

کارایی الگوریتم کرم شب تاب و الگوریتم ژنتیک در تخمین ظرفیت تبادل کاتیونی خاک با شبکه‌های عصبی مصنوعی

مسلم ثروتی^{1*} - حمیدرضا ممتاز²

تاریخ دریافت: 1396/03/02

تاریخ پذیرش: 1396/07/03

چکیده

در دهه‌های اخیر اندازه‌گیری غیرمستقیم ظرفیت تبادل کاتیونی (CEC) با استفاده از توابع انتقالی مختلف موفقیت‌آمیز بوده است. شبکه عصبی مصنوعی (ANN) نسبت به روش‌های رگرسیون آماری دارای نتایج مناسب‌تری بوده ولی با داده‌های اندک کارایی بالایی نداشته و از سوی دیگر فاقد یک روش استقرایی جامع در انتخاب الگوریتم یادگیری شبکه و توقف در حداقل محلی است. در این راستا استفاده از الگوریتم‌های بهینه‌سازی ضروری به نظر می‌رسد. هدف از این تحقیق، ارزیابی کارایی الگوریتم‌های کرم شب تاب (FA) و ژنتیک (GA) در تخمین CEC با استفاده از ANN است. برای نیل به اهداف فوق 220 نمونه از منطقه گل‌فرج به صورت تصادفی برداشته شد. سپس مدل‌سازی با سه مدل ANN، شبکه عصبی مصنوعی-ژنتیک (ANN-GA) و شبکه عصبی مصنوعی-کرم شب تاب (ANN-FA) انجام شد. در این تحقیق شبکه‌های عصبی با ساختار پرسپترون چندلایه، با الگوریتم پس انتشار خطا، تابع آموزشی بایزین و تابع محرک سیگموئید آکسون با 5 نرون مناسب‌ترین ساختار بوده است. نتایج نشان داد که مدل ANN-FA دارای بیشترین کارایی بوده، به طوری که ضریب تبیین و میانگین انحراف مربعات خطا و ضریب نش - ساتکلیف به ترتیب در مرحله آموزش 0/94، 1/31 و 0/53 و در مرحله آزمون 0/97، 1/06 و 0/59 بوده و مدل ANN-GA در مقام دوم از نظر کارایی بوده است. میانگین هندسی نسبت خطا 0/84 برای مدل ANN-FA بوده که نشان دهنده بیش برآوردی نسبی آن است. نهایتاً مدل پیشنهادی برای تخمین ویژگی خروجی مناسب بوده و کاربرد الگوریتم بهینه‌سازی کرم شب تاب و ژنتیک، حاکی از کاربردی بودن این الگوریتم‌ها در فرآیندهایی با طبیعت پیچیده و غیرخطی است.

واژه‌های کلیدی: الگوریتم تلفیقی، بهینه‌سازی، ویژگی‌های زود یافت

مقدمه

(17). روش‌های مختلفی برای ایجاد توابع انتقالی جهت تخمین ظرفیت تبادل کاتیونی استفاده شده که از آن جمله می‌توان به روش‌های آماری چندمتغیره، شبکه‌های عصبی مصنوعی و روش‌های ترکیبی اشاره نمود. اکبرزاده و همکاران (2) ظرفیت تبادل کاتیونی 80 نمونه خاک از ایران را به وسیله رگرسیون‌های خطی چندگانه مدل سازی نمودند. نتایج نشان داد که ماده آلی و رس به‌عنوان عوامل تأثیرگذار در تخمین ظرفیت تبادل کاتیونی بوده و ضریب تبیین نیز نسبتاً قابل قبول است. با توسعه سریع فناوری‌های پردازش رایانه‌ای و ایجاد نرم‌افزارهای مربوطه، از مزایای فناوری هوش مصنوعی مانند شبکه‌های عصبی³ برای مسائل مربوط به مدل‌سازی سامانه‌ها و فرآیندها استفاده شد (16). یکی از مزیت‌های استفاده از شبکه‌های عصبی مصنوعی نسبت به مدل‌های آماری عدم نیاز به یک تابع خاص برای بیان رابطه میان داده‌های ورودی و خروجی بوده و رابطه بین آن‌ها از طریق فرآیند آموزش به دست می‌آید (20). امینی و همکاران

در دهه‌های اخیر کاربرد داده‌های خاکی قابل اطمینان در مقیاس بزرگ برای طراحی سامانه‌های ارزیابی اراضی رو به توسعه است (17). ظرفیت تبادل کاتیونی از جمله ویژگی‌های خاک بوده که در پایگاه‌های اطلاعاتی (15) به‌عنوان ورودی در مدل‌های زیست‌محیطی به کار می‌رود (13 و 14). همچنین این ویژگی خاکی یکی از شاخص‌های حاصلخیزی در ارتقای کیفیت نقشه‌ها است (19). ظرفیت تبادل کاتیونی به روش مستقیم قابل اندازه‌گیری بوده ولی اندازه‌گیری آن به ویژه در مناطق خشک و نیمه‌خشک به دلیل مقادیر زیاد آهک و گچ، سخت و پرهزینه است (6) لذا تخمین آن با استفاده از توابع انتقالی، از سایر ویژگی‌های فیزیکی و شیمیایی خاک ضروری به نظر می‌رسد

1- استادیار مرکز آموزش عالی شهید باکری میاندوآب، دانشگاه ارومیه
(Email: m.sarvati@urmia.ac.ir)

* - نویسنده مسئول:

2- استادیار گروه علوم خاک، دانشگاه ارومیه

طول شرقی قرار دارد. رژیم رطوبتی منطقه اردبک هم‌مرز با زیرک⁶ و رژیم حرارتی آن ترمیک⁷ است. خاک‌های منطقه بر اساس کلید رده بندی آمریکایی (22) در رده انتی‌سول‌ها و اریدی‌سول‌ها رده‌بندی شدند. جهت نیل به اهداف، 220 نمونه خاک انتخاب گردید. سپس ویژگی‌های فیزیکی و شیمیایی این خاک‌ها برای مدل‌سازی، شامل مقدار نسبی سه ذره (بافت)، سنگریزه، کربن‌آلی، گچ، آهن و pH بر اساس تحقیقات قبلی با روش‌های استاندارد اندازه‌گیری شدند. برای مدل‌سازی تخمین ظرفیت تبادل کاتیونی با روش شبکه‌های عصبی مصنوعی، عصبی-ژنتیک و عصبی-کرم شب‌تاب، ابتدا با استفاده از ماتریس همبستگی پیرسون ویژگی‌های مؤثر در ظرفیت تبادل کاتیونی انتخاب گردید.

