

کاربرد مقایسه‌ای رگرسیون خطی چندگانه و شبکه‌های عصبی مصنوعی برای شبیه‌سازی اثرات عوامل توپوگرافی بر تغییرات کربن آلی خاک

سمیه مقیمی^{۱*}، یحیی پرویزی^۲، محمدحسین مهدیان^۳ و محمدحسن مسیح‌آبادی^۴
^۱ دانشجوی دکتری، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، ^۲ استادیار، مرکز تحقیقات کشاورزی و منابع طبیعی کرمانشاه، ^۳ استاد، سازمان تحقیقات، آموزش و ترویج کشاورزی و ^۴ استادیار، دانشگاه آزاد اسلامی واحد علوم و تحقیقات

تاریخ پذیرش: ۱۳۹۲/۱۱/۰۷

تاریخ دریافت: ۱۳۹۲/۰۷/۲۷

چکیده

کربن آلی خاک یکی از مهم‌ترین ویژگی‌های خاک بوده و هرگونه تغییر در مقدار و ترکیب آن بر اکثر ویژگی‌های شیمیایی، زیستی و فیزیکی خاک تاثیرگذار است. بهبود کربن آلی خاک سبب بهبود ساختمان خاک، کیفیت و کمیت رطوبت در حوضه، کیفیت هوا، افزایش سطح عناصر غذایی خاک و در نتیجه کیفیت و کمیت محصول، جلوگیری از تخریب و فرسایش خاک و احیا خاک و زیست بوم خواهد شد. عوامل متعددی از جمله عوامل اقلیمی، توپوگرافی و مدیریتی بر مقدار کربن آلی خاک تاثیر می‌گذارند. در مقیاس کوچک محلی مانند مرتع مورد مطالعه، عامل اقلیم تنوع قابل ملاحظه‌ای نداشته و عوامل توپوگرافی بر تغییرات کربن آلی خاک، بسیار اثرگذارند. لذا، هدف این پژوهش، برآورد تاثیر متغیرهای توپوگرافی ارتفاع، جهت شیب، درصد شیب، سایه روشن و انحنای بر مقدار کربن آلی خاک در اراضی مرتعی واقع در حوضه مرگ استان کرمانشاه است. به این منظور، برآورد کربن آلی خاک با دو روش رگرسیون چندمتغیره خطی (MLR) و شبکه‌های عصبی مصنوعی (ANN) انجام شد. بر طبق نتایج، مدل MLR، توانست ۵۳ درصد و مدل ANN، ۷۷ درصد از تغییرات کربن آلی خاک را پیش‌بینی کند. در روش MLR، مقدار RMSE و MBE به ترتیب ۰/۴ و صفر در روش ANN، مقادیر RMSE و MBE به ترتیب ۰/۱۶ و ۰/۰۳ محاسبه شد. نتایج بررسی‌ها نشان داد، شبکه عصبی مصنوعی با آرایش ۱-۹-۵ و تابع فعال‌سازی تانژانت هایپربولیک در لایه پنهان، نسبت به روش رگرسیون خطی چندگانه، دارای دقت و صحت بالاتری است. طبق نتایج شبکه عصبی مصنوعی، از بین متغیرهای مورد بررسی، به ترتیب ارتفاع با ۰/۷۹، سایه روشن با ۰/۶۴ و درصد شیب با ۰/۲۸ ضریب تاثیر، در تغییرات ذخایر کربن آلی خاک در این منطقه بیشترین سهم را دارند.

واژه‌های کلیدی: ارتفاع، انحنای، جهت شیب، درصدشیب، سایه روشن

مقدمه

زیست بوم‌ها قادر به ذخیره مقادیر زیادی کربن در زی‌توده گیاهی و خاک هستند (Jal, ۲۰۰۱). کربن آلی خاک شاخص بسیار مهمی از وضعیت خاک از نظر تولید، باروی و کیفیت فیزیکی، شیمیائی و زیستی

گرمایش جهانی در اثر افزایش دی اکسید کربن، توجه جامعه بشری را به جنگل‌ها و مراتع به‌عنوان محل ذخیره کربن جلب کرده است، چرا که این

خاک (Crow و Ingleby، ۲۰۰۱)، ظرفیت تبادل کاتیونی (Sarmadian و Taghizadeh Mehrjardi، ۲۰۰۸؛ Keshavarzi و Sarmadian، ۲۰۱۰)، هدایت الکتریکی خاک (Namdar-Khojasteh و همکاران، ۲۰۱۰)، مقاومت برشی خاک (Besalatpour و همکاران، ۲۰۱۲) و تخمین نقاط شاخص منحنی رطوبتی تعدادی از خاک‌های آهکی به کمک پارامترهای زودیافت خاک (Belyani و همکاران، ۲۰۱۲)، به کار گرفته شده است.

به منظور بررسی متغیرهای کنترل کننده مقدار کربن آلی خاک، Parvizi و همکاران (۲۰۱۰a)، از روش‌های تحلیل تفکیک اعتباری و شبکه عصبی مصنوعی استفاده نمودند. شبکه عصبی مصنوعی و تحلیل تفکیک اعتباری به ترتیب قادر به توضیح ۷۰ و ۶۵ درصد تغییرات کربن آلی خاک هستند و مدل شبکه عصبی هفت درصد توان برآورد بیشتری دارد. طبق نتایج، هر دو روش توان بالایی در برآورد تغییرات کربن آلی خاک دارند.

در پژوهش دیگری، Parvizi و همکاران (۲۰۱۰b)، فاکتورهای مربوط به ویژگی‌های خاک، اقلیم و هندسه زمین را بر روی ذخیره کربن خاک در کاربری‌های مختلف مورد بررسی قرار دادند. نتایج بررسی حاکی از این است که شبکه عصبی مصنوعی با آرایش ۳۱-۲-۱ با قدرت برآورد بالایی، قادر به توضیح ۷۶ درصد از تغییرات کربن آلی خاک است. از بین متغیرهای فیزیکی، جهت شیب و نوع آب و هوا در پیش بینی کربن آلی خاک تاثیر بیشتری دارند. تحلیل دقت آنالیز حساسیت بیانگر این موضوع است که افزودن تعداد بیشتری از متغیرهای فیزیکی به مدل تاثیر قابل ملاحظه‌ای در افزایش قدرت برآورد مدل نداشته و به منظور بالا بردن قدرت برآورد، لازم است که فعالیت‌های مدیریتی به‌ویژه شخم، تناوب، بقایای گیاهی و مدیریت چرا مورد توجه قرار گیرد.

