

ارزیابی کاربرد مدل‌های شبکه عصبی مصنوعی، شبکه عصبی تطبیقی فازی و رگرسیون در پیش‌بینی کربن آلی ذره‌ای در مراتع خرابه سنجی ارومیه

بهنام بهرامی^۱، قاسمعلی دیانتهی تیلکی^{۲*}، سعید خسروبیگی^۳، سعید جانی زاده^۴، جواد معتمدی^۴

۱- دانشجوی کارشناسی ارشد مرتعداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس

۲- دانشیار گروه مرتعداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس

۳- دانشجوی کارشناسی ارشد آبخیزداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس

۴- استادیار دانشکده منابع طبیعی، دانشگاه ارومیه

* نویسنده مسئول: dianatitilaki@yahoo.com

تاریخ دریافت: ۹۱/۱۱/۰۲ تاریخ پذیرش: ۹۱/۱۲/۰۹

چکیده

کربن آلی خاک اثرات مفیدی روی خواص شیمیایی، فیزیکی و حرارتی خاک داشته و همچنین روی فعالیت‌های بیولوژیکی خاک‌ها موثر است. کربن آلی ذره‌ای یکی از بخش‌های مهم ناپایدار مواد آلی می‌باشد و نقش قابل توجهی در کیفیت خاک و مدیریت سرزمین‌های مرتعی دارد. در این تحقیق جهت برآورد دقیق کربن آلی ذره‌ای خاک از مدل‌های شبکه عصبی مصنوعی (ANN)، شبکه عصبی تطبیقی-فازی (ANFIS) و رگرسیون چند متغیره استفاده شد. جهت انجام تحقیق، ۶۰ نمونه خاک از عمق ۰-۳۰ سانتیمتری در میان ۶۰ کوادرات یک متر مربعی که در طول ۶ ترانسکت ۱۰۰ متری در مراتع خرابه سنجی ارومیه مستقر شده بود، برداشت شد. خصوصیات خاک (نیترژن، رس، سیلت، کربن آلی، اسیدیته، هدایت الکتریکی و وزن مخصوص ظاهری خاک) اندازه‌گیری شدند. شاخص‌های آماری RMSE و CE جهت ارزیابی کارکرد مدل‌ها استفاده شدند. نتایج نشان داد بر اساس معیارهای مجذور میانگین مربعات خطا و ضریب کارایی که در مدل رگرسیونی به ترتیب ۰/۱۶ و ۰/۴۱ و در مدل شبکه عصبی مصنوعی به ترتیب ۰/۱۱ و ۰/۶۵ و در مدل شبکه عصبی تطبیقی-فازی به ترتیب ۰/۰۶ و ۰/۷۹ می‌باشند، مدل شبکه عصبی تطبیقی فازی (ANFIS) به عنوان ابزار قدرتمندتری در پیش‌بینی کربن آلی ذره‌ای خاک نسبت به آنالیز رگرسیون خطی چندمتغیره و شبکه عصبی مصنوعی عمل می‌کند.

واژه‌های کلیدی: خصوصیات خاک، کربن آلی، مدل‌سازی، ضریب کارایی

مقدمه

ناپایدار (Labile) می‌باشد. ذخایر مواد آلی تعریف شده در بخش ناپایدار عبارتند از: مواد آلی ذره‌ای (Particulate Organic Matter) (POM)، کربن زیست‌توده میکروبی، کربن محلول، کربن قابل معدنی شدن و کربن قابل عصاره‌گیری با عصاره‌گیرهای مختلف. مواد آلی ذره‌ای بخشی از ماده آلی است که از نظر مقدار تجزیه، حدواسط بقایای گیاهی تازه و هوموس می‌باشد و به عنوان مخزن موقتی ماده آلی شناخته می‌شود. این بخش هرچند سهم ناچیزی از حجم خاک را به خود اختصاص می‌دهد ولی به دلیل داشتن زمان بازگشت کوتاه و نیز غنی بودن از عناصر غذایی و کربن یکی از شاخص‌های مهم کیفیت خاک به

ماده آلی خاک یکی از شاخص‌های مهم جهت بهبود کیفیت خاک می‌باشد که باعث حفظ آب و تنظیم حرکات آن می‌شود و مواد غذایی را برای گیاهان فراهم نموده و باعث پایداری ساختمان خاک به وسیله تاثیر بر مقدار خاکدانه‌های درشت و ریز می‌شود (Handayani et al., 2008). در واقع ماده آلی عاملی برای تداوم حاصل‌خیزی خاک، جلوگیری از فرسایش و پیش‌روی بیابان و فراهم کننده یک محیط مناسب برای فعالیت بیولوژیکی خاک می‌باشد (Spaccini et al., 2004). ماده آلی خاک شامل دو بخش مواد هوموسی و ترکیبات

روش‌های محاسباتی با دقت مطلوب در تخمین این پارامتر پیچیده و مهم را می‌رساند. در ایران، اکثر مطالعات صورت گرفته در زمینه برآورد ماده آلی خاک از مدل‌های تجربی و نیمه‌تجربی استفاده شده است. حال آنکه به دلیل محدود بودن اطلاعات پیرامون مواد آلی ذره‌ای و دشواری و هزینه‌های زیاد حاصل از آزمایش شیمیایی این فاکتور، پیش‌بینی کربن آلی ذره‌ای به عنوان عاملی مهم در کاربری‌های مختلف خاک ضروری به نظر می‌رسد. به دلیل پیچیدگی روابط کربن آلی ذره‌ای و خصوصیات فیزیکی و شیمیایی خاک، بهتر است از انجام تحلیل‌های پیچیده که در برگیرنده ضرایب گوناگون برای تنظیم فرمول‌های ریاضی مدل‌ها می‌باشد، چشم‌پوشی شده و از روش‌های هوش مصنوعی (Artificial intelligence) که از قدرت انعطاف‌پذیری بالایی برخوردار است، استفاده شود. روش‌های هوش مصنوعی (مانند شبکه عصبی مصنوعی و شبکه عصبی تطبیقی-فازی) از روش‌های محاسباتی هوشمند می‌باشند که مزیت اصلی آنها سرعت بالا و دقت مطلوب در پیش‌بینی متغیرهای پیچیده با نداشت خطی و غیرخطی است. اصولاً روش‌های هوش مصنوعی در حل مسائل پیچیده که مدل‌های تجربی یا نیمه‌تجربی در حل آن کارایی مناسب نداشته باشند، بسیار کارا هستند (Caudill 1987). پیلهور شهری و همکاران (۱۳۸۹) در تحقیقی تحت عنوان مقایسه مدل شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره در پیش‌بینی کربن آلی خاک به کمک داده‌های آنالیز سطح زمین به این نتیجه دست یافتند که مدل شبکه عصبی مصنوعی نسبت به آنالیز رگرسیون خطی چندمتغیره به عنوان ابزار قدرتمندتری در پیش‌بینی کربن آلی عمل می‌کند. پارسافر و معروفی (۱۳۹۰) نیز در مطالعه برآورد دمای عمق‌های مختلف خاک از دمای هوا با بکارگیری روابط رگرسیونی، شبکه عصبی و شبکه عصبی-فازی، مدل ANN را به عنوان مدلی با دقت بالا نسبت به سایر مدل‌ها (ANFIS و رگرسیونی) معرفی کردند. انگلبای و کراو (۲۰۰۱) برای پیش‌بینی میزان کربن آلی از مدل شبکه عصبی مصنوعی استفاده کردند و نتایج آن را با مدل رگرسیون چندمتغیره مقایسه نمودند و به این نتیجه رسیدند که مدل حاصل از شبکه عصبی نسبت به سایر مدل‌ها برتری دارد. هلمبرگ و همکاران (۲۰۰۶) از مدل شبکه عصبی مصنوعی برای پیش‌بینی میزان کربن آلی، نیتروژن و فسفر استفاده