مدل‌سازی با شبکه‌های عصبی مصنوعی

در این شیوه از مدل‌سازی، از ساختاری نرونی و هوشمند با الگوبرداری مناسب از نرون‌های موجود در مغز انسان سعی می‌گردد تا از طریق توابع تعریف شده ریاضی رفتار درون‌سلولی نرون‌های مغز شبیه‌سازی شود و از طریق وزن‌های محاسباتی موجود در خطوط ارتباطی نرون‌های مصنوعی، عملکرد سیناپسی در نرون‌های طبیعی به مدل تبدیل شود. بدین منظور الگو، با دسته‌ای از داده‌های واقعی اندازه‌گیری شده، آموزش داده‌شده تا برای ورودی‌های جدید با توجه به رابطه پیدا شده در مرحله آموزش، خروجی مناسب را محاسبه نماید. در این پژوهش جهت شبیه‌سازی و تخمین ظرفیت تبادل کاتیونی از بین ساختارهای گوناگون شبکه‌های عصبی مصنوعی، از روش آموزش تحت نظارت یا سرپرستی با ساختار پرسپترون چندلایه (MLP) با الگوریتم پس انتشار خطا (BP) (4 و 8) استفاده شد. برای این منظور ابتدا داده‌ها دسته‌بندی و با رسم باکس پلات مربوط به هر ویژگی، داده‌های پرت شناسایی و حذف شد. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت شبکه‌های عصبی می‌شود. برای اجتناب از چنین شرایطی داده‌ها استاندارد شدند. برای استانداردسازی داده‌های اولیه از رابطه (1) استفاده شد.

$$X_n = (X_f - X_{min}) / (X_{Max} - X_{min}) \quad (1)$$

در تابع فوق X_n ، X_{max} و X_{min} به ترتیب نشان‌دهنده مقادیر واقعی، استاندارد شده، حداکثر و حداقل داده‌های تحت بررسی هستند.

پس از استانداردسازی داده‌ها، کل داده‌ها به دو بخش آموزش و آزمون تفکیک شد. 75 درصد داده‌ها، یعنی 165 مجموعه داده برای آموزش و 55 مجموعه داده برای آزمون در نظر گرفته شدند. برای کنترل و نظارت بر یادگیری صحیح شبکه، 25 درصد مابقی داده‌ها

(3)، تانگ و همکاران (21)، قربانی و همکاران (9) و کاشی و همکاران (11 و 12) از شبکه‌های عصبی مصنوعی برای تخمین استفاده کردند و دریافتند که شبکه‌های عصبی ظرفیت تبادل کاتیونی را با دقت بیشتر نسبت به مدل‌های رگرسیونی چند متغیره تخمین می‌زند. با این حال شبکه‌های عصبی مصنوعی با داده‌های اندک کارایی بالایی نداشته و از سوی دیگر فاقد یک روش استقرایی جامع در انتخاب الگوریتم یادگیری شبکه و توقف الگوریتم در حداقل محلی¹ است (1). برای حل این مشکل می‌توان از الگوریتم‌های بهینه‌سازی ژنتیک²، کرم شب‌تاب³ و ... استفاده نمود. الگوریتم ژنتیک نوع خاصی از الگوریتم‌های تکاملی است که از تکنیک‌های زیست‌شناسی مانند وراثت و جهش نسخه‌برداری شده است. الگوریتم‌های ژنتیک اغلب گزینه خوبی برای تکنیک‌های پیش‌بینی بر مبنای رگرسیون هستند. موتور الگوریتم ژنتیک یک جمعیت اولیه از روابط ایجاد می‌کند. هر فرد در برابر مجموعه‌ای از داده‌های مورد آزمایش قرار می‌گیرند و مناسب‌ترین آن‌ها باقی می‌مانند و بقیه کنار گذاشته می‌شوند. مناسب‌ترین افراد باهم جفت‌گیری و تغییر کرده‌اند. مشاهده می‌شود که با گذشت از میان تعداد زیادی از نسل‌ها، الگوریتم ژنتیک به سمت ایجاد رابطه‌هایی که دقیق‌تر هستند، میل می‌کنند (10). الگوریتم کرم شب‌تاب نیز یک تکنیک‌های فرا ابتکاری⁴ است که با الهام از رفتارهای ساطع کردن نورهای شب‌تاب به دست آمده است. هدف اولیه کرم شب‌تاب از ساطع نمودن نور برای جذب سایر هموعان است. تحقیقات نشان داده است که این الگوریتم در مقایسه با پرواز پرندگان و ژنتیک برای پیدا کردن نقاط بهینه عمومی⁵ در برخی از کاربردهای مورد آزمون قرار گرفته، از کارایی بیشتری برخوردار است (23). هدف از این تحقیق ارزیابی کارایی روش الگوریتم کرم شب‌تاب در تخمین ظرفیت تبادل کاتیونی خاک با استفاده از شبکه‌های عصبی مصنوعی است. شایان ذکر است که کاربرد الگوریتم کرم شب‌تاب در بهینه‌سازی تخمین ظرفیت تبادل کاتیونی خاک از نوآوری‌های تحقیق حاضر محسوب می‌شود.

