

پیش‌بینی پراکنش مکانی ماده آلی خاک با استفاده از شاخص‌های توپوگرافی و تکنیک شبکه عصبی مصنوعی - کریجینگ

محمد علی محمودی^{۱*} - مولود میرزایی^۲ - سید محمد طاهر حسینی^۳

تاریخ دریافت: ۱۳۹۶/۰۷/۰۳

تاریخ پذیرش: ۱۳۹۷/۰۲/۰۳

چکیده

ماده آلی یکی از فاکتورهای مهم کیفی خاک است که تأثیر زیادی بر ویژگی‌های فیزیکی، شیمیایی و بیولوژیکی خاک دارد. هدف از این پژوهش برآورد تغییرات مکانی ماده آلی خاک و وضعیت آن با استفاده از تکنیک شبکه عصبی مصنوعی - کریجینگ در اراضی دشت قروه در استان کردستان بود. بدین منظور تعداد ۱۵۰ نمونه خاک به روش سیستماتیک با فواصل ۲×۲ کیلومتر از عمق ۰ تا ۱۵ سانتی‌متری جمع‌آوری شد. مقدار ماده آلی خاک‌ها در آزمایشگاه اندازه‌گیری شد. با استفاده از شبکه عصبی مصنوعی رابطه بین مقدار ماده آلی و پارامترهای توپوگرافی (ارتفاع، درصد شیب، جهت شیب و شاخص خبسی توپوگرافی) بدست آمد. به کمک مدل بدست آمده نقشه اولیه ماده آلی خاک تهیه شد. سپس مقدار باقیمانده‌های مدل شبکه عصبی مصنوعی با روش کریجینگ معمولی درون‌یابی شد که پس از ادغام آن با نقشه اولیه نقشه نهایی ماده آلی خاک بدست آمد. نقشه وضعیت ماده آلی خاک از همپوشانی نقشه ماده آلی خاک با نقشه بافت خاک در چهار کلاس خیلی کم، کم، متوسط و زیاد بدست آمد. نتایج حاصل از شبکه عصبی مصنوعی نشان داد که متغیرهای ارتفاع و جهت شیب اثر معنی‌داری بر روی مقدار ماده آلی خاک داشتند ($P < 0.05$). بر اساس نتایج حاصل از ارزیابی مقاطع روش شبکه عصبی مصنوعی - کریجینگ توانست ۸۹ درصد از تغییرات مکانی ماده آلی خاک را توصیف کند. نقشه وضعیت ماده آلی خاک نشان داد که در حدود ۷۹ درصد از خاک‌های منطقه از نظر ماده آلی در وضعیت خیلی کم و کم قرار دارند.

واژه‌های کلیدی: تغییرات مکانی، شاخص‌های توپوگرافی، شبکه عصبی مصنوعی - کریجینگ، ماده آلی خاک

مقدمه

گردد (۱۸). در کشاورزی دقیق مدیریت خاک‌ها با این تغییرات تطبیق داده می‌شود. این کار باعث مصرف بهینه نهاده‌های کشاورزی می‌گردد. از اینرو، مدیریت صحیح زراعی در کشاورزی دقیق نیازمند شناخت و پیش‌بینی تغییرات مکانی ویژگی‌های خاک است (۸).

ناهمگونی خاک را می‌توان با استفاده از نمونه‌برداری پیوسته یا ناپیوسته^۴ تخمین زد. در نمونه‌برداری پیوسته ویژگی مشخصی از خاک در تمام نقاط میدانی اندازه‌گیری می‌شود. این کار معمولاً با تجزیه و تحلیل تصاویر ماهواره‌ای یا هوایی و یا از طریق جمع‌آوری داده‌های زمینی با استفاده از تکنیک‌های سنجش از دور صورت می‌گیرد. نمونه‌برداری پیوسته برای تمام نقاط میدان مورد مطالعه داده به دست می‌دهد بدون اینکه نیازی به درون‌یابی بین اندازه‌گیری‌ها و یا طرح خاصی برای نمونه‌برداری باشد (۱۸).