حساب می‌آید (Haynes, 2005). با توجه به این که مراتع توانایی زیادی برای جذب کربن دارند و در نواحی خشک و نیمه خشک ایران از وسعت بالایی برخوردار هستند، مطالعه محتوای کربن آلی و تغییرات مکانی در اکوسیستم‌های مزبور حائز اهمیت می‌باشند. این موضوع می‌تواند در کشورهای در حال توسعه‌ای همچون ایران که با بحران فرسایش خاک مواجه هستند، منجر به ایجاد راهکاری شود که حفاظت اراضی، بهره‌وری بهینه از اراضی و همچنین اصلاح و احیاء مراتع تخریب یافته را به دنبال داشته باشد. خاک منبعی برای ذخیره و جذب کربن در ارتباط با اتمسفر است. ظرفیت بالای خاک برای ترسیب و رهاسازی کربن باعث می‌شود تا این سیستم نقش مهمی در کنترل میزان دی‌اکسید کربن اتمسفر داشته باشد (Zevebergen, 1987 ; Auerswald & Sinowski, 1999) (Thorne &

اکوسیستم‌های مرتعی به دلیل اینکه نیمی از کل اراضی جهان را در بر گرفته‌اند، قابلیت بالایی در پذیرش کربن دارند. برآورد ذخیره کربن خاک در مقیاس منطقه‌ای، ملی و جهانی، بیشترین اهمیت را در ارزیابی تغییرات چرخه کربن دارد. ذخیره کربن در خاک به شکل ماده آلی در مقیاس جهانی نه تنها باعث افزایش تولید محصولات کشاورزی از طریق بهبود حاصل‌خیزی خاک‌ها می‌گردد، بلکه باعث کاهش میزان دی‌اکسید کربن هوا در نتیجه نقصان اثرات سوء گلخانه‌ای می‌شود (Somaratne et al., 2005).

مواد آلی ذره‌ای که متشکل از کربن آلی ذره‌ای (POM-C) و نیتروژن آلی ذره‌ای (POM-N) بوده، بسیار حساس به تغییرات مدیریتی و محیطی در مقایسه با مجموع کل ماده آلی خاک می‌باشند (Parton et al., 1987 ; Cambardella & Elliott, 1992). کربن آلی ذره‌ای (Particulate Organic Matter, POM-C) نزدیک به ۳۹ درصد کربن آلی خاک را تشکیل می‌دهد (Elliott, 1992) (Cambardella & Elliott, 1992). لذا برآورد مکانی و تغییرات کربن آلی ذره‌ای در اکوسیستم‌های مختلف حائز اهمیت است. یکی از دقیق‌ترین و مرسوم‌ترین روش‌های ارزیابی کربن آلی ذره‌ای خاک، پایش زمینی و نمونه‌برداری مستقیم خاک و آنالیزهای آزمایشگاهی است. از آنجایی که مقدار کربن آلی ذره‌ای خاک متأثر از خصوصیات فیزیکی و شیمیایی خاک منطقه می‌باشد، لزوم به کارگیری

از سطح دریا و میانگین بارش سالانه منطقه ۳۴۵/۴ میلیمتر و متوسط سالانه دما ۱۲/۵ درجه سانتی‌گراد می‌باشد. گونه‌های گیاهی شاخص منطقه *Onobrychis sativa*، *Astragalus coronilla*، *Noaea mucronata*، *Gundelia tournefortii* می‌باشند. اقلیم حوزه مورد مطالعه با استفاده از روش اقلیم نمای آمبرژه، اقلیم نیمه خشک سرد، بافت خاک منطقه تغییرات بسیار کمی دارد و بطور متوسط بافت خاک، لومرسی شنی است (فجری، ۱۳۸۸). پوشش گیاهی مراتع مورد بررسی، بر مبنای نمود ظاهری (فیزیونومی) و در مقیاس ۱:۵۰۰۰ شامل ۲ تیپ گیاهی *Dactylis glomerata - Astragalus spp.*، *Bromus tomentellus - Astragalus spp.* می‌باشد (فجری، ۱۳۸۸).

روش تحقیق

به منظور ارزیابی مدل‌های شبکه عصبی مصنوعی، شبکه عصبی تطبیقی-فازی و رگرسیون در پیش‌بینی کربن آلی ذره‌ای با استفاده از ویژگی‌های زود یافت خاک، ابتدا در تیپ‌های گیاهی *Dactylis glomerata - Astragalus spp.*، *Bromus tomentellus - Astragalus spp.* که سطح زیادی از مراتع منطقه را به خود اختصاص می‌دهند، دو مکان مرتعی با مساحت ۳۰ هکتار که از نظر خصوصیات فیزیکی مرتع و پوشش گیاهی، نماینده تیپ-های گیاهی مذکور می‌باشند، انتخاب و سپس در هر مکان، با توجه به پراکنش پوشش گیاهی و خصوصیات فیزیکی مراتع مورد بررسی، ۳ عدد ترانسکت ۱۰۰ متری که ۲ عدد از آنها موازی با جهت شیب و ۱ عدد از آنها عمود بر جهت شیب بودند، بطور سیستماتیک در مرتع پیاده گردید. در منطقه مورد مطالعه، سطح پلات یک متر مربع و تعداد آن برای هر واحد نمونه‌برداری ۳۰ عدد تعیین شد. در طول هر ترانسکت، پلات‌ها به فاصله ۱۰ متر از هم قرار داده شدند. در هر پلات نوع و تعداد گونه‌های موجود و درصد پوشش آنها تعیین شد. در ضمن از هر پلات اقدام به برداشت نمونه خاک از عمق ۰-۳۰ سانتی‌متری (بر اساس عمق ریشه‌دوانی گیاهان مرتعی) و تعیین عوامل فیزیوگرافی (شیب و ارتفاع) گردید. وزن مخصوص ظاهری به روش استوانه (Blake, 1986) و EC، pH و آن‌ها پس از تهیه گل اشباع، با دستگاه EC متر و pH متر اندازه‌گیری شدند. مقادیر

