



انجمن علمی مهندسی منابع طبیعی گچساران

مجله پژوهش‌های حفاظت آب و خاک
جلد هفدهم، شماره اول، ۱۳۸۹
www.gau.ac.ir/journals

بررسی کارایی توابع انتقالی جهت تخمین ظرفیت تبادل کاتیونی خاک‌های آهکی و گچی استان یزد

*مجتبی مهربانیان^۱، روح‌الله تقی‌زاده مهرجردی^۲ و فرهاد دهقانی^۳

^۱دانش‌آموخته کارشناسی ارشد گروه خاکشناسی، دانشگاه تهران، ^۲دانشجوی دکتری گروه خاکشناسی، دانشگاه تهران،

^۳مربی مرکز تحقیقات کشاورزی یزد

تاریخ دریافت: ۸۷/۹/۹؛ تاریخ پذیرش: ۸۸/۱۱/۱۸

چکیده

اگرچه ظرفیت تبادل کاتیونی را می‌توان به روش مستقیم اندازه‌گیری نمود ولی این اندازه‌گیری، به‌ویژه در ارایدی‌سول‌های ایران به دلیل مقادیر بالای کلسیم و گچ موجود در خاک، سخت و پرهزینه است. یکی از روش‌های جایگزین اندازه‌گیری مستقیم ظرفیت تبادل کاتیونی استفاده از توابع انتقالی می‌باشد. تخمین پارامترهای دیریافت خاک با استفاده از اطلاعات موجود خاک، که به وسیله معادله‌های رگرسیونی صورت می‌گیرد، توابع انتقالی خاک نامیده می‌شود. جهت توسعه توابع انتقالی می‌توان از رگرسیون چندمتغیره و شبکه عصبی مصنوعی استفاده کرد. در این پژوهش به منظور تخمین ظرفیت تبادل کاتیونی اقدام به نمونه‌برداری به تعداد ۶۰ نمونه سطحی (۳۰-۰ سانتی‌متر) به صورت شبکه منظم و با فاصله ۲۵۰ متر از خاک‌های آهکی و گچی دشت یزد- اردکان گردید. پارامترهای ورودی جهت تخمین ظرفیت تبادل کاتیونی در هر دو مدل یادشده، اجزاء بافت خاک و کربن آلی بودند. سپس نتایج پیش‌بینی ظرفیت تبادل کاتیونی مدل‌های رگرسیون چندمتغیره و شبکه عصبی مصنوعی با سه تابع انتقالی تجربی نیز مورد ارزیابی قرار گرفته شد. نتایج این پژوهش نشان داد که شبکه عصبی مصنوعی با $RMSE = 1/04$ و ضریب تبیین $0/97$ دارای کارایی بالاتری نسبت به رگرسیون پایه دارد، که احتمالاً به علت وجود روابط غیرخطی میان متغیرهای وابسته و پیش‌بینی شونده می‌باشد.

واژه‌های کلیدی: توابع انتقالی، ظرفیت تبادل کاتیونی، خاک‌های آهکی و گچی

*مسئول مکاتبه: m_mehrabanian@yahoo.com

مقدمه

امروزه استفاده از داده‌های خاک قابل اطمینان در مقیاس وسیع جهت طراحی سیستم‌های کاربری اراضی، تفکیک آلودگی‌های حاکی و پیش‌بینی تخریب اراضی رو به گسترش است (مک‌برانتی و همکاران، ۲۰۰۲). ظرفیت تبادل کاتیونی^۱ خاک از جمله خصوصیات مهم خاک می‌باشد که در پایگاه‌های اطلاعاتی - داده‌ای مربوط به خاک (مانزیکو و همکاران، ۱۹۹۱) و به‌عنوان ورودی در مدل‌های زیست‌محیطی و نیز مدل‌های مربوط به خاک به کار می‌رود (کلر و همکاران، ۲۰۰۱). اگرچه CEC را می‌توان به روش مستقیم اندازه‌گیری نمود ولی این اندازه‌گیری، به‌ویژه در اریدی‌سول‌ها^۲ به دلیل مقادیر بالای کلسیم و گچ موجود در خاک، سخت و پرهزینه است (کارپنا و همکاران، ۱۹۷۲؛ فرناندو و همکاران، ۱۹۷۷).

توابع انتقالی^۳ خاک با تخمین CEC از داده‌های زودیافت خاک یکی از روش‌های جایگزین اندازه‌گیری مستقیم CEC است. فرض اساسی در بیشتر مدل‌های تخمینی CEC بیانگر وجود رابطه خطی بین پارامتر مورد نظر و مواد آلی و میزان رس خاک می‌باشد (بروسما و همکاران، ۱۹۸۶ و مک‌برانتی و همکاران، ۲۰۰۲). کریمیان (۱۹۹۶) با استفاده از ۱۵۰ نمونه خاک استان فارس، معادلات رگرسیونی چندمتغیره ایجاد و سهم رس و مواد آلی در ظرفیت تبادل کاتیونی خاک را محاسبه نمود. این پژوهش همچنین ظرفیت تبادل کاتیونی تعدادی از خاک‌ها را پس از اکسایش مواد آلی با آب اکسیژنه اندازه‌گیری کرد و سهم مواد آلی و رس را به‌طور مستقیم تعیین نمود. کرو و همکاران (۲۰۰۰) با استفاده از بانک اطلاعاتی خاک‌های دانمارک و استفاده از متغیرهای مقدار ماده آلی، رس، سیلت ریز و pH خاک در عصاره کلرید کلسیم، توابعی برای برآورد ظرفیت تبادل کاتیونی ارائه دادند.