نمونه‌برداری ناپیوسته معمولاً با جمع‌آوری نمونه‌های خاک با استفاده از تکنیک‌های نمونه‌برداری از نقاط و اعماق از پیش تعیین شده صورت می‌گیرد. برخلاف نمونه‌برداری پیوسته، در نمونه‌برداری

ماده آلی خاک تأثیر زیادی بر ویژگی‌های فیزیکی، شیمیایی و بیولوژیکی خاک دارد. ظرفیت نگهداشت آب، مقدار مواد غذایی خاک و نیز ساختمان خاک با افزایش ماده آلی خاک بهبود می‌یابد (۵). مدیریت صحیح ماده آلی می‌تواند فرسایش خاک را کاهش داده و بارخیزی خاک را افزایش دهد. بعلاوه، افزایش ماده آلی خاک نقش مهمی در کاهش دی‌اکسید کربن اتمسفری و جلوگیری از تغییرات اقلیمی دارد (۲۸).

خاک‌ها در نتیجه اثرات اقلیم، موجودات زنده بر روی مواد مادری زمین‌شناختی در موقعیت‌های مختلف توپوگرافی در طول زمان بوجود آمده‌اند. تغییر در عوامل خاکسازي باعث ایجاد تغییر در خاک‌ها می

۱، ۲ و ۳ - به ترتیب استادیار، دانش‌آموخته کارشناسی ارشد و مربی گروه علوم و مهندسی خاک، دانشگاه کردستان، سنندج، ایران

* - نویسنده مسئول: (Email: a.mahmoodi@uok.ac.ir)

DOI: 10.22067/jsw.v32i2.68428

استخراج شده بود، استفاده کردند. نتایج بدست آمده نشان داد که شاخص موقعیت شیب عمودی^۱ مهمترین متغیر توصیف کننده توزیع ماده آلی خاک بود. سایر متغیرها مانند تیزی شیب^۲ و تابش پتانسیل خورشیدی^۳ نیز تأثیر معنی داری بر روی توزیع ماده آلی خاک داشتند. مدل ایجاد شده در این مطالعه با دو پارامتر ورودی شامل موقعیت شیب عمودی و مقدار ماده آلی استخراج شده از نقشه خاک با مقیاس (۱/۱۰۰۰۰۰) توانست ۹۲ درصد از تغییرات ماده آلی خاک را پیش بینی کند. آنها از مدل بدست آمده برای تهیه نقشه ماده آلی خاک با وضوح بالا استفاده کردند. نتایج این مطالعه نشان داد که پارامترهای توپوگرافی استخراج شده از نقشه DEM به همراه داده‌هایی که از نقشه‌های کلی خاک با مقیاس کوچک بدست می‌آیند، می‌تواند برای تهیه نقشه ماده آلی خاک با دقت و وضوح بالا با استفاده از شبکه‌های عصبی مصنوعی استفاده شوند. گنو و همکاران (۷) با استفاده از شبکه‌های عصبی مصنوعی و رگرسیون چند متغیره خطی تغییرات ماده آلی خاک را در یک منطقه تپه‌ای شبیه‌سازی کردند. آنها از شاخص‌های توپوگرافی شامل شاخص خیسی، شاخص موقعیت نسبی، ارتفاع و طول شیب که از نقشه DEM بدست آورده بودند، برای پیش‌بینی ماده آلی خاک استفاده کردند. نتایج نشان دادند که شبکه‌های عصبی ایجاد شده با استفاده از شاخص خیسی، شاخص موقعیت نسبی و طول شیب بهترین کارایی را نسبت به سایر شبکه‌های عصبی ایجاد شده و نیز رگرسیون چندمتغیره خطی داشتند. همچنین نتایج حاصل از شبکه‌های عصبی مصنوعی و رگرسیون چندمتغیره خطی نشان دادند که در بین شاخص‌های توپوگرافی شاخص خیسی بیشترین تأثیر را بر پراکنش ماده آلی خاک در منطقه مورد مطالعه داشت.

دشت قروه در استان کردستان یکی از مناطق مستعد برای کشاورزی است. عملیات خاکورزی شدید و کشت و کار نامناسب در شرایط اقلیم مدیترانه‌ای این منطقه باعث فرسایش خاک و به تبع آن از دست رفتن عناصر غذایی و مواد آلی از خاک‌های این منطقه می‌شود. این مطالعه به بررسی وضعیت ماده آلی در خاک‌های این منطقه می‌پردازد. بطور کلی اهداف این پژوهش عبارتند از: (۱) ارزیابی کارایی برخی از پارامترهای بدست آمده از نقشه رقومی ارتفاع برای پیش‌بینی تغییرات مکانی ماده آلی خاک، (۲) برآورد تغییرات مکانی ماده آلی خاک با استفاده از روش شبکه عصبی مصنوعی - کریجینگ و (۳) ارزیابی وضعیت ماده آلی خاک در بخشی از اراضی دشت قروه در استان کردستان.