کردند. پاراسومان و همکاران (۲۰۰۶) برای برآورد هدایت آبی اشباع در مقیاس مزرعه‌ای، دو مدل شبکه عصبی مصنوعی طراحی نمودند. پارامترهای ورودی در مدل اول درصد رس، سیلت و شن بود و در مدل دوم علاوه بر سه ویژگی یادشده، جرم ویژه ظاهری اضافه شد. نتایج این پژوهش نشان داد که شبکه‌های عصبی مصنوعی طراحی شده عملکردی بهتر در برآورد هدایت آبی اشباع در مقایسه با نرم‌افزار Rosetta داشته‌اند. مردون و همکاران (۲۰۰۶) با استفاده از توابع انتقالی و شبکه عصبی مصنوعی هدایت هیدرولیکی اشباع را برآورد نمودند. در این پژوهش ۱۳۰ نمونه از داده‌ها برای پی‌ریزی مدل‌ها و ۶۵ نمونه باقی‌مانده برای ارزیابی مدل‌ها مورد استفاده قرار گرفت. نتایج این پژوهش نشان داد که مدل‌های رگرسیونی، برآورد بهتری از هدایت هیدرولیکی اشباع نسبت به شبکه عصبی مصنوعی داشته‌اند. با این وجود، تفاوت یاد شده در برآورد متغیرهای مورد نظر از نظر آماری معنی‌دار نبوده است. در کشور ما با وجود وسعت زیاد مراتع و توانایی عظیم در ترسیب کربن و با توجه به نقش کربن آلی ذره‌ای خاک در پایداری و کیفیت خاک و جلوگیری از فرسایش، تا به حال تحقیقات کاربردی محدودی در زمینه توزیع مکانی کربن آلی ذره‌ای در مراتع انجام شده‌است. لذا این مطالعه به منظور مقایسه مدل شبکه عصبی مصنوعی پرسپترون چندلایه و شبکه عصبی تطبیقی-فازی و رگرسیون چندمتغیره جهت تخمین کربن آلی ذره‌ای با استفاده از داده‌های زود یافت خاک و همچنین تعیین مهمترین فاکتورهای موثر بر مقدار کربن آلی ذره‌ای خاک در مراتع خرابه‌سنجی ارومیه در استان آذربایجان غربی انجام گرفته‌است.


مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه با وسعتی برابر ۲۷۱۵ هکتار در شمال غرب ایران، استان آذربایجان غربی و در شهرستان ارومیه واقع شده است. این منطقه در واقع بخشی از حوزه آبخیز رودخانه نازلو و موسوم به زیرحوزه خرابه‌سنجی می‌باشد که در آن آبراهه‌های فصلی متعددی وجود دارند. مختصات جغرافیایی آن شامل ۲۲° ۴۸' ۳۷" الی ۴۷° ۴۵' ۳۷" عرض شمالی تا ۴۴° ۵۵' ۰۷" الی ۴۴° ۵۲' ۰۳" طول شرقی است. حداقل ارتفاع آن ۱۵۷۵ و حداکثر ۲۷۴۵ متر

سپس خاک آمیخته شده به مدت یک ساعت به وسیله شیکر تکان و سپس بر روی الک ۰/۰۵۳ میلیمتری جاری و چندین بار با آب مقطر شستشو داده شد. خاک باقی مانده به یک ظرف آلومینیومی انتقال یافته و تحت دمای ۶۰ درجه سانتیگراد بمدت ۲۴ ساعت خشک شده و سپس آنالیز کربن بر روی این خاک‌ها صورت گرفت (Cambardella & Elliott, 1992).

فراوانی نسبی اندازه ذرات خاک به روش هیدرومتری (Bauder & Gee 1986) و ماده آلی و کربن آلی با استفاده از روش سرد و بر مبنای اکسیداسیون کربن آلی به کمک بیکربنات پتاسیم ($K_2Cr_2O_7$) در محیط کاملاً اسیدی (H_2SO_4) اندازه‌گیری شد (Allison, 1975). در آزمایشگاه مواد آلی ذره‌ای به وسیله تجزیه فیزیکی تعیین شد، بدین ترتیب که ۲۵ گرم از خاک خشک شده با ۱۰۰ میلی‌لیتر سدیم هگزامتافسفات ۵ درصد آمیخته شده،




شکل (۱) موقعیت جغرافیایی منطقه مورد مطالعه
Fig. 1) Geographical position of study area

خروجی است. پارامترهای ورودی در لایه اول و پارامترهای خروجی در لایه سوم قرار دارد (Hecht, 1987). در شبکه پسانشار پیش‌خور ابتدا وزن‌های لایه خروجی تعدیل می‌شوند، زیرا برای هر یک از نورون‌های لایه خارجی، مقدار مطلوب وجود دارد که می‌تواند وزن‌ها را تعدیل کند (Khanna, 1990). پس از محاسبه خطای آموزش توسط شبکه، مقدار آن با مقدار مطلوب مقایسه می‌شود و الگوریتم یادگیری اقدام به بهینه‌سازی مقدار خطای مربوط می‌کند. اگر خطای آموزش از خطای تعیین شده از قبل کمتر باشد، فرآیند یادگیری پایان می‌یابد. ساختار یک شبکه عصبی مصنوعی با تعیین تعداد لایه‌ها، تعداد نورون‌ها در هر لایه، تابع محرک (کنترل‌کننده خروجی هر نورون)، روش آموزش، الگوریتم تصحیح وزن‌ها و نوع مدل، تعیین می‌شود (Caudill, 1987) (شکل ۲).

شبکه عصبی مصنوعی (Artificial Neural Networks)

در شبکه عصبی مصنوعی لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهد. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی‌هایی متناسب با مجموعه جدید داده به کار رود (سبزی‌پرور و بیات‌ورکشی، ۱۳۸۹). پژوهش‌های صورت گرفته نشان می‌دهد که شبکه پرسپترون چندلایه (MLP) پیش‌خور با قانون یادگیری پس انتشار خطا (BPFF)، ساده‌ترین و پرکاربردترین نوع شبکه عصبی است که در خصوص تخمین پارامترهای مجهول مناسب ارزیابی شده است. این نوع شبکه (FFBP) دارای یک لایه ورودی، یک یا چند لایه مخفی و یک لایه



شکل ۲) ساختار شبکه عصبی مورد استفاده به منظور مدل‌سازی کربن آلی ذره‌ای خاک
Fig. 2) Applied structure of neural network for modeling the soil organic carbon

در اینجا: N_i داده نرمال‌سازی شده، $X_{i \min}$ داده اولیه، $X_{i \max}$ بزرگترین داده و $X_{i \min}$ کوچکترین داده است.