یکی از روش‌های جدید در توسعه توابع انتقالی، روش شبکه عصبی مصنوعی^۴ است. ساختار کلی شبکه عصبی مصنوعی از شبکه عصبی انسان الهام گرفته شده است و تقریباً قادر به انجام عملیات‌هایی همانند سیستم‌های عصبی زیستی و در اندازه و ابعاد بسیار ابتدایی می‌باشد. مدل پایه شبکه عصبی مصنوعی برای اولین بار توسط کلاچ و پتیس (۱۹۴۳) ارائه گردیده است (به نقل از دو بوس و کلیماساسکاس، ۱۹۸۹). در این روش سعی می‌شود براساس روابط ذاتی میان داده‌ها، نگاشتی خطی یا غیرخطی بین متغیرهای مستقل و وابسته برقرار گردد. شبکه‌های عصبی مصنوعی می‌توانند مانند

- 1- Cation Exchange Capacity; CEC
- 2- Aridisols
- 3- Pedotransfer Functions (PTFs)
- 4- Artificial Neural Networks

شبکه‌های زیستی، یادگیری داشته باشند. شبکه‌های عصبی مصنوعی، در بین تکنیک‌های رایج هوش مصنوعی، در واقع سیستم‌های محاسبه‌ای مبتنی بر الگوریتم‌ها هستند که از تعدادی اصول ساختاری موجود در سیستم‌های عصبی بیولوژیک استفاده می‌کنند (دو بوس و کلیماساسکاس، ۱۹۸۹). برتری شبکه‌های عصبی نسبت به سیستم‌های هوشمند دیگر قدرت یادگیری آنها از محیط پیرامونشان و توانایی تعمیم این یادگیری می‌باشد. مهم‌ترین بخش یک شبکه زیستی نرون^۱ است. نرون‌ها سلول‌های تشکیل‌دهنده دستگاه عصبی انسان هستند. هر نرون با استفاده از تعدادی گیرنده^۲ تحریکات عصبی را دریافت می‌کند و پس از پردازش این تحریکات، آنها را از طریق یک فرستنده^۳ به نرون بعدی ارسال می‌کند. یک شبکه عصبی مصنوعی از لایه‌هایی به اسم لایه ورودی^۴، مخفی^۵ و خروجی^۶ تشکیل شده و در هر لایه یک یا چند عنصر پردازشگر (نرون) وجود دارد که با تمامی نرون‌های لایه بعدی مرتبط می‌باشند. تعداد نرون‌های لایه ورودی برابر تعداد متغیرهای مستقل سیستم موردنظر است که در این پژوهش متغیرهای وابسته همان CEC می‌باشد. به هریک از نرون‌های لایه ورودی وزنی داده می‌شود که مقدار آن تعیین‌کننده تأثیر هر متغیر بر میزان عملکرد لایه ورودی است. هر عنصر پردازشگر یا نرون از دو قسمت تشکیل شده، در قسمت اول آن مجموع وزنی مقادیر ورودی به آن محاسبه می‌شود و در قسمت دوم نرون، خروجی قسمت اول در یک تابع ریاضی قرار گرفته و از طریق آن خروجی نرون محاسبه می‌شود. به این توابع ریاضی، در اصطلاح تابع تحریک، تابع آستانه^۷ یا تابع انتقال^۸ گفته می‌شود، که عملکرد آن شبیه یک فیلتر غیرخطی است و سبب می‌شود خروجی نرون در یک محدوده عددی خاص قرار گیرد. تابع زیگموئیدی^۹ رایج‌ترین تابع آستانه مورد استفاده در نرون‌ها می‌باشد. این تابع جزو توابع پیوسته‌ای است که خروجی آن در یک محدوده عددی خاص (عموماً ۰ تا ۱ یا -۱ تا ۱) در نوسان خواهد بود (کیمار و همکاران، ۲۰۰۲). در لایه‌های مخفی و خروجی می‌توان از نرون‌های غیرخطی با تابع تحریک سیگموئید یا تانژانت هایپربولیک^{۱۰} و یا هر تابع غیرخطی پیوسته و مشتق‌پذیر دیگری استفاده کرد.