نایب‌سته تنها یک زیرمجموعه نمونه از جامعه وجود دارد. اگر تعداد کافی نمونه جمع‌آوری گردد، ویژگی‌های جامعه را می‌توان با استفاده از تکنیک‌های زمین‌آماری استنتاج کرد (۳، ۴ و ۱۴). تکنیک اصلی در روش‌های زمین‌آماری کریجینگ است که بهترین تخمین خطی غیراریب از یک متغیر مکانی را بدست می‌دهد (۱۳). با این حال، نتایج روش کریجینگ زمانی رضایت‌بخش است که تعداد نمونه‌ها کافی باشند. این امر هزینه و زمان نقشه‌برداری را افزایش می‌دهد (۱۱). یکی دیگر از روش‌های زمین‌آماری کوکریجینگ است. کوکریجینگ در واقع نوعی کریجینگ توسعه یافته است که در آن از رابطه بین متغیر اصلی با یک یا چند متغیر کمکی برای درون‌یابی متغیر اصلی استفاده می‌شود (۹، ۲۵ و ۲۷). دقت این روش زمانی بالاست که ضریب همبستگی بین متغیر اصلی با متغیرهای کمکی ۰/۵ و بیشتر بوده و تراکم نمونه‌برداری متغیر کمکی بالا باشد (۲۲، ۲۴ و ۲۹).

از دیگر روش‌هایی که در آنها از رابطه بین متغیر اصلی با یک یا چند متغیر کمکی برای درون‌یابی متغیر اصلی استفاده می‌شود روش‌های تلفیقی رگرسیون - کریجینگ یا شبکه عصبی مصنوعی - کریجینگ است. در این روش‌ها ابتدا با استفاده از روش‌های رگرسیونی یا شبکه‌های عصبی مصنوعی رابطه بین متغیر اصلی با متغیرهای کمکی بدست می‌آید. با استفاده از مدل بدست آمده نقشه اولیه متغیر اصلی تهیه می‌شود. سپس مقدار باقیمانده‌ها با استفاده از کریجینگ معمولی درون‌یابی می‌شود. در نهایت نقشه نهایی متغیر اصلی از جمع نقشه اولیه با نقشه باقیمانده‌ها بدست می‌آید (۲۰ و ۶). شبکه‌های عصبی روش‌های هوشمند مدلسازی هستند که همانند سیستم عصبی انسان عمل می‌کنند. این شبکه‌ها توانایی یادگیری و تعمیم اطلاعات را دارند. مزیت اصلی شبکه‌های عصبی در این است که برخلاف روش‌های رگرسیونی نیازی به ارتباط از پیش تعیین شده ای میان داده‌های ورودی و داده‌هایی که قرار است پیش‌بینی شوند، ندارند. از آنجایی که خاک یک سیستم طبیعی و ناهمگن است، ایجاد ارتباط میان خصوصیات آن تا حدی دشوار است. از این‌رو، در این‌گونه سیستم‌ها شبکه‌های عصبی معمولاً کاراتر از روش‌های رگرسیونی عمل می‌کنند (۱۵). بعنوان مثال اینگلی و کراو (۸) از طول موج‌های مختلف طیف بازتاب شده از خاک برای پیش‌بینی ماده آلی خاک استفاده کردند. نتایج مطالعات آنها نشان داد که شبکه‌های عصبی مصنوعی نسبت به رگرسیون چندمتغیره خطی کارایی بیشتری برای پیش‌بینی ماده آلی خاک دارند.

شاخص‌های توپوگرافی، که از نقشه‌های رقومی ارتفاع (DEM) بدست می‌آیند، می‌توانند متغیر کمکی مفیدی برای پیش‌بینی برخی از ویژگی‌های خاک‌ها باشد. بعنوان مثال زاو و همکاران (۳۰) با استفاده از شبکه‌های عصبی مصنوعی مدلی برای پیش‌بینی ماده آلی خاک بوجود آوردند. آنها برای اینکار از پارامترهای توپوگرافی و نیز از برخی از ویژگی‌های خاک که از نقشه خاک با مقیاس (۱/۱۰۰۰۰۰) استفاده کردند.