پارامترهای آماری مورد استفاده در این مطالعه مجذور میانگین مربعات خطا (RMSE) (رابطه ۲)، ضریب کارایی (CE) (رابطه ۳) و ضریب همبستگی (R) (رابطه ۴) می‌باشد. مقدار مجذور میانگین مربعات خطا بین صفر و یک قرار دارد و مقدار آن هرچه به صفر نزدیکتر باشد، نشان‌گر دقت بالا پیش‌بینی است. شاخص پراکندگی بر حسب درصد می‌باشد و بیان‌گر درصد پراکندگی داده‌های پیش‌بینی‌شده نسبت به مقادیر واقعی می‌باشد که مقدار صفر بیان‌کننده عدم پراکندگی در پیش‌بینی است. همچنین مقدار ضریب همبستگی (R) بین ۱- تا ۱ می‌باشد و مقدار ۱ و ۱- بیان‌کننده پیش‌بینی بدون خطا می‌باشد. در روابط زیر روابط محاسبه نمایه‌های آماری ذکر شده است.

$$CE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)}{\sum_{i=1}^n (O_i - \bar{O}_m)} \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (3)$$

$$R^2 = \frac{\sum_{i=1}^N (O_i - \bar{O}_m)(P_i - \bar{P}_m)}{\left(\sum_{i=1}^N [(O_i - \bar{O}_m)^2] \right)^{0.5} \left(\sum_{i=1}^N [(P_i - \bar{P}_m)^2] \right)^{0.5}} \quad (4)$$

شبکه عصبی تطبیقی-فازی (Adaptive Neuro-Fuzzy Inference System)

شبکه عصبی تطبیقی-فازی از قدرت زبانی سیستم فازی با قدرت عددی یک شبکه عصبی در مدل‌سازی فرآیندهای پیچیده بسیار قدرتمند می‌باشد (نورانی و صالحی، ۱۳۸۷). شبکه عصبی تطبیقی-فازی شبکه‌ای ۵ لایه‌ای متشکل از گره‌ها و کمان اتصال دهنده گره می‌باشد. لایه اول، داده‌های ورودی با درجه عضویت می‌باشد که توسط کاربر مشخص می‌گردد. کلیه عملیات مدل‌سازی در لایه‌های دوم تا چهارم انجام می‌گیرد. لایه آخر خروجی شبکه می‌باشد که اهداف آن حداقل نمودن اختلافات خروجی به‌دست آمده از شبکه و خروجی واقعی است.

ساختار مناسب ANFIS متناسب با داده‌های ورودی، درجه عضویت، قوانین و توابع درجه عضویت، قوانین و توابع درجه عضویت خروجی انتخاب می‌گردد. در این روش از توابع مختلف (ناقوس تعمیم یافته، گوسی نوع یک، گوسی نوع دوم، خطی و چند جمله‌ای) برای فازی-سازی استفاده شد.

قبل از آموزش شبکه عصبی، داده‌های ورودی به آن باید استاندارد شوند. برای استاندارد کردن داده‌ها از رابطه زیر استفاده شده است (معماریان فرد و بیگی هرچگانی، ۱۳۸۹):

$$N_i = \left[\left(\frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \right) \times 0.8 \right] + 0.1 \quad (1)$$

چندمتغیره به روش گام به گام توسط نرم افزار SPSS انجام شد.

نتایج

نتایج آمار توصیفی کربن آلی ذره‌ای و سایر خصوصیات فیزیکی و شیمیایی خاک منطقه مورد مطالعه در جدول (۱) ارائه شده است. نتایج این جدول نشان می‌دهد که کربن آلی ذره‌ای تغییرپذیری نسبتاً زیادی از خود نشان می‌دهد. آزمون نرمال بودن داده‌ها به روش کولموگروف-اسمیرنوف نشان داد که متغیر کربن آلی ذره‌ای دارای توزیع نرمال می‌باشد.

که O_i مقدار مشاهده شده، P_i مقدار پیش‌بینی شده، N تعداد داده‌های مشاهداتی، \bar{O}_m مقدار میانگین مشاهدات و \bar{P}_m مقدار میانگین پیش‌بینی شده است. ۷۰ درصد نمونه‌ها در شبکه عصبی مصنوعی برای آموزش مدل، ۱۵ درصد داده‌ها برای انجام فرآیند اعتبارسنجی مدل و ۱۵ درصد داده‌ها نیز برای آزمون مدل انتخاب گردید. در شبکه عصبی تطبیقی-فازی و رگرسیون چندمتغیره نیز از ۸۵ درصد داده‌ها برای آموزش و ۱۵ درصد داده‌ها برای آزمون انتخاب شد. به منظور آموزش شبکه عصبی، نرم افزار Matlab 7.9 مورد استفاده قرار گرفت. آنالیزهای آماری و رگرسیون

جدول (۱) آمار توصیفی فاکتورهای اندازه‌گیری شده و درصد کربن آلی ذره‌ای در خاک مراتع حوزه خرابه‌سنجی ارومیه
Table 1) Descriptive statistics factors and percentage of particulate organic carbon in pasture soil of Kharabe Sanji region (Urmia)

عوامل خاکی مورد بررسی	تعداد	حداقل	حداکثر	میانگین	انحراف معیار	دامنه تغییرات
کربن آلی ذره ای (%)	60	0.03	0.46	0.21	0.1	0.43
رس (%)	60	14	36	22.80	0.8	22
سیلت (%)	60	6	36	19.13	1.11	30
نیترژن (%)	60	0.04	0.18	0.1	0.005	0.14
وزن مخصوص ظاهری خاک (g/cm^3)	60	1.05	1.90	1.53	0.02	0.85
ماده آلی (%)	60	0.18	1.28	0.5	0.03	1.11
هدایت الکتریکی	60	0.09	0.19	0.13	0.003	0.1
اسیدیته	60	7.72	8.36	8.08	0.02	0.64

نتایج مدل‌سازی رگرسیون چندمتغیره

مدل رگرسیونی چندمتغیره بین کربن آلی ذره‌ای و ویژگی‌های زود یافت خاک در زیر ارائه شده است.

$$Y = 0.007 + 1.781X_1 + 0.193X_2 - 0.150X_3 + 0.004X_4$$

Y: درصد کربن آلی ذره‌ای X_1 : هدایت الکتریکی

X_2 : درصد ماده آلی X_3 : اسیدیته X_4 : درصد رس

شود و خطاها با یکدیگر همبستگی داشته باشند، امکان استفاده از رگرسیون وجود ندارد. به منظور بررسی استقلال خطاها از یکدیگر از آزمون دوربین واتسون استفاده شد. از آنجایی که مقدار آماره دوربین-واتسون (۲/۱) در فاصله ۱/۵ تا ۲/۵ قرار دارد، فرض عدم وجود همبستگی بین خطاها رد نمی‌شود و می‌توان از رگرسیون استفاده کرد. فرض دیگر رگرسیون خطی بررسی همراستایی بین متغیرهای مستقل است. بدین منظور از فاکتور عامل تورم واریانس Variance Inflation Factor

در این تحقیق برای به دست آوردن مدل رگرسیونی خطی چندمتغیره برای کربن آلی ذره‌ای خاک با استفاده از متغیرهای مستقل، شامل: هدایت الکتریکی، اسیدیته، درصد ماده آلی، درصد رس، درصد سیلت، نیترژن و وزن مخصوص ظاهری خاک از روش گام به گام ورود متغیرها استفاده شد. یکی از مفروضاتی که در رگرسیون مدنظر قرار می‌گیرد، استقلال خطاها (تفاوت بین مقدار واقعی و مقادیر پیش‌بینی شده توسط معادله رگرسیون) از یکدیگر است (جدول ۲). در صورتی که فرضیه استقلال خطاها رد

همانطور که در مدل رگرسیونی حاصل مشاهده می‌شود رابطه بین مقدار کربن آلی ذره‌ای خاک با اسیدیته غیر مستقیم می‌باشد. نتایج حاصل از رگرسیون گام به گام نشان داد که از بین عوامل وارد شده برای مدل رگرسیونی، هدایت الکتریکی، درصد ماده آلی، اسیدیته و درصد رس از عوامل تاثیرگذار بر کربن آلی ذره‌ای خاک بودند و سایر ویژگی‌های زود یافت تاثیر معنی‌داری بر کربن آلی ذره‌ای خاک نداشتند. شکل ۳ نشانگر این نکته است که مقادیر مشاهده‌ای و برآوردی در دو مرحله آزمون و آموزش انطباق کمتری با یکدیگر داشته و اختلاف حاصل از برازش نمودارها در قسمت آزمون و آموزش در این نمودار آشکار است.