برای بررسی توانایی فناوری سنجش از راه دور در تخمین کربن آلی خاک، Ayoubi و همکاران (۲۰۱۱)، از روش‌های شبکه عصبی مصنوعی و رگرسیون خطی چندگانه در دو سایت جنگل و مرتع استفاده نمودند. از داده‌های سنجش از دور ماهواره لندست ETM باندهای یک، دو، پنج، هفت و ترکیب باند سه و چهار

است. بهبود کربن آلی خاک علاوه بر آن که باعث کاهش گاز کربنیک اتمسفری و در نتیجه اصلاح گرمایش زمین می‌شود، سبب ارتقاء کیفیت و کمیت آب در حوضه، بهبود کیفیت هوا، افزایش کمیت کیفیت محصول، امنیت غذایی، حفاظت خاک و اصلاح اراضی تخریب یافته، تصفیه آلاینده‌ها، تسهیل انتقال و ذخیره آب و املاح و احیاء خاک و زیست بوم‌ها خواهد شد.

با توجه به طیف وسیع کارکردها و اهمیت در حفظ محیط زیست و سلامت زیست بوم، کربن آلی خاک نقشی غیرقابل جایگزین دارد (Parvizi و همکاران، ۲۰۱۰). کربن آلی نقش بسیار مهمی در کشاورزی و مدیریت پایدار خاک‌ها دارد و کیفیت و پایداری زیست بوم را به‌ویژه در مناطق نیمه‌خشک تضمین می‌کند (Parvizi و همکاران، ۲۰۱۰a). زیست بوم‌های مرتعی قابلیت بالایی در ترسیب و ذخیره کربن دارند. با وجود این که مقدار ذخیره کربن در مراتع در واحد سطح ناچیز است، ولی به دلیل وسعت زیاد آن در کل جهان، این اراضی پتانسیل بالایی برای ذخیره کربن خاک دارند (Schuman و همکاران، ۲۰۰۲).

عوامل بسیاری مانند توپوگرافی، کاربری اراضی، نوع خاک، مدیریت اراضی و پوشش گیاهی تغییرات مکانی کربن آلی را در مقیاس‌های مختلف کنترل می‌کند. توپوگرافی یکی از عوامل کلیدی تشکیل خاک بوده و تاثیر آن روی کربن خاک در مطالعات مختلف مورد بررسی قرار گرفته است (Senthilkumar و همکاران، ۲۰۰۹). در سال‌های اخیر، پژوهش‌های زیادی برای تعیین تغییرات مکانی کربن آلی خاک در جهان انجام شده که نتایج آن بیانگر این نکته است که در مقیاس جهانی، تنوع اقلیم اولین عامل کنترل کننده میزان کربن آلی خاک و سرعت چرخه آن بوده و توپوگرافی دومین عامل کنترل کننده در یک منطقه مشخص می‌باشد (Wang و همکاران، ۲۰۰۹).

در بررسی مقدار کربن آلی خاک، علاوه بر روش‌های آماری، از روش‌های مختلفی نظیر شبکه عصبی مصنوعی نیز می‌توان بهره گرفت. امروزه استفاده از شبکه‌های عصبی در علوم خاک رواج و گسترش پیدا کرده و در تخمین ویژگی‌هایی نظیر کربن آلی

چندگانه و شبکه عصبی مصنوعی، مقدار کربن آلی بر اساس متغیرهای توپوگرافی یادشده، برآورد شد. همچنین، علاوه بر شناسایی، اولویت‌بندی مهم‌ترین فاکتورهای توپوگرافی موثر در مقدار کربن آلی خاک نیز مد نظر قرار گرفت.

مواد و روش‌ها

منطقه مورد پژوهش: در این پژوهش، بخشی از اراضی مرتعی در حوزه آبخیز مرگ^۳ واقع در استان کرمانشاه، انتخاب شد. این سایت که با وسعت ۲۰ هکتار در موقعیت کوهستان قرار دارد، دارای ارتفاع متوسط ۱۶۶۷ متر بوده و در محدوده طول جغرافیایی ۶۹۳۹۰۰ تا ۶۹۴۵۰۰ متر و عرض ۳۷۶۹۹۰۰ تا ۳۷۷۰۵۰۰ متر، واقع شده است. در حوزه آبخیز مورد پژوهش، دمای متوسط سالیانه ۱۴/۱ درجه سانتی-گراد، سردترین و گرم‌ترین ماه‌های سال، دی ماه و مرداد ماه به ترتیب با دماهای ۱/۴ و ۲۷/۲ درجه سانتی‌گراد بوده و میانگین بارندگی سالیانه ۴۵۸ میلی‌متر است. بر اساس پردازش اطلاعات ایستگاه هواشناسی سینوپتیک کرمانشاه به وسیله نرم افزار نیوهال، رژیم رطوبتی خاک زریک و رژیم حرارتی خاک، ترمیک تعیین شد (Fatehi, ۲۰۰۸). شکل ۱ موقعیت حوضه مورد مطالعه را در سطح ایران و استان کرمانشاه، نشان می‌دهد.

نمونه برداری: به منظور بررسی وضعیت ذخیره کربن، شبکه نمونه‌برداری منظمی به روش سیستماتیک با گام‌های ۱۰۰ متری طراحی شد. در این رابطه ابتدا، نقشه توپوگرافی سایت مرتع مورد مطالعه با تغییرات توپوگرافی مناسب انتخاب شد. سپس، تعداد نقاط نمونه‌برداری با توجه به مساحت سایت و تغییرپذیری توپوگرافی، در یک شبکه منظم طراحی شد. نقاط تقاطع شبکه به عنوان نقاط نمونه‌برداری، روی نقشه منتقل شد.

