلایل کارایی بالای مدل‌های شبکه عصبی مصنوعی، ماهیت ابهامی پدیده‌های مرتبط به خاک و یا تقریبی بودن مقادیر اندازه‌گیری شده خصوصیات مختلف در محیط خاک است. مدل‌های شبکه‌های عصبی مصنوعی به دلیل در نظر گرفتن روابط غیرخطی موجود میان داده‌های ورودی و خروجی و به دنبال آن افزایش دقت در مدل‌سازی می‌تواند جایگزین مناسبی برای مدل‌های مرسوم رگرسیون خطی باشد.

در پژوهش حاضر با توجه به اهمیت برآورد ظرفیت تبادل کاتیونی خاک از مدل‌های شبکه عصبی مصنوعی و مدل نرو فازی برای پیش‌بینی این پارامتر مهم خاک استفاده شد. نتایج به‌دست‌آمده نشان داد که مدل شبکه عصبی مصنوعی MLP با R^2 ، RMSE و MAE برابر $0/81$ ، $2/54$ و $1/79$ در مقایسه با مدل RBF با R^2 ، RMSE و MAE برابر $0/75$ ، $2/87$ و $1/73$ و مدل ANFIS با R^2 ، RMSE و MAE برابر $0/80$ ، $2/67$ و $1/83$ در تخمین ظرفیت تبادل کاتیونی خاک از دقت و

فهرست منابع:

1. ارشد ر،، صیاد ، غ.ع مظلوم م،، و جعفری نژاد ا.ر.، 1388 . تخمین نفوذ آب با شبکه عصبی مصنوعی. سومین کنفرانس آبیاری و مدیریت آب، اهواز. ایران.
2. دهقانی ا.، عسگری ا، م. و. مساعدی ا ، 1388 . مقایسه سه روش شبکه عصبی مصنوعی، سیستم استنتاجی فازی - عصبی تطبیقی و زمین‌آمار در میان یابی سطح آب زیرزمینی (مطالعه موردی دشت قزوین). مجله علوم کشاورزی و منابع طبیعی 16-536-517
3. سرمدیان ف، تقی زاده ر،، عسگری ح.م، و اکبر زاده ع ، 1388 . مقایسه روش‌های نروفازی، شبکه عصبی و رگرسیون چند متغیره در پیش‌بینی. برخی خصوصیات خاک مطالعه موردی استان گلستان. مجله تحقیقات آب و خاک ایران 41:220-211
4. صیادی ح، اولاد غفاری ا.ف، فعالیان ا، و صدرالدینی ع.ا، 1388 . مقایسه عملکردهای شبکه‌های عصبی در برآورد تبخیر و تعرق MLP و RBF گیاه مرجع. مجله دانش آب و خاک 19:12-1
5. کاشی ح، قربانی ه، امامقلی زاده ص ، هاشمی ع.ا، 1392. تخمین ظرفیت تبادل کاتیونی در دو خاک بکر و کشاورزی توسط شبکه عصبی مصنوعی و رگرسیون خطی . نشریه آب و خاک (علوم و صنایع کشاورزی). 27-484-472
6. مهاجر ر.، صالحی م ه، و بیگی هرچگانی ح ، 1388. تخمین ظرفیت تبادل کاتیونی خاک با استفاده از رگرسیون و شبکه عصبی و اثر تفکیک داده‌ها بر دقت و صحت توابع. علوم و فنون کشاورزی و منابع طبیعی علوم اب و خاک، 49:83-97.
7. مهربانیان م، تقی زاده مهرجردی ر ، دهقانی ف، 1388. بررسی کارایی توابع انتقالی جهت تخمین ظرفیت تبادل کاتیونی خاک‌های آهکی و گچی استان یزد. پژوهش‌های حفاظت آب و خاک. 7-1
8. 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.
9. Azamathulla, M., C.K. Chang., A.A. Ghani, J. Ariffin., N.A. Zakaria., and Z. Abu Hasan., 2009. An ANFIS-based approach for predicting the bed load for moderately sized rivers. *Jornal of Hydrog and environmental .Res* 3 35-44.
10. Bell, M.A., H. Van Keulen., 1995. Soil pedotransfer functions for four Mexican soils. *Soil Sci. Soc. Am. J.* 59, 865–871.
11. Breeuwsma, A., J.H.M. Wosten., J.J. Vleeshouwer., Van Slobbe, A.M., and Bouma J., 1986. Derivation of land qualitiesto assess environmental problems from soil surveys. *Soil. Sci. Am. J.*, 50:186-190. by calcareous soils of Syria. *Commun. Soil Sci. Plant Annal.* 24: 197-210.
12. Bremner J.M. and C.S Mulvaney. 1982. Nitrogen total. In: Page, A.L., et al. (Ed.), *Methods of Soil Analysis. Part 2. Chemical and Microbiological Properties*. ASA, Madison, WI, pp, 595 624.
13. Bouyoucos, G.J. 1962. Hydrometer method improved for making particle size analysis of soils. *Agron*, 56: 464-465
14. Chapman.H.D.1965.Cation exchange capabilty.P. 891-901 .In C.A.Black , et al.(eds.) *Methods of soil analysis*.
15. Damangir H,2001 " Dynamic Training of ANN for Its Application in Real-Time Flood Forecasting" , M.S. Thesis, Shiraz University, Shiraz, Iran.