-
- 1- Neuron
 - 2- Dendrite
 - 3- Axon
 - 4- Input Layer
 - 5- Hidden Layer
 - 6- Output Layer
 - 7- Activation Function
 - 8- Transfer Function
 - 9- Sigmoid Function
 - 10- Hyperbolic Tangent


بررسی‌های زیادی به‌منظور توسعه شبکه عصبی مصنوعی صورت گرفت به‌طوری‌که امروزه شبکه عصبی با ساختارهای متفاوت به‌طور وسیعی در حوزه‌های مختلف علوم گسترش یافته است. شبکه‌های عصبی مصنوعی قادرند با موفقیت خصوصیات هیدرولیکی خاک را پیش‌بینی نمایند (پاچپسکی و رائلز، ۱۹۹۹؛ میناسنی و مک‌برانتسی، ۲۰۰۲). پاچپسکی و رائلز (۱۹۹۹) شبکه‌های عصبی مصنوعی را جهت تخمین منحنی رطوبتی خاک با استفاده از خصوصیات زود یافت خاک به‌کار بردند. آنها نشان دادند که شبکه‌های عصبی میزان آب را در پتانسیل‌های ماتریک انتخاب شده بهتر از رگرسیون تخمین می‌زند. اسچاپ و همکاران (۱۹۹۸) با استفاده از شبکه عصبی مصنوعی توابعی برای تخمین پارامترهای معادلات وان‌گنختن، وان‌گنختن - معلم و گاردنر ایجاد کردند، نتایج این محققان نشان داد که هرچه تعداد داده‌های ورودی مورد استفاده در این توابع بیشتر باشد، درستی توابع افزایش خواهد یافت. تاماری و همکاران (۱۹۹۶) با استفاده از شبکه عصبی اقدام به تخمین منحنی رطوبتی خاک کرده و کارایی بالاتر شبکه عصبی را نسبت به رگرسیون خطی تأیید کردند. امینی و همکاران (۲۰۰۵) با استفاده از مقدار ماده آلی و رس اقدام به برآورد میزان CEC خاک در منطقه اصفهان، به‌وسیله شبکه عصبی مصنوعی و ۵ مدل تجربی که بر پایه روش‌های رگرسیونی می‌باشند، نمودند. نتایج این محققان نشان داد که روش شبکه عصبی از برتری قابل‌قبولی نسبت به سایر روش‌ها برخوردار می‌باشد.

با توجه به مشکلات اندازه‌گیری مستقیم ظرفیت تبادل کاتیونی، هدف از این پژوهش مقایسه کارایی شبکه‌های عصبی مصنوعی و رگرسیون چندمتغیره در برآورد ظرفیت تبادل کاتیونی خاک با استفاده از متغیرهای زودیافت خاک می‌باشد.

مواد و روش‌ها

نمونه‌برداری و تجزیه‌های فیزیکی و شیمیایی خاک: منطقه مورد مطالعه در دشت یزد - اردکان واقع در استان یزد قرار گرفته است. منطقه مورد مطالعه با رژیم رطوبتی اریدیک و رژیم حرارتی ترمیک، دارای خاک‌های سرشار از آهک و گچ می‌باشد (جدول ۱). از این منطقه به تعداد ۶۰ نمونه سطحی از عمق ۰-۳۰ سانتی‌متری با فاصله ۲۵۰ متر جمع‌آوری گردید (شکل ۱). برای اندازه‌گیری درصد ذرات خاک از روش هیدرومتری (جی و بودر، ۱۹۸۶) هدایت الکتریکی عصاره‌های اشباع نمونه‌ها از

هدایت سنج فیلیپس^۱ استفاده و، همچنین کربن آلی خاک به روش والکلی و بلاک (بلاک، ۱۹۸۲)، کربنات کلسیم نمونه‌ها به روش حجم‌سنجی (گازومتری)، یون‌های محلول در عصاره اشباع خاک‌ها به کمک روش‌های معمول آزمایشگاهی (اسپارکس و همکاران، ۱۹۹۶) و ظرفیت تبادل کاتیونی نمونه‌های خاک به روش باور (باور و همکاران، ۱۹۵۲) اندازه‌گیری شدند.



شکل ۱- موقعیت منطقه مورد مطالعه و پراکنش نقاط اندازه‌گیری شده.

رگرسیون خطی چندگانه: تخمین پارامترهای دیریافت خاک با استفاده از اطلاعات موجود خاک، که به وسیله معادلات رگرسیونی صورت می‌گیرد، توابع انتقالی خاک نامیده می‌شود. در این مطالعه از سه تابع انتقالی استفاده شد که روابط آنها در جدول (۲) آورده شده است. ابتدا با استفاده از رگرسیون خطی چندگانه و روش گام به گام پیش‌رونده، مهم‌ترین ورودی‌های مدل تعیین گردید و سپس مدل رابطه شماره (۱) بر آنها برازش داده شد (پاچپسکی و رائلز، ۱۹۹۹؛ مردون و همکاران، ۲۰۰۶). در رگرسیون چندگانه خطی اگر بین متغیرهای مستقل وابستگی خطی قوی مشاهده شود، هم‌راستایی چندگانه به وجود