در مراجعه به عرصه، بر اساس موقعیت جغرافیایی معین شده در شبکه، محل نقاط نمونه‌برداری با استفاده از سیستم موقعیت‌یاب جهانی (GPS)، مشخص شد و نمونه‌برداری از عمق صفر تا ۳۰ سانتی-

برای محاسبه ضریب NDVI در هر دو سایت استفاده شد. نتایج این پژوهش موید این است که باندهای یک، دو و NDVI، مهم‌ترین فاکتورهای موثر در برآورد تغییرپذیری کربن آلی در دو سایت جنگل و مرتع، می‌باشد. طبق نتایج، روش شبکه عصبی نسبت به روش رگرسیون چندگانه خطی در سایت جنگل ۱۵ درصد و در سایت مرتع ۳۶ درصد قدرت تخمین بالاتری دارد.

طی پژوهشی، Falahatkar و همکاران (۲۰۱۲)، با تهیه نقشه DEM منطقه با روش‌های آمار کلاسیک به بررسی تاثیر شیب، جهت شیب، عمق خاک و ارتفاع بر روی مقدار کربن آلی خاک پرداختند. بین طبقه‌های مختلف شیب و همچنین، جهت شیب با مقدار ماده آلی خاک تفاوت معنی‌داری مشاهده نشد، ولی دانسیته کربن آلی خاک در ارتفاع‌های مختلف دارای تفاوت معنی‌داری بود.

ذخیره کربن در خاک باید در مقیاس‌های متفاوت مزرعه‌ای، محلی، منطقه‌ای و جهانی مورد بررسی قرار گیرد. در مقیاس‌های بزرگ مهم‌ترین عامل موثر در تغییرات کربن آلی خاک، اقلیم است. در مقیاس‌های کوچک محلی مانند مرتع مورد پژوهش، عامل اقلیم تنوع قابل ملاحظه‌ای نداشته و عوامل توپوگرافی بر تغییرات کربن آلی خاک اثرگذارند. همچنین، توپوگرافی در تغییرات اقلیم محلی^۱ و خرد اقلیم^۲ در مقیاس مزرعه، محلی و حتی منطقه‌ای، می‌تواند موثر باشد.

با وجود این‌که با روش‌ها و برنامه‌های مختلف، تغییرات کربن خاک در اثر عوامل مختلف مورد بررسی قرار گرفته، ولی لزوم پژوهش‌های بیشتر به منظور دستیابی به راه‌کارهای علمی، قابل قبول و عملی به منظور کمک به حل معضل گرمایش زمین با افزایش ذخیره دی‌اکسید کربن در خاک و تعدیل انتشار آن به اتمسفر، همچنان حایز اهمیت است.

در این پژوهش، تاثیر متغیرهای توپوگرافی نظیر ارتفاع، شیب، جهت شیب، سایه روشن و انحنای بر مقدار کربن آلی خاک، در نمونه‌های برداشت شده از اراضی مرتعی واقع در حوضه مرگ در استان کرمانشاه، بررسی شد. سپس، با روش‌های رگرسیون خطی

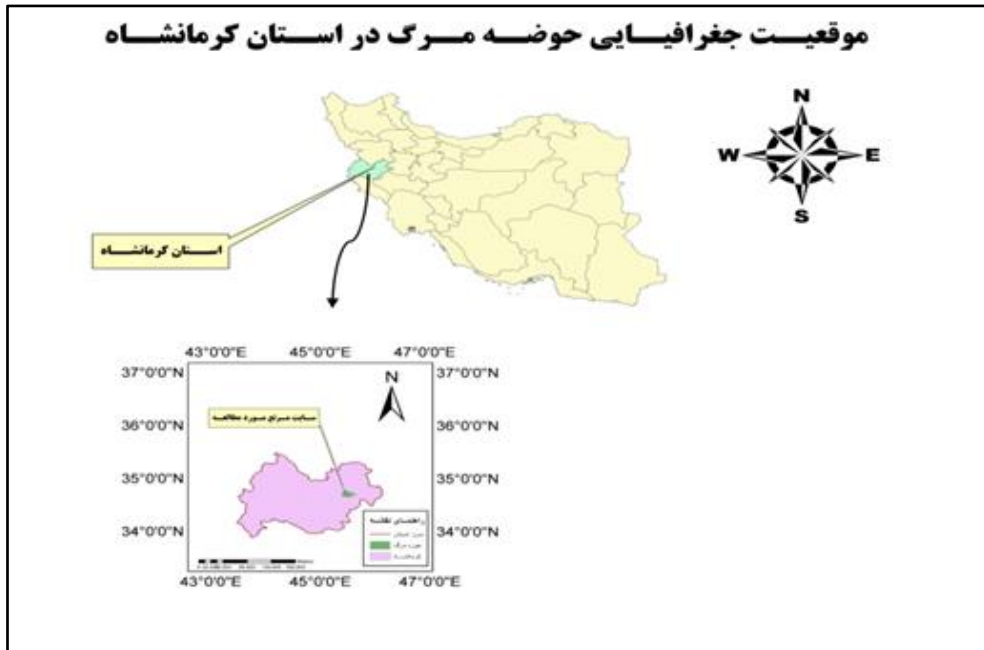
^۱ Mesoclimate

^۲ Microclimate


^۳ Merag

حذف شده و در نهایت از ۳۱ نقطه، نمونه‌برداری شد. شکل ۲ توزیع نقاط نمونه‌برداری در سایت مرتع را نشان می‌دهد.

متری خاک سطحی به انجام رسید. برخی از نقاط نمونه‌برداری پیش‌بینی شده، به دلیل اختلاط با کاربری زراعت و به‌منظور پرهیز از خطا در نتایج و تحلیل‌ها،



شکل ۱- موقعیت جغرافیایی منطقه مورد پژوهش



شکل ۲- توزیع نقاط نمونه‌برداری در سایت مرتع مورد پژوهش

اندازه‌گیری شد. در این روش، خاک با اسید سولفوریک غلیظ و دی‌کرومات پتاسیم مخلوط و پس از اتمام واکنش اکسایش و کاهش باقی‌مانده دی‌کرومات پتاسیم با فروآمونیم سولفات تیترا شد.

آماده‌سازی و آنالیز نمونه‌ها: نمونه‌های خاک پس از هوا خشک شدن، کوبیده شدن و عبور از الک دو میلی‌متری به آزمایشگاه منتقل شد. مقدار کربن آلی نمونه‌های خاک آماده شده با روش والکلی و بلاک

و دارای تعداد زیادی عناصر پردازنده متصل به هم است که عملکردی هماهنگ دارند. این شبکه ابزاری برای مدل کردن روابط پیچیده بین داده‌های ورودی و خروجی است. سلول‌های عصبی^۸ طبیعی، ورودی خود را از طریق سیناپس دریافت می‌کنند. این سیناپس‌ها بر روی دندریت‌ها یا غشاء عصب قرار دارند. در یک عصب واقعی، دندریت‌ها دامنه پالس‌های دریافتی را تغییر می‌دهند که نوع این تغییر در طول زمان یکسان نمی‌ماند و در اصطلاح، به‌وسیله عصب آموزش داده می‌شود. اگر سیگنال دریافتی به حد کافی قوی باشد و از یک مقدار آستانه بیشتر شود، عصب فعال شده و سیگنالی را در طول اکسون منتشر می‌کند. این سیگنال قادر به ورود به سیناپس دیگر و تحریک سایر اعصاب است.

شبکه عصبی مصنوعی با استفاده از مدل ساده شده عصب واقعی به پردازش اطلاعات می‌پردازد. در یک نگاه ساده، مدل یک عصب شبکه مصنوعی، شامل ورودی‌هایی است که در نقش سیناپس انجام وظیفه می‌کند. این ورودی‌ها در وزن نهایی ضرب می‌شوند تا قدرت سیگنال را تعیین کنند. نهایتاً یک تابع ریاضی تصمیم‌گیری می‌کند که آیا سلول عصبی فعال شود یا خیر و اگر جواب مثبت باشد، میزان خروجی را مشخص می‌سازد. در شکل ۳ تصویری از یک سلول عصبی و شبکه عصبی ساده نمایش داده شده است. شبکه عصبی به‌صورت مکرر از توابع برای آموزش شبکه (تغییر وزن‌ها و ارب‌ها^۹)، استفاده می‌کند تا در نهایت وزن و ارب مناسب را برای بهترین برآورد را بیابد.

در این پژوهش، برای اجرای شبکه عصبی مصنوعی از نرم‌افزار MATLAB 2010، استفاده شد. در این نرم‌افزار برای پایان دادن به روند آموزش، شاخص‌هایی اعم از تعداد تکرارها، زمان آموزش، خطا، گرادیان خطا و اعتبارسنجی را در نظر گرفته شد. آموزش شبکه به‌صورت خودکار با گذر هر یک از عوامل یادشده از حد تعیین شده، پایان می‌پذیرد. در واقع، روال آموزش تا زمانی ادامه می‌یابد که خطای شبکه روندی رو به افزایش داشته باشد. به این ترتیب

استخراج داده‌های مورد نیاز: در ابتدا، مدل رقومی ارتفاعی^۱ (DEM) اراضی مرتعی، بر مبنای نقشه توپوگرافی ۱:۲۵۰۰۰ تهیه شد. در مرحله بعد، بر اساس مدل رقومی ارتفاعی، نقشه مربوط به فاکتورهای نظیر ارتفاع^۲ جهت شیب^۳، درصد شیب^۴، سایه روشن^۵ و انحنا^۶، با استفاده از نرم‌افزار ArcGIS تهیه شد و مقادیر هر یک از فاکتورهای توپوگرافی یاد شده در نقاط نمونه‌برداری به‌دست آمد. بر اساس رابطه (۱)، متغیر کیفی جهت شیب به‌صورت یک متغیر کمی تحت عنوان جهت شیب تغییر یافته^۷ (TA) تعریف و محاسبه شد (Parvizi, ۲۰۱۰). پس از استخراج داده‌ها، از روش‌های رگرسیون خطی چندگانه و شبکه عصبی مصنوعی به‌منظور تجزیه و تحلیل استفاده شد.

$$TA = \cos(45 - \text{Aspect}) \quad (1)$$

که در آن، TA جهت شیب تغییر یافته و Aspect جهت شیب است.

تجزیه و تحلیل داده‌ها

روش آمار کلاسیک: داده‌های مربوط به عرصه مورد مطالعه پس از جمع‌آوری با استفاده از نرم‌افزار SPSS19 PASW مورد بررسی و تجزیه و تحلیل قرار گرفت. ابتدا، داده‌های پرت با استفاده از نرم‌افزار شناسایی و بررسی‌های لازم در مورد لزوم حذف آن‌ها انجام شد. آماره‌های توصیفی نظیر حداقل، حداکثر، میانگین، واریانس، انحراف معیار، ضریب تغییرات، چولگی و کشیدگی به‌دست آمد. با استفاده از عوامل توپوگرافی (ارتفاع، درصد شیب، جهت شیب تغییر یافته، سایه روشن و انحنا) به‌عنوان متغیرهای مستقل و با انجام رگرسیون خطی گام به گام، درصد کربن آلی خاک برآورد شد.

روش شبکه عصبی مصنوعی: شبکه عصبی مصنوعی به خانواده‌ای از مدل‌ها اشاره می‌کند که به‌صورت ساده شده‌ای از سیستم‌های عصبی الگو گرفته

¹ Digital Elevation Model (DEM)

² Elevation

³ Aspect

⁴ Slope Percent

⁵ Hill Shade

⁶ Curvature


⁷ Transposed Aspect

⁸ Neuron

⁹ Bias

اعتبارسنجی انجام شد. تعداد لایه‌های پنهان، تعداد نورون در لایه‌های ورودی، پنهان و خروجی تعیین و پس از انتخاب توابع فعال‌سازی لایه‌های پنهان و خروجی، برآورد کربن آلی خاک انجام شد.