(VIF)) استفاده شد. متغیرهایی که VIF آنها کمتر از ۱۰ باشد، مشکل همراستایی نخواهند داشت. مقادیر این فاکتور برای متغیرهای مستقل نشان دهنده این است که این متغیر مشکل همراستایی ندارد. از فرضیات دیگر رگرسیون، نرمال بودن متغیر وابسته می‌باشد که به همین منظور از آزمون کولموگروف-اسمیرنوف برای آزمون نرمال بودن استفاده شد. نتایج این تست نشان داد که کربن آلی ذره‌ای خاک دارای توزیع نرمال می‌باشد.

مدل مزبور توانسته است ۱۱ درصد از تغییرات کربن آلی ذره‌ای خاک را در منطقه توجیه نماید. در نهایت حدود ۸۹ درصد از تغییرپذیری کربن آلی ذره‌ای در این منطقه تبیین نگردید که این موضوع به دلیل وجود روابط غیرخطی بین پدیده‌ها می‌باشد که در مدل رگرسیونی در نظر گرفته نمی‌شود (جدول ۳).

جدول ۲) ماتریس همبستگی خصوصیات فیزیکی و شیمیایی خاک در مراتع خرابه‌سنجی ارومیه

Table 2) The correlation matrix of soil physical and chemical properties in the Kharabe Sanji region (Urmia)

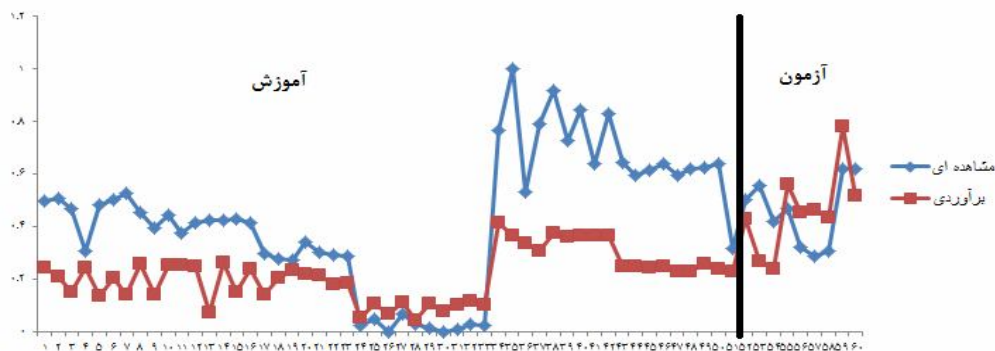
درصد سیلت	درصد ماده آلی	هدایت الکتریکی dS m^{-1}	وزن مخصوص ظاهری g cm^{-3}	درصد نیتروژن	درصد رس	اسیدیته	درصد کربن آلی ذره‌ای
							1
						1	-0.106 ^{ns}
					1	0.174 ^{ns}	0.544 ^{**}
				1	0.564 [*]	0.173 ^{ns}	0.315 ^{**}
			1	-0.307 [*]	-0.227 ^{ns}	0.140 ^{ns}	-0.426 ^{**}
		1	-0.519 [*]	0.358 [*]	0.657 [*]	0.008 ^{ns}	0.621 ^{**}
	1	0.095 ^{ns}	-0.094 ^{ns}	0.432 [*]	0.158 ^{ns}	0.190 ^{ns}	0.501 ^{**}
1	0.363 [*]	0.581 [*]	-0.266 [*]	0.487 [*]	0.737 [*]	0.384 [*]	0.504 ^{**}

** اختلاف معنی‌دار در سطح ۱ درصد، * اختلاف معنی‌دار در سطح ۵ درصد، ^{ns} عدم اختلاف معنی‌دار

جدول ۳) آماره‌های خطا و ضریب تعیین حاصل از اجرای رگرسیون چندمتغیره برای مرحله‌های آموزش و آزمون در برآورد کربن آلی ذره‌ای خاک

Table 3) Error Statistics and coefficient of determination for multivariate regression equations for training and testing phase for the estimation of soil organic carbon

مراحل	CE	RMSE	R ²	R
آموزش	0.70	0.14	0.70	0.84
آزمون	0.41	0.16	0.11	0.26



شکل ۳) برازش مقادیر مشاهداتی و برآوردی با استفاده از رگرسیون خطی چندمتغیره در مرحله آموزش و آزمون به منظور مدل‌سازی کربن آلی ذره‌ای خاک

Fig. 3) Fitting of observation data and estimated values using multivariate linear regression during the training and testing phase for modeling of particulate organic matter carbon

لونبرگ مارکوت با تابع انتقال سیگموئید در مرحله آزمون با $CE=0.65$ ، $RMSE=0.11$ ، $R^2=0.74$ به عنوان بهترین مدل شبکه عصبی مصنوعی انتخاب شد (شکل ۴). تابع انتقال تانژانت هیپربولیک به نسبت تابع سیگموئید ضریب کارایی پایین‌تری دارد و مجذور میانگین مربعات خطای بالای آن به نسبت تابع سیگموئید باعث عدم استفاده از این مدل در مقایسات مورد نظر گردید.

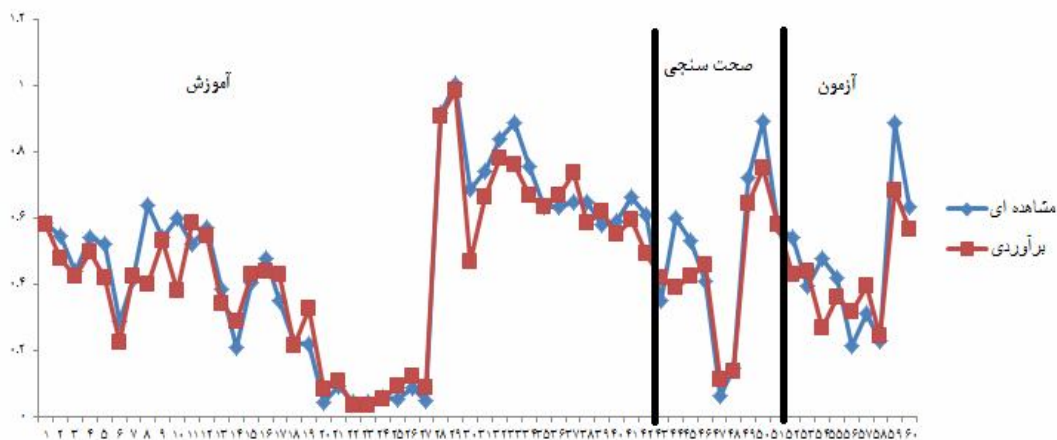
نتایج مدل‌سازی شبکه عصبی مصنوعی

در جدول ۴ آماره‌های خطا ضریب تعیین حاصل از اجرای شبکه عصبی مصنوعی (ANN) برای سه مرحله آموزش، صحت‌سنجی و آزمایش در برآورد کربن آلی ذره‌ای خاک ارائه گردیده است. ساختار مورد استفاده در این تحقیق، شامل شش لایه ورودی، هفت لایه پنهان و یک لایه خروجی است. شبکه ۶-۷-۱ با قانون یادگیری

جدول ۴) آماره‌های خطا و ضریب تعیین حاصل از اجرای شبکه عصبی مصنوعی برای مرحله های آموزش، صحت‌سنجی و آزمایش در برآورد کربن آلی ذره‌ای خاک

Table 4) Error Statistics and coefficient of determination for artificial neural networks in the training, the accuracy and validation phases for estimating soil particulate organic carbon

CE	RMSE	R ²	R	مراحل	آرایش	تابع انتقال	قانون یادگیری	نوع شبکه عصبی
0.90	0.08	0.93	0.95	آموزش				پرسپترون چند لایه
0.83	0.10	0.88	0.94	صحت سنجی			لونبرگ مارکوت	
0.65	0.11	0.74	0.86	آزمون	6-7-1	سیگموئید		
0.86	0.09	0.88	0.93	آموزش				لونبرگ مارکوت
0.79	0.11	0.85	0.92	صحت سنجی			تانژانت هیپربولیک	
0.59	0.12	0.66	0.81	آزمون	6-7-1			



شکل ۴) برازش مقادیر مشاهداتی و برآوردی با استفاده از شبکه عصبی مصنوعی در مرحله آموزش و آزمون به منظور مدل‌سازی کربن آلی ذره‌ای خاک در مراتع

Fig. 4) Fitting the observed and estimated values using artificial neural networks during the training and testing phase for modeling of soil particulate organic carbon in the pasture

مجذور میانگین مربعات خطا در تابع گوسی نوع یک بیشترین و در تابع ناقوس تعمیم‌یافته کمترین مقدار را داشت، همچنین ضریب کارایی تابع گوسی نوع یک در مقایسه با سایر توابع کمتر و تابع ناقوس تعمیم‌یافته از ضریب کارایی بیشتری برخوردار بود. نتایج حاصل از شکل ۵ بیانگر این نکته است که انطباق حاصل از داده‌های مشاهداتی و برآوردی کربن آلی ذره‌ای خاک در مدل شبکه عصبی تطبیقی-فازی نسبت به سایر مدل‌های مورد استفاده حداکثر می‌باشد.

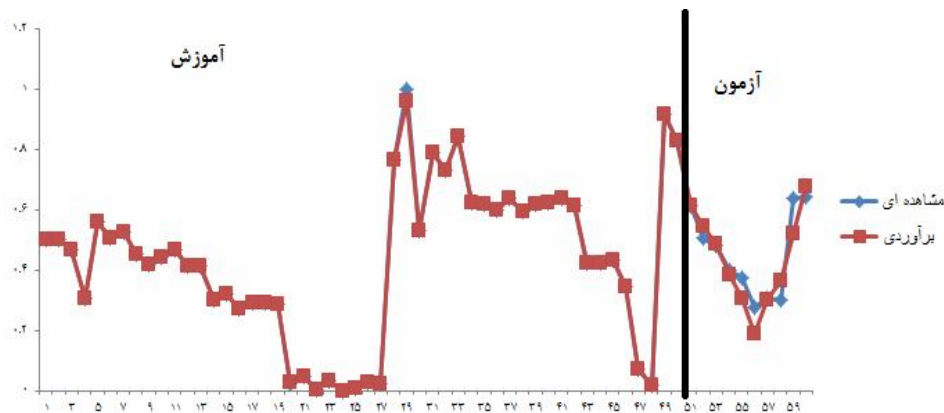
نتایج سیستم استنتاج تطبیقی عصبی فازی (ANFIS)

کاربرد مدل ANFIS با تابع ناقوس تعمیم‌یافته $CE=0/79$ و $RMSE=0/06$ ، $R^2=0/83$ نسبت به سایر توابع، از خود نشان داد. در جدول ۵ نتایج حاصل از این سیستم استنتاج تطبیقی عصبی-فازی با ساختار ذکر شده در برآورد کربن آلی ذره‌ای خاک به همراه داده‌های آنالیز مجذور میانگین مربعات خطا و ضریب کارایی ارائه گردیده است. نتایج نشان داد که

جدول ۵) نتایج شبکه عصبی تطبیقی فازی جهت برآورد کربن آلی ذره‌ای خاک در مراتع خرابه‌سنجی ارومیه

Table 5) Results of the adaptive neuro-fuzzy Inference System to estimate soil particulate organic carbon in the rangelands Kharabe Sanji of Urmia

CE	RMSE	R ²	R	مراحل	نوع تابع عضویت
0.997	0.014	0.999	0.999	آموزش	ناقوس تعمیم یافته (Gbellmf)
0.791	0.060	0.834	0.913	آزمون	
0.961	0.050	0.962	0.980	آموزش	گوسی نوع یک (gaussmf)
0.14	0.611	0.771	0.878	آزمون	
0.999	0.002	0.999	0.999	آموزش	گوسی نوع دوم (gauss2mf)
0.177	0.119	0.548	0.740	آزمون	
0.989	0.499	0.989	0.994	آموزش	مثلثی (Trimf)
0.629	0.064	0.790	0.888	آزمون	
0.997	0.010	0.997	0.998	آموزش	چندجمله‌ای (Pimf)
0.513	0.080	0.340	0.583	آزمون	



شکل ۵) برازش مقادیر مشاهداتی و برآوردی با استفاده از شبکه عصبی تطبیقی فازی در مرحله آموزش و آزمون به منظور مدل‌سازی کربن آلی ذره ای خاک در مراتع خرابه‌سنجی ارومیه

Fig. 5) Fitting the observed and estimated values using adaptive neuro-fuzzy inference system during the training and testing phase for the modeling of soil particulate organic carbon in the pastures of Kharabe Sanji of Urmia

بحث و نتیجه گیری

با توجه به نتایج بدست آمده، روش‌های شبکه عصبی تطبیقی-فازی با نوع تابع ناقوس تعمیم یافته ($R^2=0/83$)، تابع سیگموئید ($R^2=0/74$) و رگرسیون چندمتغیره ($R^2=0/11$) به ترتیب به عنوان بهترین روش برآورد کربن آلی ذره‌ای تعیین گردید. دلیل این امر در نظر گرفتن روابط غیرخطی بین پدیده‌ها در روش شبکه عصبی مصنوعی می‌تواند باشد. مدل توسعه یافته شبکه عصبی تطبیقی-فازی برای پیش‌بینی کربن آلی ذره‌ای خاک در منطقه مورد مطالعه ۸۳ درصد از تغییرپذیری در سطح ویژگی‌های زودیافت را توجیه نمود و در نهایت حدود ۱۷ درصد از تغییرپذیری کربن آلی ذره‌ای خاک در این منطقه تبیین نگردید. که این موضوع تا اندازه زیادی به دلیل در نظر نگرفتن و عدم اندازه‌گیری پارامترهای مدیریتی و به ویژه عوامل فیزیوگرافی مثل شیب و ارتفاع می‌باشد. در همین ارتباط انگلبای و کراو (۲۰۰۱) پس از مقایسه مدل‌های رگرسیونی و شبکه عصبی مصنوعی در برآورد کربن آلی ذره‌ای خاک، با توجه به مقدار مجموع مربعات خطا (SSE) که در مدل شبکه عصبی و مدل رگرسیونی چندمتغیره به ترتیب ۵/۴۳ و ۶/۲۳ بودند، به برتری مدل شبکه عصبی پی بردند. مدل‌های شبکه عصبی به دلیل در نظر گرفتن روابط غیرخطی موجود میان ویژگی‌های زودیافت خاک و کربن آلی ذره‌ای و به دنبال آن افزایش

دقت در برآورد پیش‌بینی‌ها می‌تواند جایگزین مناسبی برای مدل‌های مرسوم رگرسیونی در مدل‌سازی کربن آلی ذره‌ای باشد. پیرامون ارتباط فاکتور کربن آلی ذره‌ای با ویژگی‌های زودیافت خاک تا کنون تحقیق خاصی صورت نگرفته است. پژوهش‌های صورت گرفته در زمینه ارتباط کربن آلی کل با داده‌های آنالیز سطح زمین از گستردگی فراوانی برخوردار است. که از آن جمله می‌توان به تحقیق ایوبی و علیزاده (۱۳۸۵) اشاره کرد که از مدل رگرسیون خطی چندمتغیره برای برآورد کربن آلی بر اساس ویژگی‌های پستی و بلندی در ۳ واحد سنگ‌شناسی استفاده کردند و به این نتیجه رسیدند که این مدل می‌تواند ۲۸ تا ۳۵ درصد از تغییرات کربن آلی خاک را در منطقه توجیه نماید و همچنین نتایج نشان داد که فاکتورهای پستی و بلندی مهم که با کربن آلی ارتباط داشتند و در مدل رگرسیونی نیز وارد شده، به طور عمده شامل شیب و جهت آن، ارتفاع، شاخص قدرت جریان و شاخص حمل رسوب بوده است. در همین ارتباط سامفلث و داتمن (۲۰۰۸) از داده‌های عوارض زمین برای پیش‌بینی توزیع خصوصیات خاک از جمله کربن آلی خاک استفاده کردند. تامسون و همکاران (۲۰۰۵) نیز با مدل رگرسیونی زمین نما توانستند ۷۰ درصد از تغییرات کربن آلی را پیش‌بینی کنند. مقایسه بین مدل‌های رگرسیونی، شبکه عصبی و شبکه عصبی-فازی نشان داد که مقادیر برآورد شده به وسیله شبکه عصبی تطبیقی-فازی دارای بیشترین دقت و روش رگرسیونی دارای کمترین دقت بود.

نموده و این مدل را دارای صحت و دقت بالا معرفی کرده‌اند.

علت تفاوت بین عملکرد بهتر شبکه‌های عصبی در مقایسه با روش‌های آماری را می‌توان در قابلیت تخمین و پیش‌بینی شبکه‌های عصبی مصنوعی برای تقریب غیرخطی با حجم کم داده‌ها جستجو نمود. این در حالی است که عملکرد و دقت روش‌های رگرسیونی به شدت از حجم کم نمونه‌ها تبعیت می‌کند و حجم کم نمونه‌ها می‌تواند عامل محدودیت مدل‌های آماری گردد (Norani & Salehi, 2008). نتایج کلی پژوهش نشان می‌دهد که در عرصه‌های طبیعی که مشکلات خاص نمونه‌برداری، هزینه‌های تجزیه و آنالیز نمونه‌ها در سطح زیاد وجود دارد، می‌توان از روش‌های هوش مصنوعی و به کمک داده‌های زودیافت برای تخمین کربن آلی ذره‌ای سود جست. انتظار می‌رود در مطالعات آتی جهت ایجاد مدلی معتبرتر که تغییرپذیری بیشتری از مقدار کربن آلی ذره‌ای خاک در این منطقه را پیش‌بینی نماید، از نمونه‌برداری متراکم‌تر و تلفیق متغیرهای فیزیوگرافی و خاکی موثر بر کربن آلی ذره‌ای به نتایج رضایت بخش‌تری دست یافت.

سبزی‌پرور و بیات‌ورکشی (۱۳۸۹) نتیجه گرفتند که دقت روش استنتاج تطبیقی عصبی-فازی، ۴ درصد بیشتر از روش آماری رگرسیون است. نتایج تحقیق حاضر نشان داد که مدل شبکه عصبی تطبیقی-فازی دارای دقت نسبی بیشتری نسبت به مدل شبکه عصبی مصنوعی در برآورد کربن آلی ذره‌ای خاک می‌باشد. نتایج حاصل از رابطه رگرسیونی در این تحقیق نشان داد که هدایت الکتریکی از مهمترین عواملی بود که ارتباط با کربن آلی ذره‌ای خاک داشت. نتایج اسکالبرگ (۱۹۹۱) پیرامون تغییرات pH در لایه‌های مختلف خاک حاکی از آن بود که pH می‌تواند ارتباط معنی‌داری با کربن آلی خاک داشته باشد، در حالی که زاهدی (۱۹۹۸) ارتباط معنی‌داری بین کربن و pH خاک مشاهده نکرد. مقایسه نتایج روش‌های آماری و نتایج شبکه‌های عصبی برتری مدل‌های شبکه عصبی را در برآورد کربن آلی ذره‌ای بیان می‌کند. سایر محققین مانند مقدم‌نیا و همکاران (۲۰۰۹)؛ بازارسرن و همکاران (۲۰۰۳)؛ بیات‌ورکشی و همکاران (۲۰۰۹)؛ پارسافر و معروفی (۲۰۱۱) نیز در مطالعات خود به این موضوع اشاره

References

- Allison LE. 1975. Organic carbon. In: Black CA, Evans DD, White JL, Ensminger LE, Clark FE. (Eds.), *Methods of soil analysis, Part 2, Chemical and microbiological properties*. American Society of Agronomy, Madison. 1367p.
- Auobi Sh and Alizadeh MH. 2006. Soil surface attributes prediction using digital topographic model (Case Study: part of Mehr Watershed, Sabzevar, Khorasan Province). *Science and Technology of Agriculture and Natural Resources*, 10 (2): 85-96.
- Balan B, Mohaghegh S and Ameri S. 1995. State- of- Art- in permeability determination from well log data: Part 1- A comparative study, *Model development*. SPE. 30978: 17-25.
- Bazartseren B, Hildebrandt G and Holz K. 2003. Short-term water level prediction using neural networks and neuro-fuzzy approach. *Neuro computing*, 55: 439-450.
- Baiat varkesh M, Zare abiane H, Marofi S, Sabziparvar A and Soltani F. 2009. Simulates daily crop reference evapotranspiration using artificial intelligence methods and compared with experimental measurements of having cold semi-arid climate, Hamedan. *Journal of Soil and Water Conservation Research*, 16 (4): 79-83.
- Blake GR and Hartge KH. 1986. Bulk density. P 363-375, In: Klute, A. *Methods of soil analysis*. Part 1. 2nd Ed. Agron. Monogr. 9. ASA. Madison. WI.
- Cambardella CA and Elliott ET. 1992. Particulate soil organic matter changes across a grassland cultivation sequence. *American Journal of Soil Science*, 56: 777-783.
- Caudill M. 1987. *Neural networks primer: Part I, AI Expert*.
- Fajri F. 2009. *The report on rangeland & vegetation cover feasibility studies in the kharabeh-sanji basin*. Faculty of Natural Resources. University of Urmia.
- Gee GW and Bauder JW. 1986. Particle size analysis. 383-411p, In: *Methods of soil analysis*. Part 1. 2nd Ed. Klute, A. Agron. Monogr. 9. ASA. Madison. WI.
- Handayani IP, Coyne MS, Barton C and Workman S. 2008. Soil carbon pools and aggregation following land restoration: Bernheim Forest. *Ken. J. Environ. Monitor. Restor.* 4: 11-28.