1- Philips مدل PW-9527


مجله پژوهش‌های حفاظت آب و خاک جلد (۱۷)، شماره (۱) ۱۳۸۹

می‌آید (قربانی‌دشتکی و همایی، ۲۰۰۲). از آنجایی که فراوانی نسبی ذرات رس، شن و سیلت هم‌راستا بودند، برای جلوگیری از هم‌راستایی^۱ در توابع به‌دست آمده، در ایجاد تابع انتقالی از مقدار نسبت رس به سیلت استفاده شده است (پاچپسکی و همکاران، ۱۹۹۶؛ مردون و همکاران، ۲۰۰۶).

$$Y = b_0 + b_1 X_1 + \dots + b_n X_n \quad (1)$$

که در آن؛ Y : ظرفیت تبادل کاتیونی، b_0 : عرض از مبدأ، b_1, \dots, b_n : ضرایب رگرسیون و X_1, \dots, X_n : متغیرهای مستقل (ورودی‌های مدل) هستند.

شبکه عصبی مصنوعی: یکی از متداول‌ترین شبکه‌های عصبی مورد استفاده، شبکه عصبی پرسپترون^۲ چندلایه می‌باشد. این شبکه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه بین آنها که به‌طور مستقیم به داده‌های ورودی و نتایج خروجی متصل نیستند، تشکیل یافته‌اند. شکل (۲) لایه‌های مختلف یک شبکه عصبی را نشان می‌دهد.



شکل ۲- نمایی از ساختار شبکه عصبی (فتحی و کوچک‌زاده، ۲۰۰۴).

واحدهای لایه ورودی وظیفه توزیع مقادیر ورودی‌ها به لایه بعد و لایه خروجی نیز پاسخ سیگنال‌های خروجی را ارائه می‌دهد. در این دو لایه تعداد نرون‌ها برابر با تعداد ورودی‌ها و خروجی‌ها می‌باشد و لایه یا لایه‌های پنهان وظیفه ارتباط لایه‌های ورودی به لایه‌های خروجی را بر عهده دارند. روشی که جهت بهینه کردن وزن‌ها و بایاس‌ها برای دستیابی به مقدار معلوم، اتخاذ می‌شود، قانون یادگیری نام دارد. قانون یادگیری در واقع یک الگوریتم ریاضی پیچیده می‌باشد. هر شبکه برای به‌وجود آمدن به دو سری داده آموزش و آزمون نیازمند است. که در این مطالعه، داده‌ها با

1- Multicollinearity

2- Perceptron

استفاده از نرم‌افزار Excel ۲۰۰۳ تصادفی شده و ۸۰ درصد به‌عنوان داده‌های آموزشی (۴۸ داده) و ۲۰ درصد به‌عنوان داده‌های آزمونی (۱۲ داده) مورد استفاده قرار گرفتند.

در طی فرآیند یادگیری، میزان فراگیری توسط شبکه به‌وسیله توابع هدف به‌طور مرتب سنجیده می‌شود و در نهایت شبکه‌ای با کم‌ترین میزان خطا مورد پذیرش قرار می‌گیرد (میناسنی و مک‌براتنی، ۲۰۰۲).
ارزیابی مدل: به‌منظور مقایسه عملکرد مدل‌ها از پارامترهای مجذور میانگین مربعات خطا (RMSE) و خطای استاندارد نسبی (RSE) که به‌ترتیب از رابطه‌های (۲) و (۳) قابل محاسبه می‌باشند، استفاده گردید (آکایک، ۱۹۷۳). در ارزیابی مدل هرچه پارامترهای مورد اشاره به صفر نزدیک‌تر باشند، مدل از کارایی بالاتری برخوردار می‌باشد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (2)$$

$$RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2}}{O_{ave}} \quad (3)$$

در این رابطه‌ها، P_i : مقادیر شبیه‌سازی شده، O_i : مقادیر مشاهداتی، O_{ave} : متوسط مقادیر مشاهداتی و n : تعداد داده‌ها می‌باشند.

علاوه‌بر معیارهای آماری یادشده، برای بررسی کارایی مدل‌های مختلف از پارامتر آکایک نیز استفاده گردید (رابطه ۴). با استفاده از این پارامتر ما می‌توانیم مدل مناسب‌تر را انتخاب کنیم. در واقع مدلی مناسب‌تر است که در شرایط یکسان با تعداد پارامترهای کمتر، عملکرد بهتری داشته باشد (آکایک، ۱۹۷۳).

$$AIC = n \ln \left(\frac{ESS}{n} \right) + 2p \quad (4)$$

که در این رابطه، n : تعداد مشاهدات، ESS : مجموع مربعات خطا، p : تعداد پارامترهای مورد نیاز مدل.

1- Root Mean Square Error

2- Relative Standard Error

نتایج


در این پژوهش در ابتدا داده‌های آموزش و آزمون با استفاده از نرم‌افزار Excel ۲۰۰۳ تصادفی شده و به دو سری داده، برای استفاده در شبکه عصبی مصنوعی تقسیم گردیدند، که برای این منظور این داده‌ها طوری تعیین شدند که از نظر برخی معیارهای آماری مانند میانگین و انحراف معیار تا حد ممکن شبیه یکدیگر باشند. جدول (۱) معیارهای آماری مربوط به داده‌های تست و آموزش آورده شده‌اند.

جدول ۱- پارامترهای آماری داده‌های استفاده شده در شبکه عصبی و رگرسیون چندمتغیره برای برآورد ظرفیت تبادل کاتیونی.

| پارامتر آماری | CEC (Cmolc/kg) | رس (درصد) | سیلت (درصد) | شن (درصد) | کربن آلی (درصد) | گچ (درصد) | آهک (درصد) | |
|---------------|----------------|-----------|-------------|-----------|-----------------|-----------|------------|----------------|
| کم‌ترین | ۱/۲ | ۶۲ | ۴ | ۲۱/۳ | ۰/۰۵ | ۱/۰۹ | ۱۸/۰۲ | داده‌های آموزش |
| بیش‌ترین | ۲۰ | ۴۷ | ۴۸/۴ | ۸۹/۳ | ۱/۴۳ | ۵/۶۵ | ۲۶/۲۳ | |
| میانگین | ۹/۷۵ | ۲۳/۴۸ | ۲۷/۰۵ | ۴۸/۹۳ | ۰/۳۳ | ۳/۴۶ | ۲۲/۲۶ | |
| انحراف معیار | ۴/۷ | ۹/۹۲ | ۱۰/۴۵ | ۱۷/۶ | ۰/۲۶ | ۱/۲۵ | ۹/۳۵ | |
| کم‌ترین | ۳/۶ | ۱۱/۲ | ۳/۲ | ۲۱/۳ | ۰/۰۶ | ۱/۵۷ | ۱۹/۰۷ | داده‌های تست |
| بیش‌ترین | ۲۱ | ۲/۳۶ | ۵۷/۷ | ۸۵/۶ | ۰/۸۴ | ۴/۶۵ | ۲۶/۰۴ | |
| میانگین | ۹/۴۲ | ۲۰/۱۱ | ۲۲/۱۴ | ۵۶/۴۵ | ۰/۳۲ | ۲/۵۷ | ۲۲/۰۹ | |
| انحراف معیار | ۵/۱۶ | ۹/۳ | ۱۲/۴ | ۲۳/۳۸ | ۰/۳ | ۱/۶۷ | ۹/۱۲ | |

پس از تعیین مجموعه داده‌های تست و آموزش، داده‌های ورودی به شبکه را معیارسازی^۱ کرده و در مرحله بعد مدل مختلف شبکه عصبی با یک لایه مخفی (که تعداد نرون‌های آن بین ۲ تا ۱۰ نرون می‌باشد) ساخته و ساختار بهینه شبکه به روش سعی و خطا با استفاده از معیارهای ضریب همبستگی، RMSE، AIC و RSE تعیین گردید. برای پیش‌بینی ظرفیت تبادل کاتیونی ورودی‌های شبکه شامل درصد‌های رس، سیلت، شن و کربن آلی می‌باشد. در این قسمت مقادیر RMSE برای تعداد نرون‌های مختلف در شکل (۳) آورده شده است.

1- Normalization



شکل ۳- مقادیر RMSE برای تعداد نرون متفاوت در پیش‌بینی پارامتر ظرفیت تبادل کاتیونی.

با توجه به شکل (۳) ملاحظه می‌شود حداقل مقدار RMSE مربوط به شبکه با سه نرون در لایه مخفی می‌باشد. همچنین با توجه به این شکل مشاهده می‌شود که با افزایش تعداد نرون‌ها عملکرد مدل‌ها ضعیف‌تر شده و بهترین عملکرد مربوط به شبکه با تعداد نرون‌های پایین می‌باشد. مقادیر ضریب همبستگی، AIC، RMSE و RSE برای شبکه با سه نرون در لایه مخفی به ترتیب ۰/۹۷، ۱۹/۷۵، ۱/۰۴ و ۰/۰۹ به دست آمده است که از لحاظ هر ۴ معیار یادشده برتر از مدل‌های دیگر می‌باشد.

برای تعیین رگرسیون چندمتغیره پارامتر مورد مطالعه با استفاده از نرم‌افزار MINITAB رابطه رگرسیونی مربوطه را با استفاده از داده‌های آموزش تعیین کرده که به صورت رابطه (۵) می‌باشد. ابتدا با استفاده از رگرسیون خطی چندگانه و روش گام به گام پیش‌رونده، مهم‌ترین ورودی‌های مدل تعیین گردید و سپس مدل بر آنها برازش داده شد. در رگرسیون چندگانه خطی اگر بین متغیرهای مستقل وابستگی خطی قوی مشاهده شود، هم‌راستایی چندگانه به وجود می‌آید. از آنجایی که فراوانی نسبی ذرات رس، شن و سیلت هم‌راستا بودند، برای جلوگیری از هم‌راستایی در توابع به دست آمده، در ایجاد تابع انتقالی از مقدار نسبت رس به سیلت استفاده شده است.

$$(۵) \quad \text{شن} = ۰/۴۶ - (\text{ماده آلی}) + ۸/۶۱ (\text{سیلت/رس}) + ۰/۹۱ = ۴۲/۹ = \text{ظرفیت تبادل کاتیونی}$$

مقادیر همبستگی، AIC، RMSE و RSE برای رگرسیون چندمتغیره جهت پیش‌بینی ظرفیت تبادل کاتیونی به ترتیب ۰/۶۸، ۳۹/۲۵، ۲/۹۱ و ۰/۳۲ به دست آمده است.