از بیش برآزش شبکه جلوگیری می‌شود. برای برآورد با استفاده از شبکه عصبی مصنوعی، پس از پیش پردازش داده‌ها، انتخاب توپولوژی و معماری شبکه و تقسیم داده‌ها به بخش‌های آموزش، آزمون و



شکل ۳- الف) ساختار سلول عصبی، ب) ساختار کلی یک نورون خطی

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

$$MBE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i) \quad (3)$$

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O}_i)(-P_i)}{\sqrt{(\sum_{i=1}^n (O_i - \bar{O}_i)^2)(\sum_{i=1}^n (P_i - \bar{P}_i)^2)}} \quad (4)$$

که در آن‌ها، $\bar{O}_i, \bar{P}_i, P_i, n$ و O_i به ترتیب، تعداد داده‌ها، داده‌های برآورد شده، میانگین داده‌های برآورد شده، داده‌های اندازه‌گیری شده و میانگین داده‌های اندازه‌گیری شده می‌باشد. معیارهای RMSE و MBE هر چه به صفر و R هر چه به یک نزدیک‌تر باشد، بیانگر خطای کمتر روش و نتیجه مطلوب‌تر می‌باشد. معیار MBE به منظور بررسی اریبی برآوردها کاربرد دارد. چنان‌چه مقدار این شاخص مثبت باشد، طبق معادله (۳)، نشان‌دهنده کم برآوردی، در غیر این صورت دلیلی بر بیش برآورد بودن برآورد خواهد بود.

نتایج و بحث

آماره‌های توصیفی حاصل از تجزیه و تحلیل آماری، مطابق جدول ۱ به دست آمد. بر اساس نتایج، بیشترین ضریب تغییرات متعلق به متغیر انحنای است. بر طبق نتایج جدول ۲، کلیه متغیرها با توجه به چولگی و آزمون کولموگروف اسمیرونوف، از توزیع نرمال برخوردار هستند. بررسی همبستگی بین

در شبکه طراحی شده، تعداد نورون‌های لایه پنهان و معماری شبکه، از روش سعی و خطا و با کمینه‌سازی مقدار میانگین مربعات خطا^۱ (MSE) در هر آموزش و افزایش ضریب همبستگی چندگانه^۲ (R)، به دست آمد. ۷۰ درصد داده‌ها به عنوان داده آموزش^۳، ۱۵ درصد داده آزمون^۴ و ۱۵ درصد داده‌ها برای اعتبارسنجی^۵ منظور شد. به منظور آموزش شبکه و اصلاح وزن‌ها، از الگوریتم پس انتشار خطا^۶ استفاده شده و مدل شبکه، پرسپترون چندلایه^۷ (MLP) در نظر گرفته شد.

ارزیابی نتایج: به منظور ارزیابی صحت و دقت روش‌های استفاده شده از شاخص‌های ارزیابی ریشه میانگین مربعات خطا^۸ (RMSE)، میانگین انحراف خطا^۹ (MBE) و ضریب همبستگی چندگانه (R)، مطابق روابط (۲) تا (۴)، استفاده شد.

¹ Mean Squared Error
² Multiple Correlation Coefficient
³ Train
⁴ Test
⁵ Validation
⁶ Error Back Propagation Algorithm
⁷ Multi Layer Perceptron (MLP)
⁸ Root Mean Square Error (RMSE)
⁹ Mean Bias Error (MBE)

موثر در تغییرپذیری کربن آلی خاک و یافتن رابطه مناسب بین آن‌ها، از روش رگرسیون خطی گام به گام استفاده شد. عوامل توپوگرافی به‌عنوان متغیرهای مستقل و کربن آلی خاک به‌عنوان متغیر وابسته، در نظر گرفته شد. بر اساس ضریب همبستگی به‌دست آمده، میزان برآزش مدل رگرسیون پیش‌بینی شده با مشاهدات، ۵۲/۷ درصد برآورد شد.

متغیرهای توپوگرافی با درصد کربن آلی طبق جدول ۲، بیانگر این است که همبستگی معنی‌داری بین متغیرهای انحنا و سایه روشن با درصد کربن آلی در سطح احتمال یک درصد، وجود دارد. بین درصد کربن آلی با شاخص‌های ارتفاع، درصد شیب و همچنین، جهت شیب تغییر یافته، همبستگی معنی‌داری مشاهده نشد. برای بررسی نقش عوامل توپوگرافی

جدول ۱- برخی از آماره‌های توصیفی متغیرهای توپوگرافی در مرتع مورد پژوهش

OC (%)	Hill shade	Curvature	TA	Slope (%)	Elevation (m)	آماره
۱/۱۱	۱۴۱/۰۰	-۲/۰۰	-۰/۹۹	۰/۰۰	۱۶۵۱/۰۰	حداقل
۳/۱۷	۲۰۹/۰۰	۲/۰۰	۱/۰۰	۳۱/۱۵	۱۶۸۴/۰۰	حداکثر
۲/۰۶	۶۸/۰۰	۴/۰۰	۱/۹۹	۳۱/۱۵	۳۳/۰۰	دامنه
۱/۶۵	۱۷۴/۱۹	۰/۰۳	۰/۰۴	۱۶/۲۶	۱۶۶۷/۴۲	میانگین
۰/۴۸	۱۸/۰۱	۱/۰۵	۰/۷۴	۸/۵۸	۱۰/۷۶	انحراف معیار
۲۸/۹۶	۱۰/۳۴	۳۲۴۹/۷۲	۱۷/۵۹	۵۲/۷۷	۰/۶۵	ضریب تغییرات
۰/۲۳	۳۲۴/۲۳	۱/۱۰	۰/۵۴	۷۳/۶۳	۱۱۵/۷۸	واریانس
۱/۲۵	-۰/۰۸	۰/۳۰	-۰/۲۲	-۰/۲۴	۰/۱۱	چولگی
۱/۹۳	-۰/۸۰	-۰/۶۴	-۱/۶۳	-۰/۴۰	-۱/۴۹	کشیدگی

Elevation ارتفاع از سطح آب‌های آزاد، Slope درصد شیب، TA جهت شیب تغییر یافته، Curvature انحنا شیب، Hill shade سایه روشن و OC درصد کربن آلی خاک

جدول ۲- نتایج آزمون کولموگروف اسمیرونوف و همبستگی پیرسون

OC (%)	Hill shade	Curvature	TA	Slope (%)	Elevation (m)	مقادیر	آزمون
۰/۷۲	۰/۶۱	۱/۰۷	۱/۱۱	۰/۹۴	۰/۸۳	ضریب k.s	کولموگروف
۰/۶۹	۰/۸۵	۰/۲۰	۰/۱۷	۰/۳۴	۰/۴۹	معناداری	اسمیرونوف
۱	۰/۴۶**	۰/۵۳**	۰/۲۱	-۰/۲۱	۰/۱۴	ضریب همبستگی	همبستگی پیرسون
-	۰/۰۱	۰/۰۰	۰/۲۶	۰/۲۶	۰/۴۵	معناداری	

** همبستگی معنی‌دار در سطح یک درصد، * همبستگی معنی‌دار در سطح پنج درصد

درصد منابع تغییرپذیری کربن آلی خاک را به تغییرات خطی و مستقیم متغیر انحنا نسبت دهد.


$$OC = 1.645 + 0.527 \text{ Curvature} \quad (5)$$
 که در آن، OC درصد کربن آلی خاک و Curvature متغیر انحنا می‌باشد.

شبکه عصبی مصنوعی: آموزش شبکه عصبی مصنوعی در صورت اعمال یک سری پیش‌پردازش بر روی ورودی‌ها و هدف کارایی بالاتری خواهد داشت.

مدل رگرسیون خطی مطابق معادله (۵)، به داده‌ها برآزش داده شد. بر اساس این مدل، مقادیر کربن آلی خاک در هر یک از نقاط نمونه‌برداری برآورد شد. نمودار پراکنش مقادیر برآورد شده کربن آلی در مقابل مقادیر اندازه‌گیری شده آن در شکل ۴، نمایش داده شده است. مطابق نتایج، روش رگرسیون گام به گام توانست اولویت اثرات متغیر انحنا را در میان متغیرهای توپوگرافی مشخص نموده و حدود ۵۳

برای جلوگیری از اشباع زود هنگام نورون‌ها و یکسان نمودن ارزش داده‌ها برای شبکه، بهتر است داده‌ها در محدوده تابع سیگموئید قرار گیرد. به دلیل این که محدوده خروجی تابع سیگموئید در بازه صفر و یک است، لذا داده‌های ورودی و هدف در


محدوده صفر و یک آرایش یافتند. تابع مورد استفاده در لایه پنهان تابع سیگموئیدی از نوع تانژانت هایپربولیک و تابع لایه خروجی، خطی می‌باشد. در شبکه نهایی طراحی شده، تعداد نورون‌های لایه پنهان ۹ در نظر گرفته شد.



شکل ۴- مقادیر اندازه‌گیری و برآورد شده کربن آلی خاک به روش رگرسیون خطی گام به گام

نتایج آنالیز حساسیت متغیرهای ورودی به شبکه عصبی مصنوعی در عرصه مورد پژوهش در شکل ۵، نمایش داده شده است. ترتیب اولویت اثرگذاری متغیرهای توپوگرافی در تغییرات مقادیر کربن آلی خاک در این منطقه به ترتیب مربوط به ارتفاع، سایه روشن، درصد شیب، انحناء سطح و جهت شیب تغییر یافته است. این تفاوت نسبت به رگرسیون خطی به-

دلیل رفتار یا اثرات غیرخطی این متغیرها بر روی کمیت کربن آلی است که در شبکه عصبی قابل ردیابی و شناسایی است. مطالعات زیادی به این نکته اشاره دارند که در مناطق کوهستانی با افزایش ارتفاع، مقدار و ذخیره کربن آلی خاک افزایش می‌یابد (Powers و Schlesinger, ۲۰۰۲؛ Tsui و Chen, ۲۰۱۰؛ Podwojewski و همکاران، ۲۰۱۱).



شکل ۵- آنالیز حساسیت متغیرهای ورودی به شبکه عصبی مصنوعی در مرتع مورد پژوهش

عامل ارتفاع با تاثیر غیرمستقیم بر تغییرات مینرالوژی و مقدار و نوع پوشش گیاهی، سبب تغییر در مقدار کربن آلی خاک می‌شود. تغییر در میزان و


نوع پوشش گیاهی و بقایای آلی، سبب تغییر در کیفیت و کمیت کربن آلی ورودی به خاک را فراهم می‌کند (Djukic و همکاران، ۲۰۱۰؛ Podwojewski و

نما شامل جهت، ارتفاع و کاربری، فاکتورهای غالب موثر بر روی کربن آلی خاک می‌باشد.


مقدار ضریب همبستگی داده‌های آزمون و آموزش، اعتبارسنجی و کل داده‌ها، محاسبه شد. نمودارهای مربوط به داده‌های آزمون و تمامی داده‌ها، در شکل ۶ نمایش داده شده است. با مقایسه شکل‌های ۴ و ۶، به نظر می‌رسد شبکه عصبی مصنوعی طراحی شده در مقایسه با روش رگرسیون خطی چندگانه، به نحو مطلوب‌تری روابط غیرخطی بین عوامل توپوگرافی و کربن آلی خاک را شبیه‌سازی می‌کند. نتایج ارزیابی روش‌های رگرسیون خطی چندگانه و شبکه عصبی مصنوعی در جدول ۳ ارائه شده است.

همکاران، (۲۰۱۱). تفاوت کربن آلی خاک در طول گردان ارتفاعی به تغییرات در تعادل ورود و خروج کربن در خاک برمی‌گردد که این مساله به تغییر عوامل غیرزنده مانند دما و عوامل زنده مانند میکروارگانیسم‌ها و بقایای گیاهی، وابسته است (Hanson و Garten، ۲۰۰۶).

Thompson و Kolka (۲۰۰۵)، ارتفاع، شکل شیب، جهت شیب، ارتفاع و شیب زمین به سمت رودخانه را به‌عنوان فاکتورهای موثر در میزان کربن آلی معرفی کردند. در همین رابطه، نتایج Rezaei و Gilkes (۲۰۰۵)، موید این است که در منطقه‌ای با مواد مادری و رژیم حرارتی یکسان، مشخصات زمین:



(الف)



(ب)

شکل ۶- الف) مقادیر کربن آلی اندازه‌گیری و برآورد شده با روش شبکه عصبی مصنوعی برای داده‌های آزمون و ب) کل داده‌ها

جدول ۳- نتایج ارزیابی روش رگرسیون چندگانه خطی و شبکه عصبی مصنوعی برای برآورد کربن آلی خاک

MBE	RMSE	R	روش
۰	۰/۴۰	۰/۵۳	رگرسیون خطی چند متغیره
۰/۰۰۳	۰/۱۶	۰/۷۷	شبکه عصبی مصنوعی

R ضریب همبستگی، RMSE خطای میانگین جذر مربعات و MBE میانگین انحراف خطا است.

ارتفاع، سایه روشن و درصد شیب بر تغییرات کربن آلی خاک غیرخطی بوده و شبکه عصبی توانسته است،

بر طبق نتایج آنالیز حساسیت و جدول ۳، می‌توان نتیجه گرفت که روند اثرات متغیرهای توپوگرافی

همچنین، Besalatpour و همکاران (۲۰۱۳) نیز به این نتیجه رسیدند که تخمین با استفاده از رگرسیون برای تخمین مناسب به حجم بالایی از داده‌ها نیاز دارد، در صورتی که شبکه عصبی مصنوعی با داده‌های کمتر، قادر به برآورد دقیق‌تر است.

نتایج این پژوهش موید کاربرد مناسب شبکه عصبی مصنوعی برای کشف روابط غیرخطی متغیرها است. با توجه به تعداد کم نمونه‌ها در این پژوهش، به منظور دستیابی به نتایج دقیق‌تر در مطالعات مشابه، بهتر است تعداد نمونه‌ها را افزایش و همچنین، این پژوهش را در سطوح وسیع‌تر نیز انجام داد. بهره‌گیری از روش‌های دیگر محاسبات نرم و بهینه‌سازی مانند منطق فازی و الگوریتم ژنتیک و ترکیب این روش‌ها با شبکه‌های عصبی مصنوعی می‌تواند گامی در راستای شبیه‌سازی بهینه اثرات عوامل توپوگرافی بر تغییرات کربن آلی خاک باشد.

آن را روندیابی نماید. این نقطه قوت شبکه عصبی مصنوعی نسبت به روش رگرسیون چندگانه خطی است. با توجه به افزایش ضریب همبستگی و کاهش میانگین انحراف خطا در روش شبکه عصبی مصنوعی نسبت به رگرسیون چند متغیره خطی، به نظر می‌رسد روش شبکه عصبی مصنوعی در برآورد کربن آلی تحت تاثیر عوامل توپوگرافی در کاربری مورد مطالعه، موفق‌تر عمل کرده است. کاهش قابل ملاحظه شاخص RMSE در روش شبکه عصبی، نشان از خطای برآورد حدود ۰/۱۶ کربن آلی خاک است که نسبت به دامنه تغییرات بیش از دو درصدی کربن آلی خاک در عرصه مرتعی مورد مطالعه، خطای برآورد هشت درصدی را نشان می‌دهد، در حالی که این خطا در روش خطی رگرسیون گام به گام، ۲۰ درصد است. مقادیر بسیار کم میانگین انحراف خطا (MBE)، مبین این است که در هر دو روش عملاً خطای اریبی برآورد وجود ندارد.

منابع مورد استفاده

1. Ayoubi, S., A. Pilehvar Shahri, P.L. Mokhtari Karchegani and K. Sahrwat. 2011. Application of artificial neural network (ANN) to predict soil organic matter using remote sensing data in two ecosystems. Biomass Remote Sensing of Biomass. Intech, Open Access, InTechWeb.org, 181-196.
2. Belyani, A., M. Shorafa and M. Omid. 2012. Estimation of index points of soil moisture retention curve of some calcareous soils with readily available soil properties by artificial neural network. Journal of Water and Soil Conservation, 19(2): 167-184 (in Persian).
3. Besalatpour, A.A., M.A. Hajabbasi, S.H. Ayoubi, M. Afyuni, A. Jalalian and R. Schulin. 2012. Soil shear strength prediction using intelligent systems: artificial neural networks and an adaptive neuro-fuzzy inference system. Soil Science and Plant Nutrition, 58: 149-160.
4. Besalatpour, A.A., M.A. Hajabbasi and Sh. Ayoubi. 2013. Use of Gamma test technique for choosing the optimum input variables in modeling of soil shear strength using artificial neural networks. Journal of Water and Soil Conservation, 20(1): 97-114 (in Persian).
5. Djukic, I., V. Zehetner, M. Tatzber and M.H. Gerzabek. 2010. Soil organic-matter stocks and characteristics along an Alpine elevation gradient. Journal of Plant Nutrition and Soil Science, 173: 30-38.
6. Garten, Jr.C.T. and P.J. Hanson. 2006. Measured forest soil C stocks and estimated turnover times along an elevation gradient. Geoderma, 136: 342-352.
7. Falahatkar, S., S.M. Hosseini, A. Salman Mahiny and M.S. Alavi-Yeganeh. 2012. The relationship between primary terrain attributes and soil organic carbon in cropland (case study: Deylaman Region, Iran). 8th International Soil Science Congress on Land Degradation and Challenges in Sustainable Soil Management.
8. Fatehi, SH. 2008. Semi-detailed soil survey of merek plain in Kharkeh river basin. Final report of project, Soil and Water Research Institute. 54 pages (in Persian).
9. Ingleby, H.R. and T.G. Crowe. 2001. Neural network models for predicting organic matter content in Saskatchewan soils. Canadian Biosystems Engineering, 43: 7.1-7.5.
10. Keshavarzi, A. and F. Sarmadian. 2010. Comparison of artificial neural network and multivariate regression methods in prediction of soil cation exchange capacity, case study: Ziaran Region. Desert, 15: 167-184.
11. Lal, R. 2001. The potential of soil carbon sequestration in forest ecosystems to mitigate the greenhouse effect. In: Lal, R. (Ed.), Soil carbon sequestration and the greenhouse effect. Soil Society of America Special Publication 57 Soil Science Society of America, Madison, WI.