16. Ghorbani H, H. Kashi, N. Hafezi Moghadas, S. Emamgholizadeh, 2015, Estimation of Soil Cation Exchange Capacity using Multiple Regression, Artificial Neural Networks, and Adaptive Neuro-fuzzy Inference System Models in Golestan Province, Iran. *Communications in Soil Science and Plant Analysis*, pages 763-780.
17. Hartman E, J.D. Keeler and J. M Kowalski, 1990. "Layered neural networks with Gaussian hidden units as universal approximations". *Neural Computation*, 1.
18. Hayati M, A. M Rashdi and A. Rezaee, 2011. Prediction of grain size of nanocrystalline nickel coatings using adaptive neuro-fuzzy inference system *Solid State Sciences*, 13, 163-167.
19. Hecht-Nielsen, R, 1990. *Neurocomputing*. Addison-Wesley, Reading, Mass.
20. Hezarjaribi A, F. Nosrati Karizak, k. Abdollahnezhad and Ghorbani Kh, 2013. The Prediction Possibility of Soil Cation Exchange Capacity by Using of Easily Accessible Soil Parameters. *Journal of Water and Soil*. Vol. 27, No.4.
21. Jang J, C. Sun and E. Mizutani, 1997. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, Upper Saddle River, New Jersey, USA.
22. Jang J. S. R, 1993. ANFIS: Adaptive network-based fuzzy inference systems. *IEEE Transactions On Systems, Man, and Cybernetics* 23: 665-685.
23. Kaur R., S. Kumar, and H P. Gurung, 2002. A pedo-transfer function for estimating soil bulk density from basic soil data and its comparison with existing PTFs. *Australian Journal of Soil Research* 40: 847-57.
24. Keshavarzi A, F. Sarmadian, E. S. E. Omran and Iqbal M, 2015 A neural network model for estimating soil phosphorus using terrain analysis. *Egyptian Journal of Remote Sensing and Space Sciences*, 25:1423-1429.
25. Khoshnevisan B, S.H Rafiee, M. Omid, H. Mousazadeh. 2014. Development of an intelligent system based on ANFIS for predicting wheat grain yield on the basis of energy inputs. *Information Processing in Agriculture*. 10:1016.
26. Koekkoek E.J.W and H. Bootink, 1999. Neural networks models to predict soil water retention. *Eur. J. Soil Sci.* 50, 489-495.
27. Krogh L, H.B Madsen, and M.H Greve, 2000. Cation exchange capacity pedotransfer functions for Danish soils. *Acta Agric. Scand Sect. B, Soil and Plant Sci.*, 50:1-12.
28. Manrique L.A, C.A Jones and P.T Dyke, 1991. Predicting cation exchange capacity from soil physical and chemical properties. *Soil Sci. Soc. Am. J.* 50, 787-794.
29. McBratney A.B, B. Minasny, S.R Cattle, and R.W Vervoort, 2002. From pedotransfer functions to soil inference systems. *Geoderma*, 109:41-73.
30. Menhaj M, 2009. *Fundamental of Artificial neural networks*, Amirkabir Press, 245p.
31. Memarian fard M and H. Beigi harchagani, 2009. Comparison of artificial neural network and regression pedotransfer functions models for prediction of soil cation exchange capacity in Chaharmahal Bakhtiari province. *Journal of Water and Soil*, Vol. 23, No. 4, Winter 2009, p. 90-99.
32. Olsen S.R and J.F Sommers, 1982. Phosphorus. P 403-430, In: A.L. Page (ed.), *Methods of soil Analysis*. Agron. No. 9, part 2: Chemical and microbiological properties, 2nd edition, Am. Soc. Agron., Madison, WI, USA.
33. Page, A. L., Miller, R. H., & Keeney, D. R. (1982). *Methods of soil analysis. Part 2. Chemical and microbiological properties*. American Society of Agronomy. In *Soil Science Society of America* (Vol. 1159)
34. Paulo H.F, J.P. Ronei., D.A. João Carlos, 2002. Determination of organic matter in soils using radial basis function networks and near infrared spectroscopy. *Analytica Chimica Acta* 453:125-134.