- Haynes RJ. 2005. Labile organic matter fraction as central components of the quality of agricultural soils: An overview. *Adv. Agron.* 85: 221-268.
- Hecht R. 1987. Kolmogorov mapping, neural network existence theorem. 1st IEEE ICNN, 3. San Diego.
- Holmberg M, Forsius M, Starr M and Huttunen M. 2006. An application of artificial neural networks to carbon, nitrogen and phosphorus concentration in three boreal streams and impacts of climate change. *International Society for Ecological Information 3rd Conference*. Grottaferrata, Roma, Italy. 195: 51-60.
- Ingleby HR and Crowe TG. 2001. Neural network models for predicting organic matter content in Saskatchewan soils. *Canadian Biosystems Engineering*, 43:71-75.
- Khanna T. 1990. *Foundations of neural networks*, Addison-Wesley Pub. Co. USA .
- Merdun H, Ozer T, 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 Tillage Research*, 90: 108-116.
- Memarian Fard M and Beigi Hrchgany H. 2009. Comparison of artificial neural network models and regression transfer functions to predict soil exchange capacity in Chaharmahal and Bakhtiari Province. *Journal of Soil and Water*, 4: 90-99.
- Moghaddamnia A, Ghafari Gousheh M, Piri J, Amin S and Han D. 2009. Evaporation estimation using artificial neural networks and adaptive neurofuzzy inference system techniques. *Advances in Water Resources*, 32: 89-97.
- Norani V and Salehi K. 2008. Rainfall-runoff modeling using adaptive fuzzy neural network and comparison with neural network and fuzzy inference. *National Congress on Civil Engineering, Tehran University. Proceedings of the Fourth National Congress of Civil Engineering*.
- Parasurman K, Elshorbagy A and Si B. 2006. Estimating saturated hydraulic conductivity in spatially variable fields using neural network in Ensembles. *SSSA. J.* 70: 1851-1859.
- Parton WJ, Schmel DS, Cole CV and Ojima DS. 1987. Analysis of factors controlling soil organic matter levels in Great Plains grasslands. *A. J. Soil Sci.* 51: 1173-1179.
- Parsafar NA and Marofi S. 2011. Estimated temperatures at depths using network neural networks Fuzzy (case study: Kermanshah region). *J. Soil and Water Sci.* 21(3): 21-22.
- Pilevari A, Auobi Sh and Khademi H. 2010. Comparison of artificial neural network and multiple linear regression analysis to predict soil organic carbon data to the ground. *J. Soil and Water*, 24 (6): 1151-1163.
- Sabzi parvar A and Beiatorkeshi M. 2010. Assess the accuracy of fuzzy artificial neural network, neurotropic solar radiation simulation. *Iranian J. Physic. Res.* 4(10): 347-536.
- Sinowski W and Auerswald K. 1999. Using relief parameters in a discriminate analysis to stratify geological areas with different spatial variability of soil properties. *Geoderma*, 89: 113-128.
- Skullberg U. 1991. Seasonal Variation of pH H₂O and pH CaCl₂ in centimeter- layers of Mor Humus in a Picea Abies (L.) Karst stand. *Sweden University of Agri Sci, Dep. Forest Site Res.*
- Somararatne S, Seneviratne G and Coomaraswamy U. 2005. Prediction of soil organic carbon across different landuse patterns: A neural network approach. *SSSA. J.* 69: 1580-1589.
- Spaccini R, Mbagwu JC, Igwe CA, Conte P and Piccolo A. 2004. Carbohydrate and aggregation in lowland soil of Nigeria as influenced by organic input. *Soil and Tillage Res.* 75: 161-172.
- Sumfleth K and Duttman R. 2008. Prediction of soil property distribution in paddy soil landscapes using terrain data and satellite information as indicators. *Eco. Indicators*, 8: 485-501.
- Thompson JA and Kolka RK. 2005. Soil carbon storage estimation in a forested watershed using quantitative soil-landscape modeling. *SSSA. J.* 69: 1086-1093.
- Zahedi Gh. 1998. *Relation between vegetation and soil characteristics in a mixed hard wood stand*. Academic press, Ghent University (Belgium), 319p.
- Zevebergen LW and Thorne CR. 1987. Quantitative analysis of land surface topography. *Earth Surface Processes Landforms*, 12: 47-56.

Evaluation of Artificial Neural Network (ANN), Adaptive Neuro-Fuzzy Inference System (ANFIS) and Regression Models in Prediction of Particulate Organic Matter-Carbon (POM-C) in the Rangelands Kharabe Sanji of Urmia

B. Bahrami¹, Gh.A. Dianati Tilaki^{2*}, S.Kh.Beigi³, S. Janizadeh³, J. Moetamedi⁴

1- Graduate Student of Range Management, Faculty of Natural Resources, Tarbiat Modares University

2- Associate Professor, Faculty of Natural Resources, Tarbiat Modares University

3- M.sc. Student of Watershed Management, Faculty of Natural Resources, Tarbiat Modares University

4- Assistant Professor, Faculty of Natural Resources, Urmia University

* Corresponding author: dianatitilaki@yahoo.com

Received: 21.02.2013

Accepted: 27.03.2013

Abstract

Soil organic carbon has favorable effects on the chemical, physical and thermal properties of the soil as well as on the biological activities in the soil. Particulate organic matter-carbon (POM-C) is one of the important unstable elements in the soil organic matter has a considerable role in soil quality and rangeland management. In this research, in order to exact estimate of POM-C using ANN, ANFIS, Regression models were developed. Towards this attempt, 60 soil samples were taken from the depth of 0-30 cm of the soil within 60 quadrates of 1m² of located along 6 transects of 100m in the rangelands Kharabeh Sangi of Urmia. Soil properties (Nitrogen, clay, silt, organic carbon, pH, EC, apparent specific weight of soil) were measured. Statistic indicators RMSE, CE were used for performance evaluation of the models. The results showed RMSE and CE were calculated 0.16 and 0.41(in Regression Model), 0.11 and 0.65(in Artificial Neural Network Model), 0.06 and 0.79 (in Adaptive Neuro-Fuzzy Inference System Model), respectively. Also Adaptive Neuro-Fuzzy Inference System Model is considered as a strong tool in prediction of POM-C compared with Multivariate Linear Regression and Artificial Neural Network Models in the rangelands Kharabeh Sanji of Urmia.

Key words: soil properties, organic carbon, modeling, efficiency coefficient