مجله پژوهش‌های حفاظت آب و خاک جلد (۱۷)، شماره (۱) ۱۳۸۹

در مرحله بعد برای هر یک از مدل‌های توابع انتقالی تجربی ضرایب بهینه مربوط به هر یک از مدل‌ها را تعیین کرده که ضرایب مربوط به روابط تجربی بروسما و همکاران، مانریکو و بل و ونکولن در جدول (۲) آورده شده است.

جدول ۲- پارامترهای مدل‌های استفاده شده و ضرایب کالیبراسیون.

| ضرایب کالیبراسیون | تابع انتقالی | مدل |
|---------------------------------------|----------------------------------|--------------------------|
| $a_1=0/301$ $a_2=1/09$ | $CEC=a_1$ (ماده آلی) + (رس) | بروسما و همکاران (۱۹۸۶) |
| $a_1=6/49$ $a_2=0/1$ $a_3=0/51$ | $CEC= a_1+a_2$ (کربن آلی) + (رس) | مانریکو و همکاران (۱۹۹۱) |
| $a_1=6/49$ $a_2=0/1$ $a_3=0/34$ | $CEC= a_1+a_2$ (ماده آلی) + (رس) | بل و ونکولن (۱۹۹۵) |

سپس اقدام به برآورد مقادیر ظرفیت تبادل کاتیونی با استفاده از هر یک از توابع انتقالی گردید. که نتایج مربوط به هر یک از مدل‌ها به همراه شبکه عصبی در جدول (۳) آورده شده است. با توجه به این جدول ملاحظه می‌شود در کل بهترین عملکرد مربوط به شبکه عصبی می‌باشد که مقادیر ضریب همبستگی، AIC ، $RMSE$ و RSE آن به ترتیب ۰/۹۷، ۱۹/۷۵، ۱/۰۴ و ۰/۰۹ است که از نظر هر ۴ معیار بهتر از سایر مدل‌ها می‌باشد. بعد از شبکه عصبی که بهترین عملکرد مربوط به رگرسیون چندمتغیره و بعد از آن سایر مدل‌ها رفتار متفاوتی از خود نشان داده‌اند؛ به‌طوری که نتایج مدل‌های بل و ونکولن (۱۹۹۵) و مانریکو و همکاران (۱۹۹۱) مشابه یکدیگر شده و مدل بروسما و همکاران (۱۹۸۶) نسبت به این دو مدل کارایی کمتری را نشان می‌دهد.

مجتبی مهربانیان و همکاران


جدول ۳- عملکرد مدل‌های مختلف در برآورد پارامتر ظرفیت تبادل کاتیونی.

| مدل | RSE | R ² | AIC | RMSE |
|--------------------------|------|----------------|-------|------|
| بروسما و همکاران (۱۹۸۶) | ۰/۷۲ | ۰/۵۱ | ۶۲/۷۸ | ۸/۰۲ |
| مانزیکو و همکاران (۱۹۹۱) | ۰/۶۲ | ۰/۵۳ | ۵۵/۵۶ | ۶/۵۷ |
| بل و ونکولن (۱۹۹۵) | ۰/۶۲ | ۰/۵۳ | ۵۵/۵۶ | ۶/۵۷ |
| رگرسیون | ۰/۳۲ | ۰/۶۸ * | ۳۹/۲۵ | ۲/۹۱ |
| شبکه عصبی | ۰/۰۹ | ۰/۹۷ ** | ۱۹/۷۵ | ۱/۰۴ |

* معنی‌دار در سطح ۵ درصد.

** معنی‌دار در سطح ۱ درصد.

در شکل (۴) دیاگرام پراکنش در داده‌های تست برای مدل شبکه عصبی که بهترین عملکرد را به خود اختصاص داده، آورده شده است. با توجه به این شکل ملاحظه می‌شود بهترین خط برازش داده شده دارای زاویه‌ای نزدیک به ۴۵ درجه می‌باشد، که نشان از دقت بالای برآورد توسط مدل شبکه عصبی در تخمین پارامتر مورد بررسی دارد.



شکل ۴- دیاگرام پراکنش برای مقادیر مشاهداتی و شبیه‌سازی شده ظرفیت تبادل کاتیونی با استفاده از روش شبکه عصبی.

بحث

این بررسی نشان داد که شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی پایه کارایی بهتر داشته است. زیرا از یک سو کارایی توابع انتقالی به دست آمده در مناطق مختلف با هم متفاوتند و از سوی دیگر طبق نظر اسچاپ و همکاران (۱۹۹۸) در طراحی شبکه‌های عصبی نوع خاصی از معادلات لازم نیست و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست پیدا کرد. همچنین به علت وجود روابط غیرخطی میان متغیرهای وابسته و پیش‌بینی شونده (ظرفیت تبادل کاتیونی) شبکه عصبی عملکرد بهتری نسبت به مدل‌های رگرسیون پایه داشته است. بعد از شبکه عصبی که بهترین عملکرد را به خود اختصاص داده رگرسیون چندمتغیره دقت بالاتری را داشت. در توابع انتقالی که برای تخمین ظرفیت تبادل کاتیونی به کار رفت، مدل‌های مانریکو و بل عملکرد یکسانی داشته و نسبت به مدل بروسما دارای دقت بیشتری می‌باشند که این مسأله اهمیت نوع توابع و شکل آنها را نشان می‌دهد. نتایج به دست آمده از این پژوهش با آنچه که امینی و همکاران (۲۰۰۵) در برآورد ظرفیت تبادل کاتیونی در منطقه اصفهان به دست آورد، هم‌خوانی دارد. ایشان نیز نشان دادند که شبکه‌های عصبی کارایی بالایی در برآورد ظرفیت تبادل کاتیونی خاک نسبت به سایر توابع انتقالی که به صورت خطی هستند، دارد. پاچسکی و همکاران (۱۹۹۶)، با استفاده از آماره‌های ضریب همبستگی و ریشه میانگین مربعات خطا به بررسی شبکه عصبی مصنوعی و آنالیز رگرسیون پرداختند. آنها نتیجه گرفتند که شبکه عصبی برآورد بهتر و با خطای کمتری، براساس داده‌های زودیافت خاک دارد. نتایج مشابهی توسط تاماری و همکاران (۱۹۹۶) به دست آمده است. آنها نیز مقدار $RMSE$ کم‌تری از برآورد خصوصیات خاک با شبکه عصبی مصنوعی نسبت به رگرسیون خطی چندگانه به دست آوردند. همچنین تاماری و همکاران (۱۹۹۶) نشان دادند که اگر ناپایداری داده‌ها بالا باشد شبکه عصبی از مدل‌های رگرسیونی خطی بهتر نخواهد بود، اما زمانی که داده‌هایی با دقت بالا به کار برده شوند شبکه عصبی کارایی بالاتری را نشان می‌دهد؛ که این مسأله مؤید دقت بالای داده‌های مورد آزمایش و انتخاب صحیح داده‌های تست و آموزش می‌باشد. بنابراین با توجه به مشکلاتی که در اندازه‌گیری ظرفیت تبادل کاتیونی به طور مستقیم به خصوص در مناطق خشک و کویری وجود دارد، پیشنهاد می‌گردد در مطالعات آتی از مدل‌های نروفازی نیز برای به دست آوردن روابطی منطقی در هر منطقه برای پیش‌بینی سایر پارامترهای خاک، به خصوص خصوصیات هیدرولیکی خاک استفاده گردد.

نتیجه گیری کلی

در این پژوهش با استفاده از مدل‌های شبکه عصبی، رگرسیون چندمتغیره و چند تابع انتقالی تجربی مقادیر ظرفیت تبادل کاتیونی برآورد گردید. در این مطالعه شبکه عصبی پرسپترون با یک لایه مخفی که دارای تابع فعال‌سازی سیگموئید در لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی بود، مورد استفاده قرار گرفت. برای پیش‌بینی ظرفیت تبادل کاتیونی عوامل رس، سیلت، شن، و ماده آلی استفاده گردید. با توجه به معیارهای ارزیابی، نتایج بررسی نشان داد که در مورد مطالعه شده شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی پایه کارایی بهتر داشته است.

سپاسگزاری

نویسندگان این مقاله از همکاری‌های گروه مهندسی علوم خاک دانشکده مهندسی علوم خاک و آب پردیس کشاورزی و منابع طبیعی دانشگاه تهران و مرکز تحقیقات کشاورزی یزد جهت تأمین وسایل نقلیه و امکانات آزمایشگاهی در انجام این پژوهش سپاسگزاری می‌نمایند.

منابع

1. Akaike, H. 1973. Information theory and an extension of the maximum likelihood principle. In: Petrox, B., and Csaki, F. (eds.), Symposium on Information Theory, Akademiai Kiado, Budapest, Hungary, 267p.
2. Amini, M., Abbaspour, K.C., Khademi, H., Fathianpour, N., Afyuni, M., and Schulin, R. 2005. Neural network models to predict cation exchange capacity in arid regions of Iran. *Euro. J. Soil Sci.* 53: 748-757.
3. Bell, M.A., and Van Keulen, H. 1995. Soil pedotransfer functions for four Mexican soils. *Soil Sci. Soc. Am. J.* 59: 865-871.
4. Black, C.A. 1982. Method of soil analysis, Chemical and microbiological properties, American Society of Agronomy, INC, 2: 1965.
5. Bower, C.A., Reitmeir, R.F., and Fireman, M. 1952. Exchangeable cation analysis of saline and alkali soils. *Soil Sci.* 73: 251-261.
6. 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. Soc. Am. J.* 50: 186-190.
7. Carpena, O., Lux, A., and Vahtras, K. 1972. Determination of exchangeable Cations in calcareous soils. *Soil Sci.* 33: 194-199.
8. DuBose, P., and Klimasauskas, C. 1989. Introduction to Neural Networks with Examples and Applications. NeuralWare Inc., Pittsburgh, 317p.
9. Fathi, P., and Kouchakzadeh, M. 2004. Estimation of greenhouse cucumber transpiration using artificial neural network. *Iranian J. Soil and Water Sci.* 18: 208-215.

10. Fernando, M.J., Burau, R.G., and Arulanandam, K. 1977. A new approach to determination of cation exchange capacity. *Soil Sci. Soc. Am. J.* 41: 818-820.
11. Gee, G., and Bauder, W. 1986. Particle size distribution analysis. In: Klute, A. (Ed.), *Method of soil analysis. Part 1, second ed.* Agron. Monogr. 9. ASA and SSSA, Madison, WI, Pp: 383-411.
12. Ghorbani Dashtaki, Sh., and Homaei, M. 2002. Prediction of parametric hydraulic function in unsaturated soils using pedotransfer functions. *Agric. Engine. Res. J.* 3: 12. 3-15.
13. Karimian, A. 1996. Influence of clay and organic matter in cation exchange capacity in calcareous soils of Fars province. 5th Soil science congress in Iran.
14. Keller, A., Von Steiger, B., Van der Zee, S.T., and Schulin, R. 2001. A stochastic empirical model for regional heavy metal balances in agroecosystems. *J. Environ. Quality*, 30: 1976-1989.
15. Kimar, M., Raghuwanshi, N.S., Singh, R., Wallender, W., and Pruitt, W. 2002. Estimating evapotranspiration using artificial neural network. *J. Irri. Drain. Engine.* 128: 4. 224-233.
16. Krogh, L., Breuning-Madsen, H., and Greve, M.H. 2000. Cation exchange capacity pedotransfer function for Danish soils. *Soil and Plant*, 50: 1-12.
17. 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.* 50: 787-794.
18. McBratney, A.B., Minasny, B., Cattle, S.R., and Vervoort, R.W. 2002. From pedotransfer functions to soil inference systems. *Geoderma*. 109: 41-73.
19. Merdun, H., Ozer, C., Meral, R., and Apan, M. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Till Res.* 90: 108-116.
20. 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.
21. Pachepsky, Y.A., Timilin, 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. Pachepsky, Y.A., and Rawls, W.J. 1999. Accuracy and reliability of pedotransfer functions as affected by grouping soils. *Soil Sci. Soc. Am. J.* 63: 1748-1757.
23. Schaap, M.G., Leij, F.J., and Van Genuchten, M.Th. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Sci. Soc. Am. J.* 62: 847-855.
24. Sparks, D.L., Page, A.L., Helmke, P.A., Leppert, R.H., Soltanpour, P.N., Tabatabai, M.A., Johnston, G.T., and Summer, M.E. 1996. *Methods of soil analysis*, SSSA., Madison, Wisconsin, 1973p.
25. Tamari, S., Wosten, J.H.M., and Ruz-suarez, J.C. 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Sci. Soc. Am. J.* 60: 1732-1741.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 17(1), 2010
www.gau.ac.ir/journals

Assessing the Efficiency of Pedotransfer Functions for Estimating CEC in some Calcareous and Gypsiferous Soils of Yazd Province

***M. Mehrabian¹, R. Taghizadeh Mehrjardi² and F. Deghani³**

¹Former M.Sc. Student, Dept. of Soil Sciences, University of Tehran, ²Ph.D. Student, Dept. of Soil Sciences, University of Tehran, ³Instructor, Agriculture Research Center of Yazd

Abstract

CEC can be measured directly but its measurement is especially difficult and expensive in the Aridisols of Iran because of the large amounts of carbonates and gypsum in these soils. Pedotransfer functions (PTFs) provide an alternative to direct CEC measurement by estimating CEC from more readily available soil data. Estimation of costly measured properties from widely available or more easily measured basic soil properties by means of regression equations is referred to pedotransfer functions. To develop pedotransfer functions, we can use regression PTFs and neural networks. In the present study for estimating CEC, 60 surface soil samples (0-30 cm) were collected in 250×250 m grid from calcareous and gypsiferous soils of Yazd-Ardakan plain. Input parameters for estimating CEC in both mentioned models were: soil texture class and soil organic carbon content. Finally, result of prediction of CEC by regression PTFs and neural networks compare with empiric pedotransfer functions. In general, the neural network-based models were provided more reliable predictions (RMSE=1.04 and coefficient of determination=0.97) than the regression-based PTFs. Higher accuracy of ANN is because of non-linear correlation between dependent and independent variables.

Keywords: Pedotransfer functions, Cation exchange capacity, Calcareous and gypsiferous soils

* Corresponding Author; Email: m_mehrabanian@yahoo.com