35. Richards L.A. 1954. Diagnosis and Improvement of Saline and Alkali Soils, L.A. Richards (eds). Handbook of U.S. Dept. of Agriculture, Washington, pp, 4-160.
36. Rezaei M, A. Majdi, M. Monjezi, 2012. An intelligent approach to predict unconfined compressive strength of rock surrounding access tunnels in longwall coal mining. *Neural Comput Appl* 24(1):233–241.
37. Sarmadian, F, R. Taghizadeh Mehrjardi, 2009. Modeling of some soil properties using artificial neural network and multivariate regression in Gorgan Province, North of Iran. *Global Journal of Environmental Research*, 2 (1): 30–35.
38. Schaap, M.G and W. Bouten, 1996. Modeling water retention curves of sandy soils using neural networks. *Water Resour. Res.* 32: 3033-3040.
39. Schap, M. G, F. J. Leij and M. T. Van Genuchten, 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Journal of Soil Science Society of America*, 62, 847–855.
40. Tay ,J.H and X. Zhang., 2000. A fast predicting neural fuzzy model for high-rate anaerobic wastewater treatment systems. *Water Res.* 34 (11), 2849–2860.
41. Tomasella, J, M. G. Hodnett and L. Rossato, 2000. Pedotransfer functions for the estimation of soil water retention in Brazilian soils. *Journal of Soil Science Society of America*, 49, 1100-1105.
42. Walkly, A., and Black, I.A. 1934. An examination of the degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Science* 37: 29-38.
43. Wosten ,J.H.M, Y.A .Pachepsky and W.J. Rawls, 2001. Pedotransferfunctions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *Journal of Hydrolgy*. 251, 123–150.
44. Yang, F. g, S. y. Cao, X. n. Liu and K.j. Yang, (2011). Design of groundwater level monitoring network with ordinary kriging. *Journal of Hydrodynamic Ser. B*, 20(3): 339-346.
45. Yilmaz, I and O. Kaynar. 2011. Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. *Expert Systems with Applications*, 38: 5958–5966.

Prediction of Cation Exchange Capacity in the Soils of Gilan Province Using Intelligent Models

A. Bazoobandi, H. Ghorbani¹, S. Emamgholizadeh, and M. R.Sh. Novbarian

Former MSc Student of Soil Sciences, Shahrood University of Technology Shahrood, Iran;
E-mail: Ahmad.bazoo@yahoo.com

Associate Professor in Soil and Environmental Pollution Water and Soil Department Faculty of Agriculture Shahrood University of Technology Shahrood, Iran; E-mail: ghorbani1969@yahoo.com

Associate Professor in Water and Soil Department Faculty of Agriculture Shahrood University of Technology Shahrood, Iran; E-mail: s_gholizadeh517@yahoo.com

Former MSc student of Soil Sciences, Tarbiat Modares University, Tehran, Iran;
E-mail: shoaibimohammadreza@gmail.com

Received: May, 2016 and Accepted: May, 2017

Abstract

Cation exchange capacity (CEC) is one of the most important characteristics of soils in relation to nutrient elements and water storage in the soil, as well as soil pollution management. CEC measurement is difficult and time-consuming. So, estimating it by use of soil readily available properties is good. In this study, intelligent model was employed and the parameters used were the physical and chemical properties of the soil such as particle size distribution, organic carbon, clay and sands content, phosphorus, nitrogen, PH and EC. The methods of artificial neural network (MLP), (RBF) and Adaptive-network-based fuzzy inference system (ANFIS) were used to assess CEC. Then, the ability of this method to predict CEC was investigated by using 250 soil samples in two groups: 80 percent for training and 20 percent for validation. To determine the accuracy of the model prediction of CEC, statistical indices including Mean Absolute Error (MAE), the coefficient of determination (R^2), and Root Mean Square error (RMSE) were evaluated. The results showed higher efficiency of artificial neural network MLP compared to the other models with the values of MAE, RMSE, R^2 equal to 1.79, 2.54, and 0.8, respectively¹. The sensitivity analysis performed on the input data to the model showed that organic carbon and the pH had the highest and lowest correlation with the cation exchange capacity. The results show that use of artificial neural network to estimate the soil cation exchange capacity is possible and can be used to facilitate the measurement, lower economic cost, and save time.

Keywords: Adaptive-network-based fuzzy inference system, ANFIS, Artificial Neural Network, MLP, Readily available properties, RBF, Neuro-fuzzy model

¹ Corresponding author: Water and Soil Department, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran