

نقشه برداری رقومی کربن آلی خاک (مطالعه موردی: مریوان، استان کردستان)

شلیر اسکندری^۱ - کمال نبی الهی^{۲*} - روح الله تقی زاده مهرجردی^۳

تاریخ دریافت: ۱۳۹۶/۰۸/۱۷

تاریخ پذیرش: ۱۳۹۷/۰۴/۱۱

چکیده

کربن آلی خاک یکی از خصوصیات مهم خاک می باشد که اطلاعات پیرامون تغییرات مکانی آن جهت مدیریت زراعی، تخریب اراضی و مطالعات زیست محیطی حائز اهمیت می باشد. هدف از این پژوهش استفاده از روش شبکه عصبی مصنوعی برای تهیه نقشه کربن آلی خاک می باشد. بنابراین، تعداد ۱۳۷ نمونه خاک از عمق ۰-۳۰ سانتی متری خاک های منطقه مریوان استان کردستان برداشت شده و خصوصیت کربن آلی خاک اندازه گیری شد. متغیرهای محیطی که در این پژوهش استفاده شد شامل اجزاء سرزمین و داده های تصویر ETM⁺ ماهواره لندست می باشد. جهت ارتباط دادن بین کربن آلی خاک و متغیرهای کمکی، از مدل شبکه عصبی مصنوعی بهره گرفته شد. بر اساس نتایج آنالیز حساسیت به روش رپر، برای پیش بینی کربن آلی خاک، متغیرهای کمکی شامل شاخص خیسی، شاخص همواری دره، فاکتور LS، شاخص NDVI و باند ۳ مهم ترین بودند. نتایج این تحقیق نشان داد که مدل شبکه عصبی مصنوعی دارای ۰/۸۰، ۰/۰۱- و ۰/۶۷ به ترتیب برای ضریب تبیین، میانگین خطا و میانگین ریشه مربعات خطا می باشد. لذا پیشنهاد می شود که جهت تهیه نقشه رقومی خاک از مدل های شبکه عصبی مصنوعی در مطالعات آینده استفاده شود.

واژه های کلیدی: متغیرهای محیطی، تغییرات مکانی، نقشه برداری رقومی

مقدمه

می شوند (۱۹). مک برانتی و همکاران (۱۹) یک چهارچوب پیش بینی کننده با ارزش برای تخمین تغییرپذیری خاک در مناطق با داده های محدود خاک از طریق ترکیب اندازه گیری های مستقیم خصوصیات خاک با یکسری داده های کمکی سهل الوصول ارائه کردند. داده های کمکی جهت افزایش صحت پیش بینی خصوصیات خاک از طریق مشاهدات مستقیم محدود به کار می روند. بر اساس مطالعات پیشین نقشه مدل رقومی ارتفاع، داده های سنجنش از دور از جمله مهمترین داده های کمی هستند که جهت پیش بینی خصوصیات خاک می توانند مفید باشند (۳۱، ۱، ۸) در سال های اخیر، تکنیک های مختلفی همچون جنگل تصادفی (۲۳)، فازی (۱۱)، شبکه عصبی مصنوعی (۲۹، ۳۷، ۷)، رگرسیون درختی (۱۳)، رگرسیون لجستیک (۳۲، ۱۲) و زمین آمار (۲۴ و ۳۳) توسط محققین جهت نقشه برداری رقومی به کار برده شده است.

شبکه عصبی مصنوعی (ANN) به عنوان یکی از معمول ترین تکنیک های نقشه برداری رقومی با شبیه سازی و الهام از مطالعه سیستم مغز و شبکه عصبی موجودات زنده اشتقاق یافته است (۲۰). در این روش سعی می شود، بر اساس روابط ذاتی میان داده ها، مدلی خطی یا غیرخطی بین متغیرهای مستقل و وابسته برقرار شود. (۱۷). مبنای این شبکه ها روش های داده کاوی هستند که بر مبنای قواعد و

کربن آلی خاک یک شاخص مهم در ارزیابی حاصلخیزی خاک و تخریب اراضی می باشد که تاثیر زیادی بر روی خصوصیات خاک دارد (۱۶). اقدامات انجام شده برای پایش و ارزیابی کربن آلی خاک، به طور فزاینده ای در سطح دنیا در حال گسترش است. این در حالی است که نمونه برداری مستقیم همراه با اندازه گیری های آزمایشگاهی یا صحرایی، معمولاً، پرهزینه و وقت گیر بوده و در نتیجه، برای اهداف کاربردی دارای محدودیت است. از این رو نیاز به روش هایی احساس می شود که بتواند براحتی سطح گسترده ای از مناطق را پایش کرده و روند تغییرات کربن آلی خاک را مورد بررسی قرار دهد. یکی از راه های چاره جهت غلبه بر این چالش استفاده از نقشه برداری رقومی خاک است. در نقشه برداری رقومی خاک، خصوصیات خاک بر اساس ارتباطشان با متغیرهای محیطی به صورت رقومی نقشه برداری

۱ و ۲- دانشجوی کارشناسی ارشد و استادیار گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه کردستان

*- نویسنده مسئول: (Email: k.nabiollahi@uok.ac.ir)

۳- استادیار گروه مدیریت مناطق خشک و بیابانی، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان

پیش‌بینی کربن آلی خاک با استفاده از روش شبکه عصبی مصنوعی در منطقه مریوان استان کردستان است.

مواد و روش‌ها

محدوده مطالعاتی

منطقه مورد مطالعه حوضه‌ای با وسعت ۲۰۰۰۰ هکتار بوده که در شهرستان مریوان در استان کردستان واقع شده است (شکل ۱). متوسط بارندگی سالانه ۹۱۳ میلی‌متر و متوسط درجه حرارت سالانه ۱۳/۸ درجه سانتی‌گراد می‌باشد. رژیم رطوبتی و حرارتی خاک منطقه به ترتیب زیریک و مزیک می‌باشد. واحدهای فیزیوگرافی منطقه شامل دشت‌های دامنه‌ای، کوه و تپه و کاربری‌های اصلی منطقه شامل زراعت، جنگل و تالاب می‌باشد.

نمونه‌برداری و آنالیزهای آزمایشگاهی

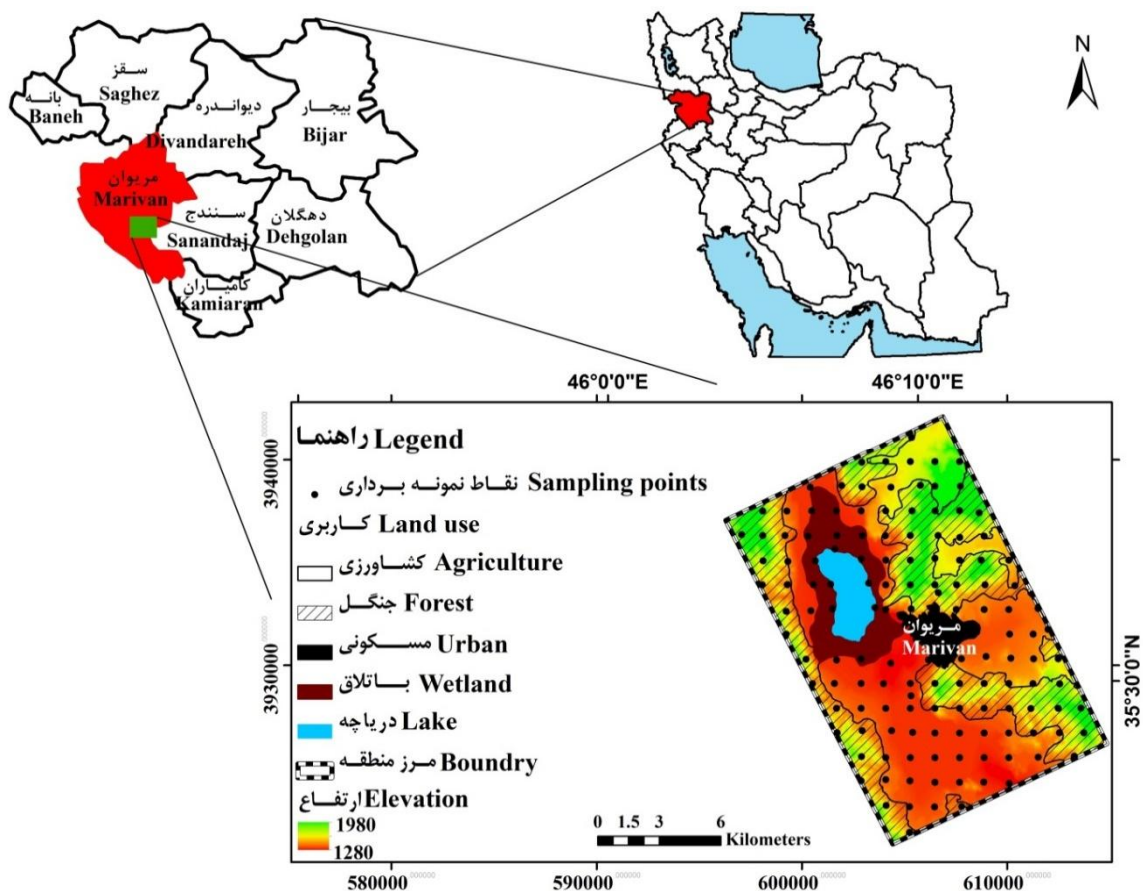
بر اساس متغیرهای کمکی همچون نقشه کاربری و مدل رقومی ارتفاع محل ۱۳۷ نمونه به روش تصادفی طبقه‌بندی شده در منطقه مریوان استان کردستان به وسعت ۲۰۰۰۰ هکتار انتخاب شده و سپس نمونه‌برداری از عمق ۰-۳۰ سانتی‌متری صورت گرفت (شکل ۱). نمونه‌های خاک پس از هوا خشک شدن و عبور از الک ۲ میلی‌متری کربن آلی خاک به روش تیتراسیون (۲۱) اندازه‌گیری شد.

داده‌های کمکی توپوگرافی و سنجش از دور

در نقشه‌برداری رقومی خاک، علاوه بر داده‌های خاک نیاز به داده‌های کمکی می‌باشد. در مطالعه حاضر از مدل رقومی ارتفاع سازمان زمین‌شناسی آمریکا (رزولیشن ۹۰ متر) استفاده گردید. بعد از آماده کردن مدل رقومی ارتفاع، از آن برای استخراج کردن اطلاعات کمکی استفاده گردید. پارامترهای زمین‌نما (۱۵ پارامتر) شامل فاکتور LS^۱، شاخص خیزی، شاخص همواری دره، شیب، ارتفاع، انحنای پروفیلی، انحنای سطح، انحنای عمق دره، موقعیت نسبی شیب، مساحت حوضه آبخیز، الگوی خمیدگی، مشخصات خمیدگی، خمیدگی کلی، بیشترین و کمترین خمیدگی در محیط سامانه جغرافیایی ساگا محاسبه و استخراج گردید. روش استخراج تمام پارامترهای مزبور در روش ارائه شده توسط هنگل و همکاران (۱۰) تشریح گردیده است. همچنین در این مطالعه از تصاویر ماهواره‌ای سنجنده ETM⁺ استفاده گردید. تصاویر این سنجنده مربوط به تابستان ۱۳۹۴ (هم‌زمان با زمان نمونه‌برداری از خاک) می‌باشد.

قوانین ریاضی عمل می‌کنند. یکی از نکات مثبت شبکه‌های عصبی مصنوعی توانایی بررسی ارتباط بین حجم و تعداد زیادی از داده‌ها بدون هیچ اطلاع قبلی در مورد ارتباط بین آنها است (۱۸). شبکه‌های هوشمند عصبی دارای قابلیت برآورد خوبی هستند و به عنوان پردازش‌گرهایی هوشمند و موفق در پیش‌بینی خصوصیات خاک نتایج خوبی ارائه داده‌اند و می‌توانند فرآیند تصمیم‌گیری در مسائل خاک را آسان کنند. ایوبی و همکاران (۲) با استفاده از مدل شبکه عصبی مصنوعی کربن آلی خاک را در دو منطقه سمیرم و لردگان پیش‌بینی و ضریب تبیین ۰/۹۹ و ۰/۸۴ به ترتیب برای این مناطق گزارش کرده و نشان دادند که مدل‌های شبکه عصبی مصنوعی با دقت بالا و قابل قبولی توانایی تخمین کربن آلی خاک را بر اساس داده‌های کمکی دارند. رادیانتو و همکاران (۲۶) با استفاده از سه مدل شبکه عصبی مصنوعی، جنگل تصادفی و رگرسیون درختی نقشه رقومی کربن آلی خاک را در دو منطقه در اندونزی تهیه کردند و به ترتیب ضرایب تبیین ۰/۸۶-۰/۵۹، ۰/۹۸-۰/۹۳ و ۰/۹۹-۰/۹۵ را برای این مدل‌ها گزارش نمودند. غلامعلی‌زاده آهنگر (۹) با مقایسه روش‌های رگرسیون خطی، زمین‌آماری و شبکه عصبی مصنوعی در مدل‌سازی کربن آلی در اراضی خشک دشت سیستان، تنها ۵ درصد تغییرات کربن آلی در منطقه مورد مطالعه توسط متغیرهای موجود در مدل رگرسیون خطی توجیه گردید (ضریب تبیین ۰/۵). همچنین بهترین روش زمین‌آماری، یعنی کوکریجینگ ساده با استفاده از متغیر کمکی رس، با ضریب تبیین ۰/۲۳ فقط تا اندازه‌های توانایی تخمین میزان کربن آلی را داشت. این در صورتی است که شبکه عصبی مصنوعی کارایی بسیار بهتری با ضریب تبیین ۰/۷۹ در تخمین مقدار کربن آلی نسبت به روش‌های رگرسیون خطی و زمین‌آماری داشت. ملون و همکاران (۱۵) با استفاده از شبکه عصبی مصنوعی و داده‌های کمکی (باند‌های تصاویر ماهواره‌ای و مشتقات مدل رقومی ارتفاع) نقشه رقومی کربن آلی خاک را تهیه و ضریب همبستگی ۰/۴۴ و ۰/۲۰ را به ترتیب برای مرحله آموزش و تست گزارش کردند.

منطقه مریوان در استان کردستان جزو مناطق جنگلی زاگرس می‌باشد که با توجه به افزایش جمعیت در چند دهه اخیر و متعاقباً افزایش نیاز به غذا مورد تهدید قرار گرفته و متأسفانه بخش‌های آن تحت کشت زراعت رفته است. از طرف دیگر هم استان کردستان یکی از قطب‌های مهم کشاورزی در ایران است که بایستی بخش کشاورزی آن مورد توجه قرار گیرد. لذا تهیه نقشه کربن آلی خاک جهت افزایش تولید محصولات و مدیریت بهتر اراضی در مناطق جنگلی و جلوگیری از تخریب اراضی ضروری می‌باشد، اما متأسفانه هیچ گونه نقشه جامع در سطح استان وجود ندارد که چنین اطلاعاتی را در اختیار ما قرار دهد. از طرفی هم تهیه نقشه کربن آلی خاک زمان‌بر و هزینه‌بر است. لذا جهت غلبه بر این مشکل کاربرد نقشه-برداری رقومی می‌تواند مفید واقع شود. بنابراین هدف از این مطالعه



شکل ۱- موقعیت منطقه مورد مطالعاتی و پراکنش مکانی نقاط نمونه برداری
Figure 1- Location of study area and spatial variability of sample points

لایه‌های اطلاعاتی موثر در فرآیند پیش‌بینی حائز اهمیت می‌باشد. بسیاری از روش‌ها برای انتخاب ویژگی‌ها در دهه اخیر معرفی شده‌اند. الگوریتم‌های انتخاب ویژگی بسته به روند ارزیابی آن‌ها به دو دسته عمده تقسیم می‌شوند. اگر انتخاب ویژگی مستقل از هر گونه الگوریتم یادگیری انجام شود (یعنی به صورت پیش‌پردازنده کاملاً مجزا)، آن را روش فیلتر یا حلقه باز می‌گویند. در این مورد ویژگی‌های نامطلوب قبل از استنتاج دور ریخته می‌شوند. اما، اگر روند ارزیابی با یک الگوریتم طبقه‌بندی در ارتباط باشد، روش انتخاب ویژگی را روش رپر^۳ یا حلقه بسته می‌نامند. این روش، جستجو در فضای زیرمجموعه‌ها را بر اساس تخمین دقت ناشی از انتخاب یک زیرمجموعه خاص، تحت شرایط الگوریتم طبقه‌بندی مورد استفاده انجام می‌دهد. الگوریتم‌های دسته دوم معمولاً نتایج بهتری به دست می‌دهند. مهم‌ترین بخش در روش انتخاب ویژگی حلقه بسته، الگوریتم جستجویی است که در آن به کار رفته است. در این مقاله از روش رپر با الگوریتم جستجوی تکاملی از نوع الگوریتم ژنتیک استفاده گردید. این روش به جعبه سیاه

این تصویر از باندهای (باند ۱: ۰/۴۵-۰/۵۲ میکرومتر، باند ۲: ۰/۵۲-۰/۶۰ میکرومتر، باند ۳: ۰/۶۳-۰/۶۹ میکرومتر، باند ۴: ۰/۷۶-۰/۹۰ میکرومتر، باند ۵: ۱/۵۵-۱/۷۵ میکرومتر، باند ۷: ۲/۰۸-۲/۳۵ میکرومتر) تشکیل شده است. همچنین شاخص پوشش گیاهی نرمال شده (NDVI) و روشیابی (BI^۲) نیز با استفاده از نرم افزار ArcGIS از ترکیب باندها محاسبه گردید (رابطه ۱ و ۲)

$$NDVI = \frac{ShortwaveIR1 - NIR}{Shortwave1 + NIR} \quad (1)$$

$$Brightness\ index = \sqrt{Red^2 + NIR^2} \quad (2)$$

آنالیز حساسیت

در اغلب موارد بسیاری از ویژگی‌ها (لایه‌های اطلاعاتی)، نامربوط و زائد هستند و کارایی الگوریتم یادگیری را کاهش داده و در بعضی موارد دقت و سرعت مدل‌سازی را پایین می‌آورند. بنابراین انتخاب

همه موقعیت‌های نمونه‌برداری انجام می‌شود. پس از تعیین مدل مناسب، با استفاده از ضریب تبیین بین مقادیر واقعی و برآورد شده کربن آلی خاک و همچنین با استفاده از محاسبه شاخص‌های میانگین ریشه مربعات خطا (رابطه ۱) و میانگین خطای مدل (رابطه ۲) که واحد اندازه‌گیری‌شان درصد است اعتبارسنجی شد.

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

$$ME = \frac{1}{n} \sum_{i=1}^n (Z_o - Z_p)^2 \quad (2)$$

که در آنها Z_0 مقادیر پیش‌بینی شده، Z_p مقادیر مشاهداتی و n تعداد داده‌ها است.

نتایج و بحث

در جدول ۱ خلاصه خصوصیات آماری کربن آلی خاک در عمق ۰-۳۰ سانتی‌متری آمده است. مقادیر کربن آلی خاک در منطقه از ۰/۲۶-۸/۴۵ درصد متغیر است و میانگین آن در منطقه با ۳/۰۸ درصد نشان دهنده کربن آلی متوسط منطقه مورد بررسی است. بیشترین میزان کربن آلی خاک در مناطق جنگلی (۸/۴۵ درصد) و تالاب (۷/۳۳) و کمترین میزان آن در اراضی کشاورزی (۰/۲۶) مشاهده شد. در منطقه مورد مطالعه، به نظر می‌رسد که جایگاه زمین‌نما در توزیع مکانی رطوبت خاک و پوشش گیاهی مؤثر بوده و این عوامل هم منجر به تغییرات کربن آلی در منطقه شده‌اند. کربن آلی خاک بر اساس چولگی و تست کولموگوروف-اسمیرنوف دارای توزیع نرمال می‌باشد و همچنین دارای ضریب تغییرات متوسط می‌باشد (۴۶/۶).

آنالیز حساسیت

در اغلب موارد بسیاری از ویژگی‌ها (لایه‌های اطلاعاتی)، نامربوط و زائد هستند و کارایی الگوریتم یادگیری را کاهش داده و در بعضی موارد دقت و سرعت مدل‌سازی را پایین می‌آورند. بنابراین انتخاب لایه‌های اطلاعاتی مؤثر در فرآیند پیش‌بینی حائز اهمیت می‌باشد. آنالیز حساسیت مدل رپر نشان داد که متغیرهای کمکی مانند شاخص خیسی (۱۸ درصد)، شاخص همواری دره (۱۳/۷۰ درصد)، فاکتور LS (۱۳/۲۰ درصد)، شاخص NDVI (۳۰/۶۱ درصد) و باند ۳ (۲۴/۴۸ درصد) بالاترین تاثیر را بر روی پیش‌بینی کربن آلی خاک را در منطقه مورد مطالعه دارند (شکل ۲).

معروف است. دلیل استفاده از الگوریتم ژنتیک این است که این الگوریتم می‌تواند یک جستجوی تصادفی را انجام دهد و مستعد گیر افتادن در کمینه محلی نمی‌باشد (۲۲). بر اساس نتایج آنالیز حساسیت به روش رپر، مهمترین پارامترها جهت پیش‌بینی کربن آلی خاک تشخیص داده شد. سپس تمام لایه‌های اطلاعاتی یا کمکی به فرمت رستری با اندازه سلولی ۳۰ متری تهیه شد (پارامترهای مدل رقومی ارتفاع با اندازه پیکسل ۹۰ متری با استفاده از روش نزدیکترین همسایه و اقدام به نمونه‌گیری مجدد^۱ به پیکسل ۳۰ متری تبدیل گردید). در نهایت تمامی اطلاعات (کربن آلی خاک و متغیرهای محیطی) به فرمت نهایی txt تبدیل شده و برای انجام فرآیند مدل‌سازی در نرم‌افزارهای مربوطه آماده شدند و در نهایت به نقشه رستری تبدیل شدند.

مدل‌سازی خاک

در این تحقیق شبکه عصبی مصنوعی پرسپترون^۲ چند لایه با یک لایه مخفی که دارای تابع فعال‌سازی سیگموئید^۳ در لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی بوده و تعداد نرون‌های آن از دو تا ۱۰ نرون متغیر بوده و بهترین تعداد نرون به صورت سعی و خطا تعیین شد. همچنین به علت کارایی، سادگی و سرعت بالا در این تحقیق الگوریتم آموزشی لونیبرگ مارکوارت^۴ استفاده شد. در تحقیق حاضر از نرم‌افزار متلب^۵ برای ساختن شبکه عصبی مصنوعی و در نهایت پیش‌بینی کربن آلی خاک استفاده شد.

ارزیابی مدل و نقشه

برای بررسی ارزیابی نقشه کربن آلی خاک، اعتبارسنجی به روش حذف یک داده و پیش‌بینی آن انجام گرفت. در شرایطی که زمان و بودجه کافی برای برداشت نمونه احتمالی وجود ندارد، بهترین گزینه اعتبارسنجی به روش حذف داده است (۴). برخلاف روش تقسیم داده‌ها به تست و آموزش، در این روش تقسیم کردن به طور تکرارپذیری انجام می‌شود و این روش را مؤثرتر می‌کند. در چنین شرایطی بهترین گزینه برای اعتبارسنجی مدل نقشه‌برداری رقومی، اعتبارسنجی به روش حذف داده و پیش‌بینی آن است. پایگاه داده (n) به $n-1$ موقعیت برای واسنجی و یک موقعیت برای اعتبارسنجی تقسیم می‌شود. در هر تکرار، مدل برای موقعیت حذف شده اجرا می‌گردد و متغیر حذف شده پیش‌بینی می‌گردد. سپس با مقدار واقعی مقایسه می‌گردد و خطای پیش‌بینی محاسبه می‌شود. این فرآیند برای

- 1- Resampling
- 2- Perceptron
- 3- Sigmoid
- 4- Lvenberg-Marquardt
- 5- Matlab

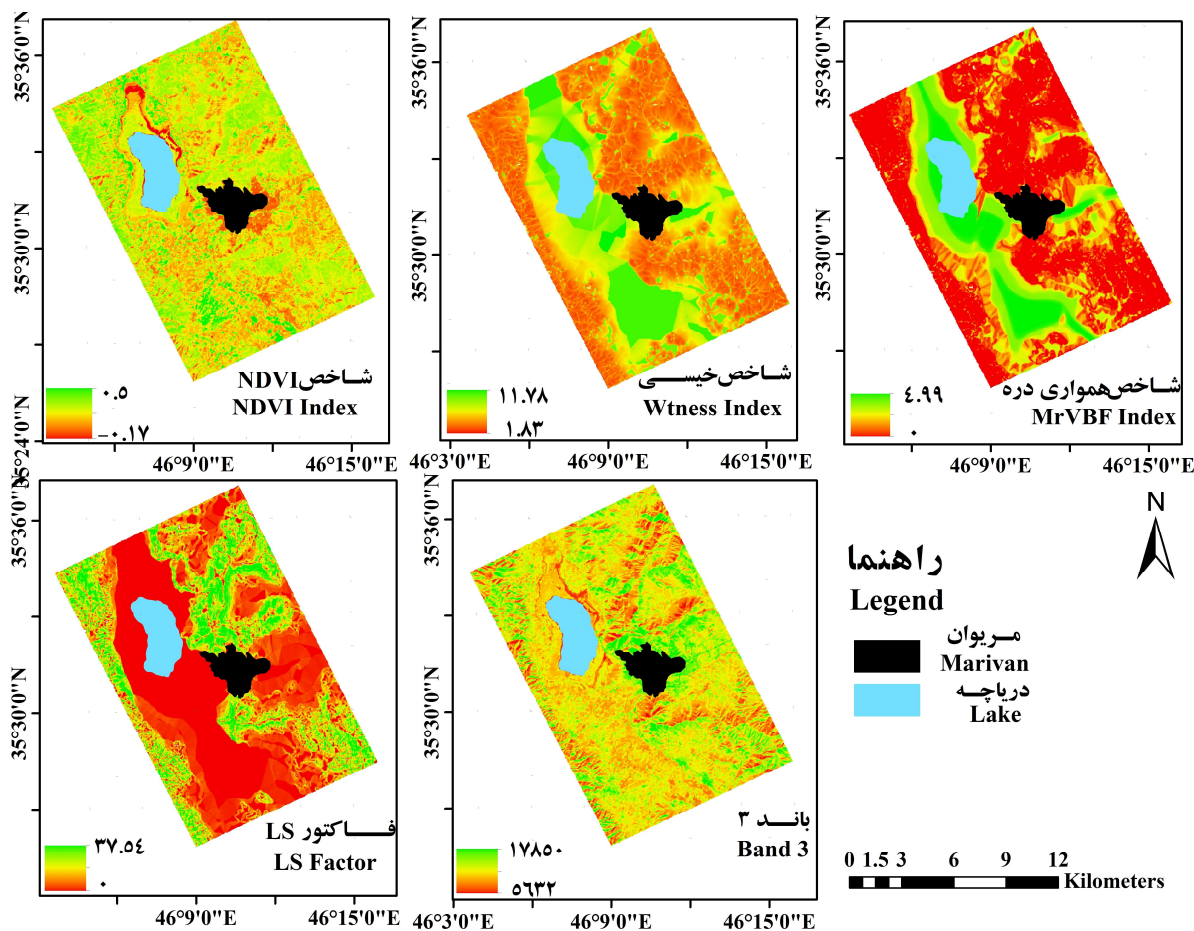
جدول ۱- پارامترهای آماری مربوط به کربن آلی خاک و داده‌های کمکی
Table 1- Statistic parameters of soil organic carbon and auxiliary data

خصوصیت Characteristic	کشیدگی Kurtosis	چولگی Skewness	حداکثر Mean	حداکثر Maximum	حداقل Minimum	ضریب تغییرات Coefficient of Variation
کربن آلی خاک (%) Soil organic carbon (%)	0.92	1.00	3.08	8.45	0.26	46.65
شاخص همواری MrVBF index	0.59	0.95	1.39	4.99	0	125.51
شاخص خیسی Wetness index	-0.48	0.88	5.77	11.78	1.83	45.88
فاکتور LS LS factor	0.14	1.03	2.95	37.54	0	113.79
شاخص NDVI NDVI index	4.85	1.22	0.09	0.50	-0.17	64.33
باند ۳ Band 3	0.94	0.71	7236.23	17850	5772	10

سریلانکا از داده‌های تصاویر ماهواره‌ای لندست ۸ و مدل رقومی ارتفاع استفاده نمودند و نتایج آنها نشان داد که مهم‌ترین داده‌های کمکی جهت پیش‌بینی کربن آلی خاک در عمق ۱۵-۰ سانتی‌متری ارتفاع، باندهای ۲، ۴، ۷، نسبت باندهای ۴/۳ و ۴/۷ و در عمق ۳۰-۱۵ سانتی‌متری ۲، ۵، ۶ شاخص NDVI، نسبت باندهای ۴/۳ و ۴/۷ بودند. وانگ و همکاران (۳۵) با استفاده از داده‌های کمکی اقلیم (بارندگی و دما)، پستی و بلندی (شاخص خیسی و ارتفاع)، سنگ‌شناسی و تصاویر ماهواره‌ای نقشه رقومی کربن آلی خاک در اراضی مرتعی استرالیا را در دو عمق ۵-۰ و ۳۰-۰ سانتی‌متری تهیه کردند و نتایج آنالیز حساسیت نشان داد که در عمق ۵-۰ سانتی‌متری باندهای ۱، ۲ و ۳ و در عمق ۳۰-۰ سانتی‌متری بارندگی، باند ۱ و ۲ دارای بیشترین تاثیر در پیش‌بینی تغییرات کربن آلی خاک می‌باشند. وانگ و همکاران (۳۶) در نقشه‌برداری رقومی کربن آلی خاک در چین در چهار عمق ۵-۰، ۱۵-۵، ۳۰-۱۵، ۶۰-۳۰ و ۱۰۰-۶۰ سانتی‌متری با استفاده از متغیرهای کمکی بارندگی، دما، کاربری اراضی و مدل رقومی ارتفاع، بر اساس نتایج آنالیز حساسیت به این نتیجه رسیدند که پارامترهای توپوگرافی ارتفاع درصد شیب و شاخص خیسی و شاخص NDVI بیشترین تاثیر را در پیش‌بینی کربن آلی خاک دارند. سایندهای هبورا (۲۷) در مقایسه تکنیک‌های نقشه‌برداری رقومی خاک برای مقادیر کربن آلی و رس در فلات مرکزی برونودی از ۱۶ متغیر کمکی از جمله متغیرهای مشتق شده از نقشه‌های خاک موجود، مشتقات مدل رقومی ارتفاعی و تصاویر ماهواره‌ای لندست استفاده کردند و نشان دادند که بهترین پارامترها در مدل‌سازی شامل واحدهای سنگ‌شناسی، مشتقات مدل رقومی ارتفاع و شاخص NDVI بود.

این موضوع نشان دهنده آن است که در منطقه مورد مطالعه، پستی و بلندی و پوشش گیاهی از مهم‌ترین فاکتورهای خاک‌سازی بوده و در توزیع مکانی خاک و ویژگی‌های آن از جمله کربن آلی خاک مؤثر می‌باشد، چرا که توپوگرافی و پوشش گیاهی هر منطقه یکی از ویژگی‌های مهم و تأثیرگذار بر ویژگی‌های خاک آن منطقه از جمله کربن آلی خاک می‌باشد. نتایج پژوهش‌های زیادی بیانگر رابطه پارامترهای سرزمین و تصاویر ماهواره‌ای با ویژگی‌های خاک بوده است. دای و همکاران (۷)، توزیع مکانی ماده آلی خاک را با استفاده از پارامترهای ورودی ارتفاع، درجه‌حرارت، بارندگی و شاخص NDVI و مدل شبکه عصبی مصنوعی-کریجینگ پیش‌بینی کردند. نتایج نشان داد که ضرایب همبستگی بین ماده آلی خاک با پارامترهای ارتفاع، بارندگی، درجه حرارت و NDVI به ترتیب ۰/۲۳، ۰/۱۶، ۰/۲۱ و ۰/۲ بود.

تقی‌زاده و همکاران (۳۰)، برای تهیه نقشه رقومی کربن آلی خاک در منطقه بانه استان کردستان، از متغیرهای کمکی داده‌های سنجش از دور، پارامترهای سرزمین و مدل‌های شبکه عصبی مصنوعی، راندوم فارست، رگرسیون لاجستیک، درخت تصمیم و الگوریتم ژنتیک استفاده کردند و به این نتیجه رسیدند که مهم‌ترین متغیرهای کمکی جهت پهنه‌بندی کلاس خاک و کربن آلی خاک شاخص NDVI، شاخص رس، شیب، جهت شیب، انحنای سطح، شاخص MrVBF، شاخص خیسی بودند. ایوبی و همکاران (۲) جهت پیش‌بینی کربن آلی خاک در دو کاربری مرتع (سمیرم استان اصفهان) و جنگل (لردگان استان چهارمحال و بختیاری) از داده‌های سنجنده ETM استفاده کردند و نتایج آنالیز حساسیت نشان داد که در کاربری مرتع باند ۱ بیشترین تاثیر، باند ۲ و ۵ تاثیر متوسط و باند ۷ و شاخص NDVI تاثیر کمتر در تغییرات کربن آلی خاک داشتند و در کاربری جنگل شاخص NDVI دارای بیشترین تاثیر بود. راتنایاک و همکاران (۲۵) جهت تهیه نقشه رقومی کربن آلی خاک در اراضی شالیزار منطقه



شکل ۲- نقشه‌های مهمترین داده‌های کمکی جهت تخمین کربن آلی خاک بر اساس آنالیز حساسیت

Figure.2- Maps of the most important auxiliary data to estimate soil organic carbon based on sensitivity analysis

مدلسازی مکانی

توپولوژی شبکه یک فاکتور اساسی در طراحی شبکه عصبی مصنوعی می‌باشد به علت اینکه این ساختار اثر تاثیرگذار بر روی سرعت یادگیری و صحت طبقه‌بندی نهایی می‌گذارد. تعداد لایه‌های مخفی و تعداد نرون‌ها جزء اجزای اصلی شبکه پرسپترون می‌باشد. بجز توپولوژی شبکه عصبی مصنوعی که ذکر شد تعداد اپوک در مرحله یادگیری بسیار حائز اهمیت می‌باشد. تعداد نرون‌ها در لایه‌های ورودی و خروجی ثابت بوده و بسته به تعداد ورودی (متغیرهای کمکی) و خروجی (کربن آلی خاک) مدل به کار گرفته شده دارد. لایه ورودی شبکه شامل ۲۵ ورودی می‌باشد. لایه خروجی شامل یک نرون می‌باشد. تعداد نرون‌ها و لایه‌های مخفی بستگی به پیچیدگی مسئله مورد نظر دارد. در اینجا یک لایه مخفی برای ایجاد شبکه پرسپترون مورد استفاده قرار گرفت. تعداد نرون‌های لایه مخفی و همچنین تعداد اپوک در فرآیند آموزش و به‌صورت سعی و خطا به

دست آمدند. در این پژوهش، تعداد نرون ۲ تا ۱۰ و تعداد تکرار ۱۰۰ تا ۱۰۰۰ مورد آزمایش قرار گرفت. برای تعیین بهترین ترکیب از شاخص ریشه مربعات خطا استفاده شد. نتایج نشان داد که تعداد نرون ۶ و تکرار ۸۷۰ دارای بهترین ترکیب برای پیش‌بینی کربن آلی خاک می‌باشد (جدول ۲). نتایج ریشه مربعات خطا، میانگین خطا و ضریب تبیین برای کربن آلی خاک ۰/۶۷، ۰/۱۹- و ۰/۸۰ بدست آمد. بعد از بدست آوردن ساختار بهینه در مرحله آموزش شبکه عصبی مصنوعی که در بالا توضیح داده شد، شبکه آموزش دیده با روش اعتبارسنجی آزمایش کرده تا دقت این مدل برای پیش‌بینی کربن آلی خاک مشخص شود که نتایج ریشه مربعات خطا، میانگین خطا و ضریب تبیین برای کربن آلی خاک در جدول ۲ آمده است. در شکل ۳ نمودار پراکنش داده‌های پیش‌بینی شده برای مدل شبکه عصبی مصنوعی ارائه شده است. با توجه به این شکل، ملاحظه می‌شود بهترین خط برازش شده دارای زاویه‌ای نزدیک به ۴۵ درجه بوده که نشان دهنده

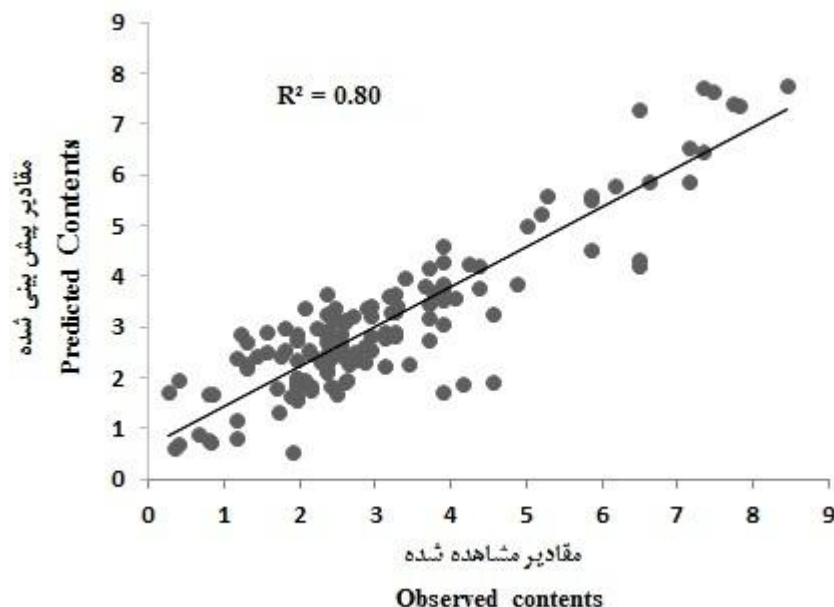
پیش‌بینی کربن آلی خاک در این عمق‌ها به ترتیب نرون‌های ۵، ۷، ۱۴ و ۱۰ بودند. دایی و همکاران (۷) با یک فرایند دو مرحله‌ای شامل استفاده از شبکه‌ی عصبی مصنوعی و سپس بهره‌گیری از کریجینگ معمولی نقشه‌ی پراکنندگی کربن آلی خاک را در فلات تبت تهیه و ضریب همبستگی ۰/۷۵ را گزارش کردند. سومارانت و همکاران (۲۸) در سریلانکا با استفاده از دو مدل شبکه عصبی مصنوعی و رگرسیون خطی چندگانه کربن آلی خاک در در کاربری‌های مختلف پیش‌بینی و به ترتیب ضرایب همبستگی ۰/۸۳-۰/۹۲ و ۰/۷۳-۰/۸۲ را گزارش نمودند. ویر و همکاران (۳۴) با استفاده از روش‌های رگرسیون برداری پشتیبان، شبکه‌ی عصبی مصنوعی و روش جنگل تصادفی اقدام به نقشه‌برداری و پیش‌بینی ذخایر کربن آلی خاک در کنیا کردند و به این نتیجه رسیدند که روش رگرسیون برداری پشتیبان و شبکه عصبی مصنوعی کمترین میزان ریشه‌ی مربعات خطا (به ترتیب ۱۵/۵ و ۱۴/۹ مگاگرم کربن بر هکتار) و بیشترین مقادیر ضریب تبیین (۰/۶) را داشته است.

دقت بالای برآورد توسط مدل شبکه عصبی مصنوعی است. در نهایت نقشه کربن آلی خاک با استفاده مدل شبکه عصبی مصنوعی در محیط ArcGIS تهیه شد (شکل ۴). محققین دیگری نیز از مدل شبکه عصبی در نقشه‌برداری رقومی کربن آلی خاک استفاده کرده‌اند. ایوبی و همکاران (۲) با استفاده از داده‌های تصاویر ماهواره‌ای لندست و دو مدل شبکه عصبی مصنوعی و رگرسیون خطی چندگانه، کربن آلی خاک را در دو منطقه سمیرم در استان اصفهان و لردگان در استان چهارمحال و بختیاری پیش‌بینی کردند. نتایج آنها نشان داد که برای دو منطقه سمیرم و لردگان مدل شبکه عصبی مصنوعی پرسپترون چند لایه (به ترتیب با ضریب تبیین ۰/۹۹ و ۰/۸۴) دارای کارایی بهتری نسبت به مدل رگرسیون خطی چندگانه (به ترتیب با ضریب تبیین ۰/۷۷ و ۰/۵۴) بود. تقی زاده و همکاران (۳۰) در منطقه بانه استان کردستان ضریب همبستگی ۰/۶۸، ۰/۵۷، ۰/۴۹ و ۰/۴۱ را جهت نقشه‌برداری رقومی کربن آلی خاک (به ترتیب برای عمق‌های ۰-۱۵، ۱۵-۳۰، ۳۰-۶۰ و ۶۰-۱۰۰ سانتی‌متری) با استفاده از مدل شبکه عصبی مصنوعی گزارش کردند و بهترین نرون‌ها هم جهت

جدول ۲- مقادیر RMSE برای تعداد نرون مختلف در پیش‌بینی کربن آلی خاک

Table 2- Contents of Root Mean Square Error of different number of neuron to estimate soil organic carbon

تعداد نرون Number of neuron	2	3	4	5	6	7	8	9	10
میانگین ریشه مربعات خطا Root Mean Square Error	0.81	0.74	0.80	0.70	0.67	0.71	0.78	0.90	0.87



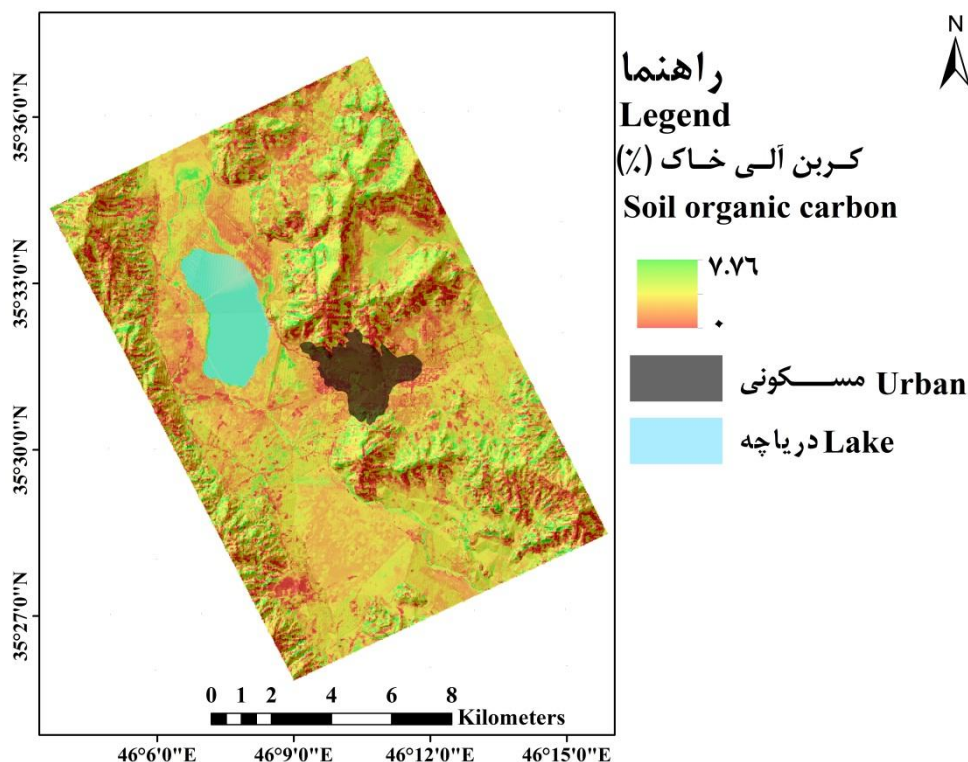
شکل ۳- نتایج مدل شبکه عصبی برای تخمین کربن آلی خاک

Figure 3- Results of artificial neural model to estimate soil organic carbon

جدول ۳- نتایج مدل برای پیش‌بینی کربن آلی خاک

Table 3- Results of models to estimate soil organic carbon

مدل Model	میانگین خطا Mean error	ضریب تبیین determination of coefficient	میانگین ریشه مربعات خطا Root Mean Square Error
شبکه عصبی مصنوعی Artificial neural network	0.019	0.80	0.67



شکل ۴- نقشه کربن آلی خاک منطقه مورد مطالعه

Figure 4- Soil organic carbon map of the study area

کشت‌های زراعی منطقه هم می‌تواند مزید بر علت باشد که منجر به زیاد شدن کربن آلی خاک در اراضی زراعی شده است. در تالاب منطقه مورد مطالعه هم به دلیل عدم وجود شرایط هوایی جهت تجزیه، کربن آلی خاک بیشتر از کاربری زراعت می‌باشد. بونفاتی و همکاران (۳) در نقشه برداری رقوم کربن آلی خاک در جنوب برزیل بیان کردند که خاک‌های تحت پوشش جنگل دارای مقادیر بالاتر کربن آلی (۱۸۴ تن کربن بر هکتار) بود چون جنگل‌ها دارای مقادیر بالاتری بقایای آلی است که به خاک وارد می‌شود. به‌طور کلی ورود بقایای تازه و میزان نسبتاً کم تجزیه به‌طور کلی سطح کربن آلی خاک را نسبت به چمنزارها افزایش می‌دهد. در مراتع (۲۰۵ تن کربن بر هکتار)، ریشه‌های عمیق سبب تجمع کربن آلی تا عمق خاک می‌شود. خاک‌های تحت کشت محصولات زراعی و تاکستان کمترین مقدار کربن آلی (۱۶۳ تن کربن بر هکتار)، به دلیل کاهش ورود مواد آلی و افزایش تجزیه دارند.

آنالیز مکانی کربن آلی خاک و مهمترین داده‌های کمکی

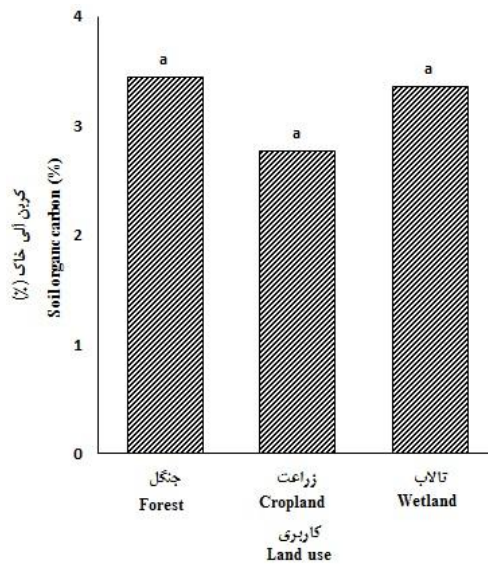
مطابق با نقشه رقوم کربن آلی خاک (شکل ۴) بیشترین مقادیر کربن آلی خاک در مناطق غربی، شمال شرقی، جنوب شرقی قرار دارد، که این بخش‌ها عمدتاً دارای پوشش جنگلی و فیزیوگرافی کوه و تپه هستند. همچنین مناطق تحت پوشش تالاب که در اطراف دریاچه قرار گرفته‌اند دارای کربن آلی خاک بالای هستند. در شکل ۵ هم میانگین کربن آلی خاک را در کاربری‌های زراعت، جنگل و تالاب نشان می‌دهد. میزان کربن آلی خاک در کاربری زراعت کمتر از تالاب و جنگل می‌باشد اگرچه از لحاظ آماری دارای اختلاف معنی‌داری نیستند. دلیل این عدم معنی‌داری احتمالاً می‌تواند به سه دلیل باشد: ۱- قرار گرفتن جنگل‌ها در اراضی شیب‌دار ۲- قرار گرفتن قسمت عمده اراضی زراعی در مناطق کم شیب ۳- تحت کشت رفتن بخشی از تالاب منطقه (در سال‌های اخیر به دلیل بارندگی‌های کم تالاب عقب نشینی کرده است و تحت کشت رفته) ۴- آبی بودن اغلب

گیاهی اثر می‌گذارد، مرتبط باشد. بونفاتی و همکاران (۳) در جنوب برزیل مهم‌ترین متغیرهای کمکی جهت نقشه‌برداری کربن آلی خاک در مناطق زراعی را ویژگی‌های حاصل از مدل رقومی ارتفاع مانند عمق دره و شاخص خیسی توپوگرافی و رده‌ی خاک‌ها گزارش کردند. چارتین و همکاران (۵) از مشتقات حاصل از مدل رقومی ارتفاع به‌عنوان متغیر کمکی محیطی استفاده کرده و در بین آنها فاکتور LS در کنار سطح اب زیر زمینی، ذرات رس و سیلت به‌عنوان مهم‌ترین پارامتر در توضیح تغییرات مکانی مقدار کربن آلی خاک در مقیاس مزرعه‌ای شناخته شد.


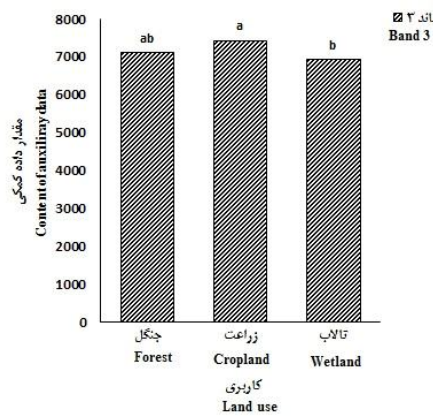
بر اساس آزمون آنالیز حساسیت، در میان داده‌های مربوط به تصاویر ماهواره‌ای، باند ۳ و شاخص NDVI مهم‌ترین متغیرهای داده‌های تصاویر ماهواره‌ای جهت پیش‌بینی کربن آلی خاک انتخاب شدند. هر چه پوشش گیاهی بیشتر باشد به دلیل جذب بیشتر طیف الکترومغناطیسی، بازتاب در باند ۳ کمتر خواهد بود. در کاربری زراعت به دلیل جذب کمتر و بازتاب بیشتر، بیشترین مقدار باند ۳ را دارد و در جنگل مقادیر باند ۳ کمتر از کاربری زراعت می‌باشد (شکل ۶ و ۷). مقدار باند ۳ هم در تالاب به دلیل داشتن سطح خیس آب دارای بیشترین جذب می‌باشد لذا کمترین مقدار باند ۳ را دارا می‌باشند (شکل ۶). ملون و همکاران (۱۵) در نقشه‌برداری میزان ذخایر کربن عوامل محیطی مهم برای پیش‌بینی کربن آلی خاک را ارتفاع بالای شبکه آبراه‌های، شاخص قدرت جریان و باندهای ۳ و ۴ گزارش کردند. شاخص NDVI که نشان دهنده میزان پوشش گیاهی است دارای میانگین ۰/۰۹ درصد و دامنه تغییرات آن ۰/۱۷-۰/۵- در منطقه است (شکل ۲). هر چه پوشش گیاهی بیشتر باشد، میزان شاخص NDVI بیشتر خواهد بود. در منطقه مورد مطالعه اگرچه مقادیر بیشتری در جنگل نسبت به دو کاربری دیگر دارند اما از لحاظ آماری برای اختلاف معنی‌دار نیستند (شکل ۶) که احتمالاً دلیل این عدم معنی‌داری هم می‌تواند به قرار گرفتن جنگل‌ها در اراضی شیب‌دار و اراضی زراعی در مناطق کم شیب‌تر نسبت داده شود. ملون و همکاران (۱۵) هم در نقشه‌برداری رقومی کربن آلی خاک در استرالیا نشان دادند که مناطقی که دارای پوشش جنگلی بودند دارای شاخص NDVI بیشتری هستند. ایوبی و همکاران (۲) در پیش‌بینی تغییرات مقدار ماده آلی خاک با استفاده از سنجش از دور در دو منطقه سمیرم اصفهان در مرکز ایران با کاربری مرتع و منطقه لردگان چهارمحال و بختیاری در غرب ایران با کاربری جنگل طبیعی نشان داد که همبستگی بین ماده آلی و شاخص NDVI در سطح یک درصد، معنی‌دار و مثبت بود.

کومار و همکاران (۱۴) در نقشه‌برداری رقومی کربن آلی خاک با استفاده از روش رگرسیون کریجینگ در مقایسه میزان کربن آلی ذخیره در خاک کاربری‌های مختلف در پنسیلوانیا نشان داد که جنگل‌ها بیشترین مقدار کربن آلی ذخیره را داشتند (۶۴ درصد). دلیل بیشتر بودن میزان ذخایر کربن آلی خاک در جنگل‌ها می‌تواند به دلیل مساحت بیشتر اراضی جنگلی و عملیات شخم باعث کاهش خاکدانه‌سازی در خاک‌های زراعی می‌شود و حفاظت فیزیکی ماده آلی خاک را کاهش می‌دهد. در نتیجه زمین‌های زراعی عموماً مقادیر پایین‌تری ذخیره‌ی کربن آلی نسبت به ظرفیت بالقوه خود دارند. باتلاق‌ها در پنسیلوانیا حدود ۲/۳٪ (۰/۲۷ پتاگرم) از مجموع (۱/۱۲ پتاگرم) ذخایر کربن آلی خاک را به‌خود اختصاص می‌دهد. شرایط بی‌هوای طولانی مدت خاک‌ها در باتلاق‌ها، میزان تجزیه بقایای آلی را در مقایسه با سایر کاربری‌ها کاهش داده و باعث افزایش ذخایر کربن آلی خاک در آن‌ها می‌شود.

کلایک (۶) هم در بررسی تأثیر تغییر کاربری بر میزان ماده آلی خاک در سه کاربری جنگل، مرتع و اراضی زراعی نشان داد که درصد ماده آلی خاک اندازه‌گیری شده در اراضی زراعی در لایه صفر تا ده سانتی‌متر، ۴۴ و ۴۸ درصد و در لایه ۲۰-۰ سانتی‌متری خاک ۴۸ و ۵۰ درصد در مقایسه با کاربری جنگل و مرتع کاهش پیدا کرده است. بر اساس آزمون آنالیز حساسیت، شاخص خیسی، شاخص همواری دره و فاکتور LS به‌عنوان مهم‌ترین متغیرهای پارامترهای سرزمین جهت پیش‌بینی کربن آلی خاک انتخاب شدند. شاخص خیسی که یکی از متغیرهای توپوگرافی مورد استفاده است بیانگر توزیع مکانی رطوبت بوده و در واقع میزان تجمع آب در خاک و در سطح زمین را نشان می‌دهد و در حقیقت این ناحیه پتانسیل بالای تجمع مواد شسته شده از مناطق بالادست را نشان می‌دهد. میانگین شاخص خیسی برای منطقه در حدود ۵/۷۷ درصد و دامنه تغییرات آن ۱۱/۷۸-۱/۸۳ درصد است (شکل ۲). شاخص همواری دره هم نشان‌دهنده قسمت‌های هموار پایین دره است که میانگین آن در منطقه ۱/۳۹ درصد و دامنه تغییرات آن ۴/۹۹-۰ درصد می‌باشد (شکل ۲). شاخص‌های خیسی و همواری دره در اراضی جنگلی به دلیل داشتن سطوح شیب‌دار و قرار گرفتن در واحدهای فیزیوگرافی کوه و تپه، کمترین مقدار و در تالاب داری بیشترین مقدار می‌باشند (شکل ۶). با افزایش این شاخص‌ها میزان کربن آلی خاک می‌تواند به دلیل تجمع رطوبت بیشتر، افزایش یابد. در نقطه مقابل این شاخص‌ها، فاکتور LS که میانگین آن در منطقه ۲/۹۴ درصد و دامنه تغییرات آن ۳۷/۵۴-۰ درصد می‌باشد (شکل ۲) در کاربری جنگل دارای بیشترین مقدار و در تالاب کمترین مقدار را دارند (شکل ۶). تأثیر پارامترهای توپوگرافی بر ترکیب و توزیع کربن آلی خاک می‌تواند به تأثیر آن‌ها بر توزیع خاک از طریق فرسایش و رسوب، حفظ پوشش گیاهی و عمق ریشه و بر زهکشی خاک که بر تجزیه کربن آلی خاک و نیز پوشش



شکل ۵- میانگین کربن آلی خاک در کاربری‌های مختلف
Figure 5- Mean value of soil organic carbon indifferent land uses.



شکل ۶- میانگین داده‌های کمکی در کاربری‌های مختلف (میانگین‌های که حروف مشترک ندارند مطابق با آزمون تی در سطح ۱ درصد اختلاف معنی داری باهم دارند (مقدار $P < 0.05$))

Figure 6- Mean value of auxiliary data in different land uses. Means (n = 3) that share a letter are not significantly different at the level 0.01 ($p > 0.05$) according to T's tes

نتیجه‌گیری

فاکتورهای تاثیرگذار بر روی دقت مدل می‌باشد. به‌طور کلی نتایج نشان داد که تکنیک‌های پدومتری بخصوص شبکه عصبی می‌توانند در گستره‌ای وسیع جهت نقشه‌برداری رقومی خصوصیات خاک‌ها به کار گرفته شود. لذا پیشنهاد می‌گردد که جهت تهیه نقشه رقومی خاک از مدل‌های شبکه عصبی مصنوعی، و داده‌های کمکی همچون اجزاء سرزمین و تصاویر ماهواره‌ای در مطالعات آینده استفاده شود.

در پژوهش حاضر از مدل شبکه عصبی مصنوعی جهت بررسی تغییرات مکانی کربن آلی خاک در منطقه مریوان استان کردستان استفاده شد. نتایج نشان داد بیشترین میزان کربن آلی خاک به ترتیب در اراضی جنگلی، تالاب و زراعت می‌باشد. همچنین نتایج نشان داد که مهم‌ترین متغیر کمکی شاخص NDVI می‌باشد و وجود ارتباط قوی بین داده خاک و پارامترهای محیطی نیز یکی از

منابع

- 1- Adhikari K., Minasny B., Greve B.G., and Greve M.H. 2014. Constructing a soil class map of Denmark based on the FAO legend using digital techniques. *Geoderma*, 214-215: 101-113.
- 2- Ayoubi S., Shahri A.P., Karchegani P.M., and Sahrawat K.L. 2011. Application of artificial neural network (ANN) to predict soil organic matter using remote sensing data in two ecosystems. In *Tech Publication*, 181-196.
- 3- Bonfatti B., Hartemink A.E., Giasson E., Tornquist C.G., and Adhikari K. 2016. Digital mapping of soil carbon in a viticultural region of Southern Brazil. *Catena*, 261: 204-221.
- 4- Brus D.J., Kempen B., and Heuvelink G.B.M. 2011. Sampling for validation of digital soil maps. *European Journal of Soil Science*, 62: 394-407.
- 5- Chartin C., Stevens A., Goidts E., Kruger I., Carnol M., and Wesemael B.V., 2017. Mapping Soil Organic Carbon stocks and estimating uncertainties at the regional scale following a legacy sampling strategy (Southern Belgium, Wallonia). *Geoderma Regional*, 9: 73-86.
- 6- Celik I. 2005. Land-use Effects on Organic Matter and Physical Properties of Soil in a Southern Mediterranean Highland of Turkey. *Soil and Tillage Research*, 83: 270-277.
- 7- Dai P.F., Qigang Z., Zhiqiang L.V., Xuemei W., and Gangcai L. 2014. Spatial prediction of soil organic matter content integrating artificial neural network and ordinary kriging in Tibetan Plateau. *Ecological Indicators*, 45: 184-194.
- 8- Greve M.H., Kheir R.B., and Greve B.M. 2012. Using Digital Elevation Models as an Environmental Predictor for Soil Clay Contents. *Soil Science Society of America Journal*, 76: 2116-2127.
- 9- Gholamalizadeh Ahangar A., Sarani F., Hashemi M., and Shabani A. 2015. Comparison of Linear Regression Methods, Geostatistical and Artificial Neural Network Modeling of Organic Carbon in Dry Land of Sistan Plain. *Journal of Water and Soil*, 28: 1250-1260. (In Persian with English abstract)
- 10- Hengel T., Rossiter D.G., and Stein A. 2003. Soil sampling strategies for spatial prediction by correlation with auxiliary maps. *Geoderma*, 120: 75-93.
- 11- Heung B., Bulmer C.E., and Schmidt M.G. 2014. Predictive soil parent material mapping at a regional-scale: a random forest approach. *Geoderma*, 214-215: 141-154.
- 12- Jafari A., Finke P.A., Van deWauw J., Ayoubi S., and Khademi H. 2012. Spatial prediction of USDA-great soil groups in the arid Zarand region, Iran: comparing logistic regression approaches to predict diagnostic horizons and soil types. *European Journal of Soil Science*, 63: 284-309.
- 13- Jafari A., Khademi H., Finke P., Wauw J.V.D., and Ayoubi S. 2014. Spatial prediction of soil great groups by boosted regression trees using a limited point dataset in an arid region, southeastern Iran. *Geoderma*, 232-234: 148-163.
- 14- Kumar S., Lal R., and Liu D., 2012. A geographically weighted regression kriging approach for mapping soil organic carbon stock. *Geoderma*, 189-190: 627-634.
- 15- Malone B.P., McBratney A.B., Minasny B., and Laslett G.M. 2009. Mapping continuous depth functions of soil carbon storage and available water capacity. *Geoderma*, 154: 138- 152.
- 16- Manlay R., Feller C., and Swift M. 2007. Historical evolution of soil organic matter concepts and their relationships with the fertility and sustainability of cropping systems. *Agriculture Ecosystems & Environment*, 119: 217-233.
- 17- Marcel G.S., Feike J.L., Martinus T., and van Genuchten H. 1998. Neural Network Analysis for Hierarchical Prediction of Soil Hydraulic Properties. *Soil Science Society of America Journal*, 62: 847-855.
- 18- Mattara, M.A., Alazbab, A.A., and Zin El-Abedin T.K. 2015. Forecasting furrow irrigation infiltration using artificial neuralnetworks. *Agricultural Water Management*, 148: 63-71.
- 19- McBratney A.B., Santos M.L.M., and Minasny B. 2003. On digital soil mapping. *Geoderma*, 117: 3-52.