12. Namdar-Khojaste, D., M. Shorafa, M. Omid and M. Fazeli-Shaghani. 2010. Application of artificial neural networks in modeling soil solution electrical conductivity. *Soil Science*, 175: 432-437.
13. Parvizi, Y., M. Gorji, M.H. Mahdian and M. Omid. 2010a. Sensitivity analysis for determining priority of factors controlling SOC condition of West of Iran. *International Journal of Environmental and Earth Sciences*, 47: 922-926.
14. Parvizi, Y., M. Gorji, M.H. Mahdian and M. Omid. 2010b. Determination of soil organic carbon variability of rainfed crop. *Modern Applied Science*, 4(7): 25-33.
15. Parvizi, Y. 2010. Mapping of spatial variability of soil organic carbon and predicting the influences of physical and management factors by use of multivariate analysis and artificial neural networks. PhD Thesis. 338 pages (in Persian).
16. Podwojewski, P., J. Poulénard, M.L. Nguyet, A. de Rouw, V.T. Nguyen, Q.H. Pham and D.T. Tran. 2011. Climate and vegetation determine soil organic matter status in an alpine inner-tropical soil catena in the Fan Si Pan Mountain, Vietnam. *Catena*, 87: 226-239.
17. Powers, J.S. and W.H. Schlesinger. 2002. Relationships among soil carbon distributions and biophysical factors at nested spatial scales in rain forests of northeastern Costa Rica. *Geoderma*, 109: 165-190.
18. Rezaei, S.A. and R.J. Gilkes. 2005. The effects of landscape attributes and plant community on soil chemical properties in rangelands. *Geoderma*, 125: 167-176.
19. Sarmadian, F. and R. Taghizadeh Mehrjardi. 2008. Modeling of some soil properties using artificial neural network and multivariate regression in Gorgan Province, North of Iran. *Global Journal of Environmental Research*, 2: 30-35.
20. Senthilkumar, S., A.N. Kravchenko and G.P. Robertson. 2009. Topography influences management system effects on total soil carbon and nitrogen. *Soil Science Society of American Journal*, 73(6): 2059-2067.
21. Schuman, G.E., H.H. Janzen and J.E. Herrick. 2002. Soil carbon dynamics and potential carbon sequestration by rangeland. *Environmental Pollution*, 116(3): 391-396.
22. Thompson, J.A. and R.K. Kolka. 2005. Soil carbon storage estimation in a forested watershed using quantitative soil-landscape modeling. *Soil Science Society of America Journal*, 69(4): 1086-1093.
23. Tsui, C.C. and Z.S. Chen. 2010. Net nitrogen mineralization and nitrification of different landscape positions in a lowland subtropical rainforest in Taiwan. *Soil Science and Plant Nutrition*, 56: 319-331.
24. Wang, Y., X.C. Zhang, J.L. Zhang and S.J. Li. 2009. Spatial variability of soil organic carbon in a watershed on the loess plateau. *Pedosphere*, 19(4): 486-495.

Comparison of applying multi linear regression analysis and artificial neural network methods for simulating topographic factors effect on soil organic carbon

Somaiye Moghimi^{*1}, Yahya Parvizi², Mohammad Hossein Mahdian³ and Mohammad Hassan Masihabadi⁴

¹ PhD Student, Sciences and Researches Unit, Islamic Azad University, Iran, ² Assistant Professor, Agricultural and Natural Resources Research Center, Kermanshah, Iran, ³ Professor, Agricultural Research, Education and Extension Organization, Iran and ⁴ Assistant Professor, Sciences and Researches Unit, Islamic Azad University, Iran

Received: 19 September 2013

Accepted: 27 January 2014

Abstract

Soil organic carbon is one of the most important soil characteristics, and any changes in its content and composition, affects soil physical, chemical, and biological characteristics. Enhancing soil organic carbon improves soil structure, increases water and nutrients in soils, reduces soil erosion and degradation and thus greater productivity of plants and water quality are expected in watersheds and ultimately soil and ecosystem reclamation happens. Climatic, topographic and managerial factors affect soil organic carbon content. In local scale, climatic factors have not high efficiency on soil organic carbon and topographic factors play more important role compared to climate on soil organic carbon variability. The objective of this study was to predict and evaluate the effects of topographic factors such as elevation, slope percent, aspect, hill shade, and curvature on the soil organic carbon content of a rangeland in Mereg watershed, Kermanshah, Iran. Stepwise Multi Linear Regression (MLR) and Artificial Neural Network (ANN) were employed to develop models to predict soil organic carbon. A Multi-Layer Perceptrons (MLP) ANN with back-propagation error algorithm was applied to this research. The result showed that the multi linear regression and ANN models explained 53 and 77 percent of the total variability of soil organic carbon, respectively. The calculated RMSE and MBE were 0.40 and 0 for the MLR and 0.16 and 0.003 for MLP models. Results indicated that designated ANN model with 5-9-1 arrange was more feasible than multi linear regression for predicting soil organic carbon. Elevation with 0.79, hill shade with 0.64 and slope percent with 0.24, were identified as the important factors that explained the variability of soil organic carbon.

Key words: Aspect, Curvature, Elevation, Hill shade, Slope

* Corresponding author: sm_moghimi1010@yahoo.com