مواد و روش‌ها

منطقه گلفرج به وسعت حدود 8000 هکتار در شمال استان آذربایجان شرقی در شهرستان جلفا واقع شده است. این منطقه به لحاظ جغرافیایی بین 38 درجه و 42 دقیقه تا 38 درجه و 46 دقیقه عرض شمالی و بین 45 درجه و 30 دقیقه تا 45 درجه و 53 دقیقه

- 1- Local minimum
- 2- Genetic Algorithm (GA)
- 3- Firefly algorithm (FA)
- 4- Metaheuristic Techniques
- 5- Gravitational search algorithm

6- Aridic Border to Xeric

7- Thermic

مدل‌سازی با الگوریتم شبکه‌های عصبی مصنوعی-کرم شب‌تاب

در این تحقیق کلیه ویژگی‌های ورودی در بازه صفر تا یک نرمال شدند تا باعث افزایش سرعت آموزش و کاهش خطا در شبکه عصبی و همسان‌سازی تغییرات در ابعاد مختلف شود. شایان ذکر است که این ویژگی‌ها براساس مدل نهایی شامل رس، سیلت، شن، ماده آلی بودند. ضریب جذب نور، تغییر جذابیت را مشخص می‌کند و مقدار آن مشخص کننده تعیین سرعت همگرایی و چگونگی رفتار الگوریتم کرم شب‌تاب بوده و رفتار الگوریتم را کنترل می‌کند. با این روش می‌توان چندین نقطه بهینه را در صورت وجود در طی تکرارهای مشابه با تنظیم ضریب جذب نور پیدا کرد. با افزایش ضریب جذب نور، پارامتر جذابیت کم‌رنگ‌تر شده، لذا کرم‌ها به سمت بهینه‌های محلی جذب نمی‌شوند. در صورت وجود چندین نقطه بهینه در فضای جواب، چنانچه تعداد کرم‌ها به صورت قابل توجهی از نقاط بهینه بیشتر باشد، هیچ نقطه‌ای از چشم کرم‌ها دور نخواهد ماند. برای بهینه‌سازی تخمین ظرفیت تبادل کاتیونی ابتدا با استفاده شبکه‌های عصبی مصنوعی مدل‌سازی پروسه صورت گرفت. جمعیت اولیه برای کرم شب‌تاب 40 کرم شب‌تاب در فضای جواب منظور شد. داده‌های اولیه داده‌شده به الگوریتم کرم شب‌تاب در حقیقت داده‌های آموزش شبکه عصبی هستند. میزان روشنایی هر کرم شب‌تاب که مبین تابع هدف یا ظرفیت تبادل کاتیونی است توسط خروجی شبکه عصبی پیش‌بینی و به الگوریتم کرم شب‌تاب داده شد. ابتدا لازم است مناسب‌ترین مقادیر پارامترهای مرتبط با جذب نور محیط و حرکت تصادفی کرم شب‌تاب برای بهینه‌سازی توسط کرم شب‌تاب به دست آیند (24). به این منظور در مرحله اول حرکت تصادفی در مرحله اول برابر با 0/5 در نظر گرفته شد و با تغییر ضریب جذب نور تأثیر آن در مقادیر بهینه بررسی و ضریب جذب نور مناسب انتخاب شد. برای تنظیم مقادیر جذب نور در بازه صفر تا 3 مقادیر بهینه تابع هدف به دست آمد.

مقایسه صحت و دقت ارزیابی

برای این منظور از آماره‌های ضریب تبیین (R^2) (رابطه 1)، جذر میانگین مربعات خطا (RMSE) (رابطه 2)، از معیار نش-ساتکلیف⁴ (رابطه 3) و میانگین هندسی نسبت خطا⁵ (رابطه 4) استفاده شد. در صورت نزدیکی مقادیر پیش‌بینی شده و واقعی شاخص ضریب تبیین، معیار نش-ساتکلیف و میانگین هندسی نسبت خطا به یک و جذر میانگین مربعات خطا به صفر نزدیک خواهد شد.

به‌عنوان داده‌های آزمون مدل معرفی گردید. برای مدل‌سازی شبکه‌های عصبی مصنوعی پس از وارد کردن داده‌ها به نرم‌افزار، جهت تعیین شبکه بهینه از کلیه توابع محرک تعریف شده در نرم‌افزار (تانژانت هیپربولیک آکسون، سیگموئید آکسون، تانژانت هیپربولیک خطی آکسون، سیگموئید خطی آکسون، بایاس آکسون، آکسون خطی و آکسون) به شکل سعی و خطا تا حصول بهترین نتیجه استفاده شد. برای آموزش شبکه‌های طراحی شده با معماری متفاوت، از توابع آموزشی بایزین¹ استفاده شد. این الگوریتم آموزش، بهترین روش برای آموزش شبکه‌های عصبی مصنوعی طراحی شده است و پایداری بیشتری نسبت به دیگر الگوریتم‌های پس انتشار خطا دارد (18).

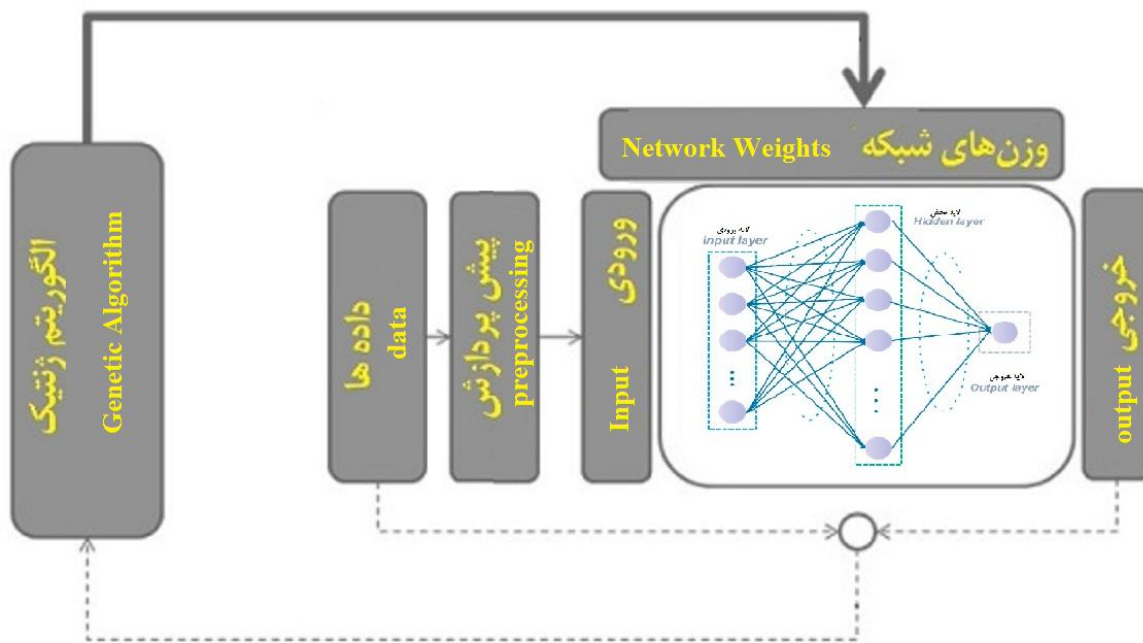
مدل‌سازی با الگوریتم شبکه‌های عصبی مصنوعی-ژنتیک

در این روش الگوریتم ژنتیک به تنظیم اوزان اتصالات شبکه می‌پردازد. شایان ذکر است که در شبکه‌های عصبی مصنوعی بایستی تعداد و نوع ورودی‌ها، لایه‌های میانی، نرون‌ها و الگوریتم مناسب آموزش شبکه درست انتخاب شوند، تا شبکه کارآمد و دقیق طراحی گردد. شکل 1 چگونگی تعامل شبکه عصبی و الگوریتم ژنتیک را نمایش می‌دهد. پس از فرآیند پیش‌پردازش، مجموعه داده‌ها به‌عنوان ورودی شبکه عصبی مورداستفاده قرار گرفت. وزن‌های اولیه متناظر با ورودی‌های شبکه عصبی (کروموزم‌های الگوریتم ژنتیک) در تکرار اول به صورت تصادفی شدند. همچنین، رابطه میانگین مجذور خطا² به‌عنوان تابع برازش هر کروموزم از الگوریتم ژنتیک انتخاب شد و از این رو به‌کارگیری عملگر تقاطع³ امکان‌پذیر شد. در پایان هر تکرار، 10 درصد از بهترین کروموزم‌ها به همراه 90 درصد کروموزم تولید شده تصادفی جدید، به نسل بعد منتقل گردید. فرآیند مذکور تا رسیدن به شرایط توقف الگوریتم ادامه یافت. در پایان بهترین کروموزم به‌عنوان وزن‌های اولیه به شبکه عصبی مصنوعی اعمال شد. تعداد کل تکرار الگوریتم ژنتیک برابر با 200 در نظر گرفته شد و اگر بعد از 40 تکرار بهینه شدن افزایش نیافت، الگوریتم متوقف شد. به‌منظور انتخاب پارامترهای الگوریتم ژنتیک شامل تعداد جمعیت اولیه، احتمال تقاطع و احتمال جهش، الگوریتم از روش سعی و خطا استفاده شد. فرآیند آموزش و آزمون شبکه عصبی پیشنهادی و همچنین الگوریتم ژنتیک در نرم‌افزار متلب نسخه 2012 کد نویسی شده و نتایج محاسباتی آن‌ها توسط سیستم یکسان با مشخصات پردازنده 27/2 گیگاهرتزی و رم 4 گیگا بیتی به دست آمد.

- 1- Bayesian (Ba)
- 2- Mean squared error (MSE)
- 3- Crossover

4- Nash-Sutcliffe (NES)

5- Geometric Mean Error Ratio (GMER)



شکل 1- بهینه‌سازی شبکه‌های عصبی مصنوعی با الگوریتم ژنتیک
Figure 1- Optimization of Artificial Neural Network by Genetic Algorithm

پیرسون بین ویژگی‌های مؤثر در مقدار ظرفیت تبادل کاتیونی را نشان می‌دهد. چنانچه ملاحظه می‌شود 4 ویژگی رس، سیلت، شن و ماده آلی دارای همبستگی بیشتری نسبت به سایر ویژگی‌ها با ظرفیت تبادل کاتیونی داشته لذا به‌عنوان پارامترهای ورودی انتخاب شدند. دران و پارکین (7) ظرفیت تبادل کاتیونی را یکی از پارامترهای مهم کیفیت خاک می‌دانند اگرچه ذرات و ترکیبات خاک (ماده آلی، رس، شن، سیلت، گچ، آهک، نوع رس و ...) به درجات مختلف در ایجاد نقاط تبادل کاتیونی نقش دارند، ولی این ویژگی‌ها در غالب خاک‌ها در بخش رس و مواد آلی آن‌ها متمرکز است که نتایج تحقیق فوق نیز مؤید این مطلب است.

جدول‌های 3 و 4 کارایی توابع محرک مختلف را به‌ترتیب در مرحله آموزش و آزمون و جدول 5 و 6 کارایی تعداد نرون‌های مختلف را به ترتیب در مرحله آموزش و آزمون برای تابع محرک انتخابی نشان می‌دهد. نتایج مؤید این مطلب است که بهترین تابع محرک سیگموئید آکسون با 5 نرون در مرحله آموزش و آزمون است. حداقل مقدار RMSE مربوط به شبکه با پنج نرون در یک‌لایه مخفی است. تغییرات RMSE دارای روند مشخصی نبوده، چون شبکه عصبی یک مدل جعبه سیاه بوده و وزن‌ها به‌طور تصادفی انتخاب می‌شود لذا نمی‌توان این روند موجود را به‌طور کامل توضیح داد. فقط باید با سعی و خطا بهترین ساختار را به دست آورد. شاید به توان گفت با پیچیده‌تر شدن رابطه بین متغیر وابسته و متغیرهای مستقل، مدل شبکه عصبی

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O}_i)(I_i - \bar{I}_i)]^2}{\sum_{i=1}^n (O_i - \bar{O}_i) \sum_{i=1}^n (I_i - \bar{I}_i)} \quad (1)$$

$$RMSE = \frac{1}{n} \sum_{i=1}^n (\bar{O}_i - I_i) \quad (2)$$

$$NSE = \frac{\sum_{i=1}^n (O_i - I_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \quad (3)$$

$$GMER = \exp \left[\frac{1}{n} \sum_{i=1}^n \ln \left(\frac{I_i}{O_i} \right) \right] \quad (4)$$

در این روابط، O_i مقدار عملکرد مشاهده شده، I_i مقدار عملکرد برآورد شده توسط مدل، O_{ii} میانگین مقادیر عملکرد مشاهداتی، I_{ii} میانگین مقادیر عملکرد محاسباتی و n تعداد داده‌ها می‌باشد.

نتایج و بحث

جدول 1 میانگین ویژگی‌های فیزیکی و شیمیایی مورد استفاده را در ایجاد توابع انتقالی نشان می‌دهد. این ویژگی‌ها به همراه آماره‌های توزیع برای مراحل آموزش و آزمون جداگانه مورد بررسی قرار گرفتند. چنانچه ملاحظه می‌شود، خاک‌های مورد بررسی در دامنه وسیعی از نظر ویژگی‌های مورد بررسی قرار دارند. نرمال بودن داده‌ها نیز با استفاده از روش کولموگروف-اسمیرنوف مورد بررسی قرار گرفت که نتایج مؤید نرمال بودن داده است. جدول 2 ماتریس همبستگی

به طوری که ضریب تبیین و میانگین انحراف مربعات خطا به ترتیب در مرحله آموزش 0/91 و 1/77 و در مرحله آزمون 0/93 و 1/50 برآورد گردید. استفاده از معیار نش و ساتکلیف در مرحله آموزش 0/45 و در مرحله آزمون 0/48 نشان دهنده دقت نسبتاً بالای مدل است. میانگین هندسی نسبت خطا در این روش 1/43 برآورد گردید که نشان دهنده کم برآوردی مدل است.

در شبکه‌های عصبی مبتنی بر کرم شب‌تاب نیز پارامترهای مدل در حالت بهینه محاسبه گردید. برای ضریب جذب نور در بازه صفر تا 3 مقادیر تابع هدف به دست آمد. نتایج به دست آمده نشان داد، مقادیر بهینه در این تحقیق تحت تأثیر تغییرات ضریب جذب نور قرار نمی‌گیرد، لذا ضریب جذب نور برابر 1، در نظر گرفته شد. مقدار حرکات تصادفی نیز در حالت بهینه 0/3 برآورد گردید.

بیش از حد آموزش می‌بیند و قادر به برازش مناسب بر روی داده‌های جدید نیست (5).

نتایج مدل‌سازی با شبکه‌های عصبی مصنوعی مؤید این مطلب است که این روش دارای دقت بالایی بوده به طوری که ضریب تبیین و میانگین انحراف مربعات خطا به ترتیب در مرحله آموزش 0/84 و 1/94 و در مرحله آزمون 0/87 و 1/81 برآورد گردید. استفاده از معیار نش و ساتکلیف در مرحله آموزش 0/24 و در مرحله آزمون 0/28 نشان دهنده دقت نسبتاً بالای مدل است. میانگین هندسی نسبت خطا در این روش 1/43 برآورد گردید که نشان دهنده کم برآوردی مدل است.

نتایج مدل‌سازی با شبکه‌های عصبی مصنوعی-الگوریتم ژنتیک مؤید این مطلب است که این روش نیز دارای دقت بالایی بوده

جدول 1- پارامترهای آماری ویژگی‌های فیزیکی و شیمیایی خاک برای 220 نمونه خاک

Table 1- Statistics criteria of physical and chemical properties for 220 soil sample

مرحله Stage	آماره Statistics	گچ Gypsum (%)	کربن آلی Organic matter (%)	pH	شن Sand (%)	سیلت Silt (%)	رس Clay (%)	سنگریزه Gravel (%)	آهک Lime (%)	ظرفیت تبادل کاتیونی CEC (cmol+ kg-1)
آموزش Train	میانگین Average	3.33	0.37	8.19	43.28	32.2	24.38	17.5	26.31	23.7
	بیشینه Maximum	32.34	1.07	8.89	86	54	58	85	61	35.5
	کمینه Minimum	0.1	0.01	7.60	8	4	6	1	7	7.4
	ضریب تغییرات Coefficient of variation	0.47	1.70	27.83	43.28	32.2	2.03	0.87	2.46	28.1
	کشیدگی Kurtosis	0.91	0.98	0.25	0.22	0.37	0.91	0.43	0.95	0.86
	چولگی Skewness	0.62	0.61	0.34	0.68	0.34	0.55	0.45	0.33	0.57
	آزمون نرمال بودن Normality test	0.09*	0.31**	0.13**	0.12**	0.07*	0.12**	0.02**	0.12**	0.11**
آزمون Test	میانگین Average	0.77	0.37	7.83	49.81	35.36	14.95	23.5	26.42	21.4
	بیشینه Maximum	7.5	1.23	8.3	84	44	26	50	48.5	2.34
	کمینه Minimum	0.05	0.04	7.5	30	12	4	2	3.5	1.8
	ضریب تغییرات Coefficient of variation	0.42	1.23	37.62	3.92	4.21	2.53	1.63	2.03	1.26
	کشیدگی Kurtosis	3.24	1.31	0.46	0.94	1.41	0.43	0.37	0	0.79
	چولگی Skewness	10.11	1.71	0.32	1.67	1.89	0.31	0.94	0.33	0.43
	آزمون نرمال بودن Normality test	0.09*	0.31**	0.16**	0.01**	0.06*	0.13**	0.2**	0.17**	0.14**

*: در سطح احتمال 5 درصد، **: در سطح احتمال 1 درصد

جدول 2- ماتریس همبستگی بین پارامترهای انتخابی برای مدل سازی ظرفیت تبادل کاتیونی 220 نمونه خاک

Table 2- Correlation matrix between selected properties for cation exchange capacity modeling for 220 sample

ماده آلی Organic matter	رس Clay	سیلت Silt	شن Sand	گچ Gypsum	آهک Lime	واکنش خاک pH	سنگریزه Gravel	ظرفیت تبادل کاتیونی Cation exchange capacity	
ماده آلی Organic matter	1								
رس Clay	0.82**	1							
سیلت Silt	0.44*	-0.43*	1						
شن Sand	0.41*	0.35	-0.29	1					
گچ Gypsum	0.11	0.15	0.14	0.05	1				
آهک Lime	0.18	0.26	0.32	0.29	0.26	1			
واکنش خاک pH	0.45*	0.21	0.32	0.22	0.29	0.44*	1		
سنگریزه Gravel	0.46*	0.25	0.19	0.21	0.21	0.13	0.35	1	
ظرفیت تبادل کاتیونی CEC	0.93**	0.86**	-0.57*	-0.53*	0.31	0.42	0.38	0.29	1

جدول 3- پارامترهای آماری برای توابع محرک متفاوت شبکه های عصبی مصنوعی در مرحله آموزش

Table 3- Statistics parameter for different stimulating functions of artificial neural networks in train stage

تابع محرک Motion function	شبکه های عصبی مصنوعی Artificial Neural Networks	
	RMSE	R ²
Axon آکسون	2.37	0.72
Bias Axon بایاس آکسون	1.81	0.81
Linear Axon خطی آکسون	2.30	0.74
Linear Sigmoid Axon سیگموئید خطی آکسون	2.07	0.77
Linear Tanh Axon تانژانت خطی آکسون	2.16	0.76
Sigmoid Axon سیگموئید آکسون	1.67	0.82
Tanh Axon تانژانت آکسون	1.94	0.79

جدول 4- پارامترهای آماری برای توابع محرک متفاوت شبکه های عصبی مصنوعی در مرحله آزمون

Table 4- Statistics parameter for different stimulating functions of artificial neural networks in test stage

تابع محرک Motion function	شبکه های عصبی مصنوعی Artificial Neural Networks	
	RMSE	R ²
Axon آکسون	2.37	0.73
Bias Axon بایاس آکسون	1.74	0.83
Linear Axon خطی آکسون	2.24	0.75
Linear Sigmoid Axon سیگموئید خطی آکسون	2.00	0.79
Linear Tanh Axon تانژانت خطی آکسون	2.15	0.78
Sigmoid Axon سیگموئید آکسون	1.59	0.85
Tanh Axon تانژانت آکسون	1.86	0.80

جدول 5- پارامترهای آماری برای تعداد نرون‌های متفاوت تابع محرک Sigmoid Axon در مرحله آموزش
 Table 5- Statistics parameter for different number of neurons triggers function Sigmoid Axon in train stage

تابع محرک Motion function	شبکه‌های عصبی مصنوعی Artificial Neural Networks		
	تعداد نرون Number of neurons	RMSE	R ²
سیگموئید آکسون Sigmoid Axon	2	2.20	0.73
	3	2.16	0.76
	4	2.13	0.79
	5	1.94	0.84
	6	2.23	0.81
	7	2.54	0.78
	8	2.45	0.79
	9	2.69	0.75
	10	2.67	0.74

جدول 6- پارامترهای آماری برای تعداد نرون‌های متفاوت تابع محرک Sigmoid Axon در مرحله آزمون
 Table 6- Statistics parameter for different number of neurons triggers function Sigmoid Axon in test stage

تابع محرک Motion function	ANN		
	تعداد نرون Number of neurons	RMSE	R ²
سیگموئید آکسون Sigmoid Axon	2	2.18	0.74
	3	2.14	0.79
	4	2.03	0.81
	5	1.81	0.87
	6	2.11	0.85
	7	2.41	0.79
	8	2.36	0.80
	9	2.57	0.78
	10	2.55	0.76

کارایی شبکه‌های عصبی مصنوعی با استفاده از الگوریتم کرم شب‌تاب دارد.

نتیجه‌گیری کلی

بر اساس ماتریس همبستگی پیرسون چهار ویژگی در تخمین CEC بیشترین وزن را به خود اختصاص دادند و لذا به‌عنوان ورودی‌های مدل انتخاب شدند. از نظر شیمی خاک، از بین سه ذره رس، سیلت و شن فقط ذرات رس دارای بار الکتریکی منفی بوده و باعث ایجاد CEC می‌شوند، از طرفی افزایش در میزان سیلت و شن باعث کاهش CEC می‌شود. در روش شبکه‌های عصبی مصنوعی بیشترین کارایی متعلق به شبکه‌ها با تابع محرک سگموئید آکسون با 5 نرون در مرحله آموزش و آزمون بود. در مقایسه میان سه روش مورد استفاده برای تخمین ظرفیت تبادل کاتیونی، روش شبکه‌های عصبی مصنوعی - کرم شب‌تاب از دقت بیشتری برخوردار بود. لازم به ذکر است که کاربرد الگوریتم بهینه‌سازی ژنتیک نیز باعث افزایش کارایی مدل‌سازی تخمین ظرفیت تبادل کاتیونی نسبت به مدل شبکه‌های عصبی مصنوعی گردید. بنابراین پیشنهاد می‌شود با توجه به اینکه

نتایج مدل‌سازی با شبکه‌های عصبی مصنوعی مبتنی بر الگوریتم کرم شب‌تاب نشان داد که این روش دارای دقت بالایی بوده به طوری که ضریب تبیین و میانگین انحراف مربعات خطا به ترتیب در مرحله آموزش 0/94 و 1/31 و در مرحله آزمون 0/97 و 1/06 برآورد گردید. استفاده از معیار نش و ساتکلیف در مرحله آموزش 0/53 و در مرحله آزمون 0/59 نشان دهنده دقت نسبتاً بالای مدل است. میانگین هندسی نسبت خطا در این روش 0/84 برآورد گردید که حاکی از بیش‌برآوردی مدل است.

در کل می‌توان چنین بیان کرد که روش شبکه‌های عصبی مصنوعی - الگوریتم کرم شب‌تاب، شبکه‌های عصبی مصنوعی - الگوریتم ژنتیک و شبکه‌های عصبی مصنوعی به دلیل ضریب تبیین بیشتر، ریشه میانگین مربعات خطای کمتر، ضریب نش-ساتکلیف نزدیک‌تر به یک به ترتیب بیشترین کارایی را دارند. همچنین این روش علاوه بر کارایی بیشتر از سرعت بالایی در رسیدن به جواب تخمین برخوردار است. شایان ذکر است که مدل شبکه‌های عصبی مصنوعی - الگوریتم شب‌تاب دارای بیش‌برآوردی و دو مدل دیگر دارای کم-برآوردی هستند. نهایتاً نتایج بهینه‌سازی حاکی از امکان افزایش

روش هیبرید شبکه عصبی مصنوعی با الگوریتم بهینه‌سازی کرم شب‌تاب دارای کارایی زیاد برای تخمین و تشخیص روابط غیرخطی بین متغیرها می‌باشند.

شبکه‌های عصبی مصنوعی فاقد یک روش استقرایی جامع در انتخاب الگوریتم یادگیری شبکه و توقف الگوریتم در حداقل محلی است، لذا در تخمین‌های مختلف ویژگی‌های دیرپافت خاک از یک الگوریتم بهینه‌سازی استفاده گردد. در نهایت می‌توان چنین عنوان کرد که

منابع

- 1- Andonie R. 2010. Extreme Data Mining: Inference from small data sets, *International Journal of Computers Communications and Control*, 5(3):280-291.
- 2- Akbarzadeh A., Taghizadeh Mehrjardi R., Rahimi Lak H., and Ramezanpour H. 2009. Application of artificial intelligence in modeling of soil properties (Case study: Roodbar Region, North of Iran), *Environmental Research Journal*, 3(2):19-24.
- 3- 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, *European Journal of Soil Science*, 53:748-757.
- 4- Asgari M.S., Khodadadi M., Sarmadian F., and Gzny R. 2009. The effectiveness of artificial neural networks in the yield of wheat, barley and maize, *Journal of Agriculture*, 85(1):62-71.
- 5- Bell M.A., and Van Kullen H. 1995. Soil pedotransfer function for four Mexican soils, *Soil Science Society of America Journal*, 59:865-871.
- 6- Carpena O., Lux A., and Vahtras K. 1972. Determination of exchangeable cations in calcareous soils, *Journal of Soil Science*, 33:194-199.
- 7- Doran J.W., and Parkin T.B. 1994. Defining and assessing soil quality. p. 543-569. In J.W Doran et al (Ed.) *Defining Soil Quality for a Sustainable Environment*, Soil Science Society American Special publication, Madison, Wisconsin, USA.
- 8- DuBose P., and Klimasauskas C. 1989. *Introduction to Neural Networks with Examples and Applications*, Neural Ware Inc, Pittsburgh.
- 9- Ghorbani H., Kashi H., Hafezi Moghadas N., and Emamgholizadeh S. 2015. Estimation of soil cation exchange capacity using multiple regression, artificial neural networks and adaptive neuro-fuzzy inference system models in Golestan Province, Iran. *Communication in Soil Science and Plant Analysis*, 46(6):763-780.
- 10- Holland J.H. 1984. *The Georgians: Genealogies of Pioneer Settlers*. Genealogical Publishing Com, Amesterdam.
- 11- Kashi H., Ghorbani H, Emamgholizadeh S., and Hashemi S.A.A. 2013. The Estimation of Soil Cation Exchange Capacity in Disturbed and Undisturbed Soils Using Artificial Neural Networks and Multiple Regressions, *Journal of water and soil*, 27:472-484.
- 12- Kashi H., Emamgholizadeh S., and Ghorbani H. 2014. Estimation of soil infiltration and cation exchange capacity based on multiple regression, ANN (RBF, MLP), and ANFIS Models, *Soil Science and Plant Analysis*, 45:1195-1213.
- 13- Keller A., Von steiger B., Van der Zee S.T., and Schulin R. 2001. A stochastic empirical model for regional heavy metal balances in agro ecosystems, *Journal of Environmental Quality*, 30:1976-1989.
- 14- Krogh L., Madsen H.B., and Greve M.H. 2000. Cation exchange capacity pedotransfer functions for Danish soils, *Soil and Plant Science*, 50:1-12.
- 15- Manrique L.A., Jones C.A., and Dyke P.T. 1991. Predicting cation exchange capacity from soil physical and chemical properties, *Soil Science Society of America Journal*, 50:787-794.
- 16- Merdun H., Cinar O., and Apan M. 2006. Comparison of artificial neural network and regression pedotransfer function for prediction of soil water retention and saturated hydraulic conductivity, *Soil and Tillage Research*, 90:108-116.
- 17- McBratney A.B., Minasny B., Cattle S. R., and Vervoort R.W. 2002. From pedotransfer functions to soil inference systems, *Geoderma*, 109:41-73.
- 18- Mirzaee S., Ghorbani-dashtaki Sh., Mohammadi J., Asadzadeh F., and Kerry R. 2017. Modeling WEPP erodibility parameters in calcareous soils in northwest Iran, *Ecological Indicators*, 74:302-310.
- 19- Oberthur T., Doberman A., and Neue H.V. 1996. How good is a reconnaissance soil map for agronomic purpose?, *Soil Use and Management*, 12:33-43.
- 20- Schaap M.G., and Bouten W. 1996. Modelling water retention curves of sandy soils using neural networks, *Water Research*, 32: 3033-3040.
- 21- 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, *Environmental Engineering Science*, 26(2):1-10.
- 22- USDA. 2014. *Keys to Soil Taxonomy*. 12th edition, Soil Survey Staff, Natural Resource Conservation Service.
- 23- Yang, X. S. 2008. *Nature-Inspired Metaheuristic Algorithms*, Luniver Press, UK.
- 24- Yang X.S. 2009. *Firefly Algorithms for Multimodal Optimization*. P. 169-178. In *Stochastic Algorithms. Foundations and Applications*, SAGA, Lecture Notes in Computer Sciences, Cambridge, UK.



Firefly Algorithm and Genetic Algorithm Performance in Cation Exchange Capacity Prediction by Artificial Neural Networks

M. Servati^{1*}- H. Momtaz²

Received: 23-05-2017

Accepted: 25-09-2017

Introduction: Cation Exchange Capacity (CEC) refers to the amount of negative charges available on the soil colloids surface. Clay and organic colloids carry a negative charge on their surfaces. Cations are attracted to the colloids by electrostatic bonds. Therefore, the charge of the soil is zero. For fertility map planning and commonly indicator of soil condition, CEC is an essential property. CEC is commonly measured on the fine earth fraction (soil particles less than 2 mm in size). CEC could be obtained directly but its measurement is difficult and expensive in the arid and semi-arid regions with high amounts of gypsum and lime. Pedotransfer functions (PTFs) are appropriate tools to estimate CEC from more readily measured properties such as texture, organic carbon, gravel, pH and etc. Regression PTFs, artificial neural networks (ANN), and hybrids technique (HA) could be used to developing pedotransfer functions. The prior research revealed that could provide superior predictive performance when developed ANN model. Furthermore, ANN technique has no comprehensive method to select network learning algorithm and stopping algorithm in the minimum local. Therefore, application of optimization algorithms such as Genetic (GA) and firefly (FA) is necessary. The Purpose of the present study was to evaluate the performance of FA and GA to predict the soil cation exchange capacity by ANN technique based on easily-measured soil properties.

Materials and Methods: 220 soil samples were collected from 39 soil profiles located in Golpharaj (Jolfa) area of East Azarbaijan province. The study site lies from 45° 30' to 45° 53' east longitudes and from 38° 42' to 38° 46' north latitudes. Then, soil samples were air-dried and passed through a 10 mesh sieve for removing gravels and root residues. Soil textural class, organic matter content and CEC were, respectively, determined by hydrometer, Walkley and Black, and bower methods. The artificial neural network (ANN), artificial neural network-Genetic algorithm (ANN-GA) and artificial neural network-Firefly algorithms (ANN-FA) models were applied to predict the soil cation exchange capacity on the basis of the easily-measured soil properties. In ANN-GA and ANN-FA models, soil CEC was estimated via an artificial neural network and were then optimized using a genetic algorithm and firefly algorithm. The Genetic algorithms are commonly used to generate high-quality solutions to be optimized by relying on crossover, mutation and selection operators. The firefly algorithm is modeled by the light attenuation over fireflies' mutual gravitation, instead of the phenomenon of the fireflies light. The schema of flashes is frequently unique for specific types. The techniques' results were then compared by four parameter, i.e., correlation coefficient (R^2), root mean square errors (RMSE), Nash-Sutcliffe (NES) and Geometric mean error ratio (GMRE).

Results and Discussion: The correlation coefficients of soil characteristic factors with CEC were analyzed through correlation matrix analysis. According to this analysis, the factors which had insignificant influence on the CEC were excluded. The clay, silt, sand and organic matter content were selected as input data. The parameter of the best deployment for MLP network could be used to predict CEC in the studied site. This model comprised 4 neurons (sand, silt, clay percentage and OM) in input layer. The optimum number of neurons in hidden layer was estimated to be 5. Additionally, the most efficient activity function in hidden layer was Axon sigmoid. Results showed that three CEC models performed reasonably well. ANN-FA model had the highest R^2 (0.94), lowest RMSE ($1.31 \text{ Cmol}^+ \text{ Kg}^{-1}$) and highest Nash-Sutcliffe coefficient (0.53) in training stage and high R^2 (0.97), lowest RMSE ($1.06 \text{ Cmol}^+ \text{ Kg}^{-1}$) and highest Nash-Sutcliffe coefficient (0.59) in test stage. ANN-GA model had also higher R^2 (0.91), lower RMSE ($1.77 \text{ Cmol}^+ \text{ Kg}^{-1}$) and higher Nash-Sutcliffe coefficient (0.45) in training stage and higher R^2 (0.93), lower RMSE ($1.50 \text{ Cmol}^+ \text{ Kg}^{-1}$) and higher Nash-Sutcliffe coefficient (0.48) in test stage indicating good performance of the model as compared with ANN models. The results showed that both ANN and Hybrid algorithm methods performed poorly in extrapolating the minimum and maximum amount of CEC soil properties data. In addition, the comparison of ANN-FA, ANN-GA results with ANN

1- Assistant Professor Shahid Bakeri High Education Center of Miandoab, Urmia University, Urmia, Iran

(*- Corresponding Author Email: m.sarvati@urmia.ac.ir)

2- Assistant Professor of Soil Science Department, Urmia University, Urmia, Iran

models revealed that ANN-FA was more efficient than the others.

Conclusions: The results of present study illustrated that ANN model can predict CEC with acceptable limits. Therefore, FA and GA algorithms provide superior predictive performance when is combined with ANN model. Firefly algorithm as a new method is utilized to optimize the amount of the weights by minimizing the network error. Final results revealed that this suggested technique improves the modeling performance.

Keywords: Easily-measured properties, Hybrid algorithm, Optimizations