- 20- Minasny B., and McBratney A. 2002. The method for fitting neural network parametric pedotransfer functions. *Soil Science Society of America Journal*, 66(2): 352-361.
- 21- Nelson D.W., and Sommers L.E. 1982. Total carbon, organic carbon, and organic matter. p. 539-594. In: Page, A.L., R.H., D.R., Keeney (Eds.), *Methods of Soil Analysis, Part 2-Chemical and Microbiological Properties*. ASA-SSSA, Madison, WI.
- 22- Nosrati H., and Eftekhari M. 2014. A new approach for variable selection using fuzzy logic. *Computational Intelligence in Electrical Engineering*, 4: 71-83. (In Persian with English abstract)
- 23- Pahlavan-Rad M.R., Toomanian N., Khormali F., Brungard C.W., Komaki C.B., and Bogaert P. 2014. Updating soil survey maps using random forest and conditioned Latin hypercube sampling in the loess derived soils of northern Iran. *Geoderma*, 232-234: 97-106.
- 24- Piccini C., Marchetti A., and Francaviglia R. 2014. Estimation of soil organic matter by geostatistical methods: use of auxiliary information in agricultural and environmental assessment. *Ecological Indicators*, 36: 301-314.
- 25- Ratnayake R.R., Karunaratne R.B., Lessels J.S., Yogenthiran N., Rajapaksha R.P.S.K., and Gnanavelrajah N. 2016. Digital soil mapping of organic carbon concentration in paddy growing soils of Northern Sri Lanka. *Geoderma Regional*, 7: 167-176.
- 26- Rudiyanto Minasny B., Setiawan BI, Arif C, Saptomo SK, and Chadirin Y. Digital mapping for cost-effective and accurate prediction of the depth and carbon stocks in Indonesian peatlands. *Geoderma*, 272: 20-31 (2016).
- 27- Sindayihebura A., Ottoy S., Dondeyne S., Meirvenne M.V., and Orshoven J.V. 2017. Comparing digital soil mapping techniques for organic carbon and clay content: Case study in Burundi's central plateaus. *Catena*. 156: 161-175.
- 28- Somaratne S., Seneviratne G., and Coomaraswamy U. 2005. Prediction of Soil Organic Carbon across Different Land-use Patterns: A Neural Network Approach. *Soil Science Society of America Journal*, 69: 1580-1589.
- 29- Taghizadeh-Mehrjardi M., Neupane R., Sood K., and Kumar S. 2017. Artificial bee colony feature selection algorithm combined with machine learning algorithms to predict vertical and lateral distribution of soil organic matter in South Dakota, USA. *Carbon Management*, 8: 277-291
- 30- Taghizadeh-Mehrjardi R., Nabiollahi K., and Kerry R. 2016. Digital mapping of soil organic carbon at multiple depths using different data mining techniques in Baneh region, Iran. *Geoderma*, 253-254: 67-77.
- 31- Taghizadeh-Mehrjardi R., Nabiollahi K., Minasny B., and Triantafyllis J. 2015. Comparing data mining classifiers to predict spatial distribution of USDA-family soil groups in Baneh region, Iran. *Geoderma*, 253-254: 67-77.
- 32- Vasques G.M., Dematte J.A.M., Viscarra Rossel R.A., Ramirez-Lopez L., and Terra F.S. 2014. Soil classification using visible/near-infrared diffuse reflectance spectra from multiple depths. *Geoderma*, 223-225: 73-78.
- 33- Veronesi F., Corstanje R., and Mayr T. 2014. Landscape scale estimation of soil carbon stock using 3D modeling. *Science Total Environment*, 487: 578-586.
- 34- Were K, Bui DT, Dick QB, and Singh BR. 2015. A comparative assessment of support vector regression, artificial neural networks, and random forests for predicting and mapping soil organic carbon stocks across an Afrotropical landscape. *Ecological Indicators*, 52, 394-403.
- 35- Wang B., Waters C., Orgill S., Gray J., Cowie A., Clark A., and Liu D.L., 2018. High resolution mapping of soil organic carbon stocks using remote sensing variables in the semi-arid rangelands of eastern Australia. *Science Total Environment*, 630: 367-378.
- 36- Wang S., Zhuang Q., Wang Q., Jin X., and Han C. 2017. Mapping stocks of soil organic carbon and soil total nitrogen in Liaoning Province of China. *Geoderma*, 305: 250-263.
- 37- Zhao Z., Chow T.L.W., Rees H., Yang O., Xing Z., and Meng F.R. 2009. Predict soil texture distributions using an artificial neural network model. *Computers and Electronics in Agriculture*, , 65: 36-48.

Digital Mapping of Soil Organic Carbon (Case Study: Marivan, Kurdistan Province)

Sh. Eskandari¹ - K. Nabiollahi^{2*} - R. Taghizadeh-Mehrjardi³

Received: 08-11-2017

Accepted: 02-07-2018

Introduction: Soil organic carbon is one of the most important soil properties which its spatial variability is essential to crop management, land degradation and environmental studies. Investigation of variability of soil organic carbon using traditional methods is expensive and time consuming. Therefore, one of the ways to overcome this challenge is using digital soil mapping which can predict soil characteristics using auxiliary data and data mining methods. Previous studies have shown that digital elevation model (DEM) and remotely sensed data are the most commonly useful ancillary data for soil organic carbon prediction. Artificial neural network (ANN) is a common technique of digital mapping. The region of Marivan in Kurdistan province is one of the forested areas in Iran. In recent decades, due to population growth and the increased need for food, this forested area has been threatened and some parts are now cultivated. Therefore, accurate mapping of soil organic carbon so as to improve land management and prevent land degradation is necessary. The purpose of this research was using ANN model and auxiliary data to map soil organic carbon.

Materials and Methods: The study area is located in Kurdistan Province, Marivan (cover 20000 ha). Soil moisture and temperature regimes are Xeric and Mesic, respectively. Elevation also varies between 1280 and 1980 m. The main land use types are cropland, forestland and wetland. The major physiographic units are piedmont plain, mountain and hills with flat to steep slopes. Using stratified random soil sampling method, 137 soil samples (for the depth of 0-30 cm) were collected and soil organic carbon were measured. In the current study, auxiliary data were terrain attributes and ETM⁺ data of Landsat 7. Terrain parameters (including 15 factors), bands 1, 2, 3, 4, 5, 6, 7, brightness index (BI) and normalized difference vegetative index (NDVI) were computed and extracted using SAGA and ArcGIS software, respectively. ANN model was applied to establish a relationship between soil organic carbon and auxiliary data. Finally, soil organic carbon were mapped using ANN and validated based on cross validation method. Three different statistics were used for evaluating the performance of model in predicting soil organic carbon, namely the coefficient of determination (R^2), mean error (ME) and root mean square error (RMSE).

Results and Discussion: Based on sensitive analysis of ANN model, auxiliary variables including wetness index, index of valley bottom flatness (MrVBF), LS factor, NDVI index, and B3 were the most important factors for prediction of soil organic carbon. The quantities of R^2 , ME and RMSE calculated for ANN model were 0.80, 0.01 and 0.67, respectively. Soil organic carbon content ranged from 0.26 to 8.45 % and the highest content was observed in forestland with hill and mountain physiography and wetland around the lake. It is noteworthy that the differences for different land uses were not statistically significant. Auxiliary data including wetness index, index of valley bottom flatness, LS factor, and B3 in different land uses had statistically significant difference ($p < 0.05$) indicating a closer relationship between auxiliary data and soil organic carbon. MrVBF and wetness index were lower and higher in forestland and wetland, respectively. Conversely, LS factor was higher and lower in forestland and wetland, respectively. Band 3 was lower in cropland and wetland compared to in forestland. NDVI index was also insignificantly higher in forestland compared to in cropland and wetland.

Conclusion: In this research, ANN model was used to investigate the spatial variability of soil organic carbon in Marivan, Kurdistan province. The highest content of Soil organic carbon was found in forestland and wetland. NDVI index was the most important auxiliary data to predict soil organic carbon within our study area. According to the values of statistics, ANN accurately estimated the soil organic carbon. Therefore,

1 and 2- M.Sc. Student and Assistant Professor of Department of Soil Science and Engineering, Faculty of Agriculture, University of Kurdistan, Sanandaj

(*- Corresponding Author Email: k.nabiollahi@uok.ac.ir)

3- Assistant Professor of Department of Arid and Desert Regions Management, University of Ardakan

employing pedometric techniques such as ANN model, auxiliary data of terrain attributes and satellite images to digitally map soil properties and update old maps is recommendable. Further studies are needed to compare these results with direct measurements of soil organic carbon.

Keywords: Digital elevation model, Land use, Satellite image