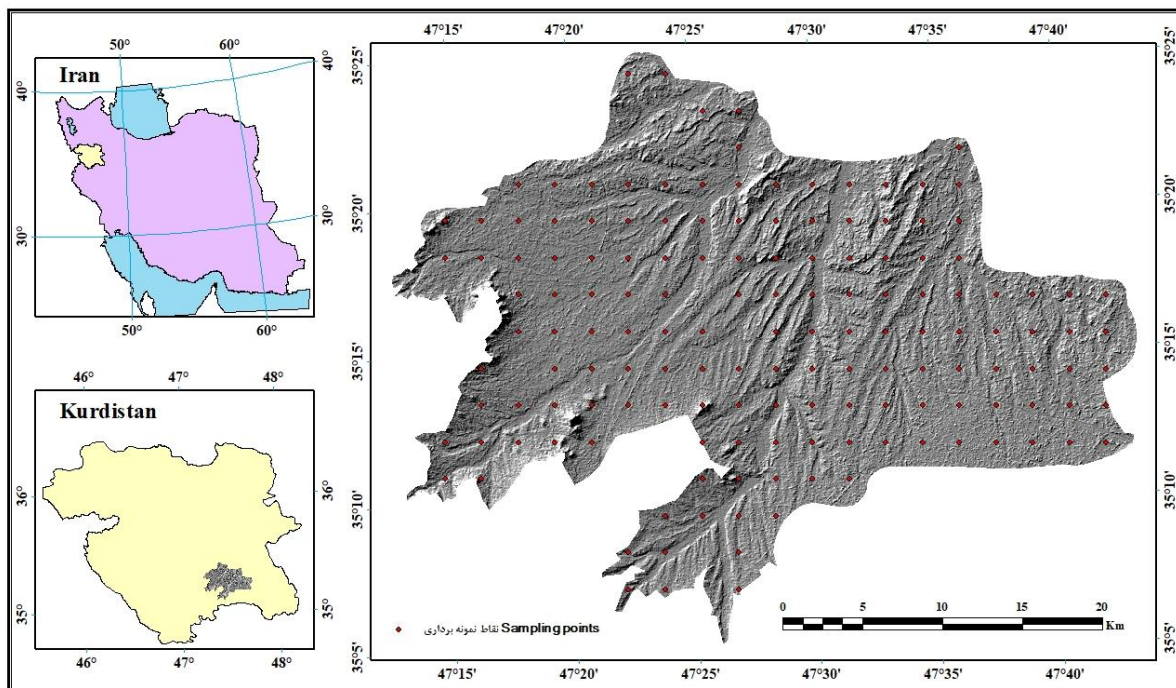
1- Vertical slope position
2- Slope steepness
3- Potential solar radiation

مواد و روش‌ها

منطقه مورد مطالعه

طول شرقی و ۳۵ درجه و ۵ دقیقه تا ۳۵ درجه و ۲۶ دقیقه عرض شمالی واقع شده است (شکل ۱). اراضی این منطقه عمدتاً تپه‌ای و دارای کاربری کشاورزی (آبی و دیم) می‌باشند. رژیم حرارتی خاک های این منطقه مزیک و رژیم رطوبتی آنها زریک است.

منطقه مورد مطالعه بخشی از اراضی دشت قروه در استان کردستان در غرب ایران با مساحتی در حدود ۸۷ هزار هکتار است، که در محدوده جغرافیایی ۴۷ درجه و ۱۲ دقیقه تا ۴۷ درجه و ۴۴ دقیقه



شکل ۱- موقعیت منطقه مورد مطالعه و نقاط نمونه‌برداری

Figure 1- Location of the study area and distribution of the sampling points

جغرافیایی ایالات متحده آمریکا (USGS) استخراج شدند. این شاخص‌ها عبارت بودند از ارتفاع (H)، درصد شیب (S)، جهت شیب (Asp) و شاخص خیسی توپوگرافی (TWI). شاخص خیسی توپوگرافی و یا به اختصار شاخص خیسی، که اولین بار توسط بون و کیرکی (۱) ارائه شد، معرف خوبی برای توزیع رطوبت در سطح زمین‌نماست و به صورت زیر تعریف می‌شود:

$$TWI = \ln \left(\frac{\alpha}{\tan \beta} \right) \quad (1)$$

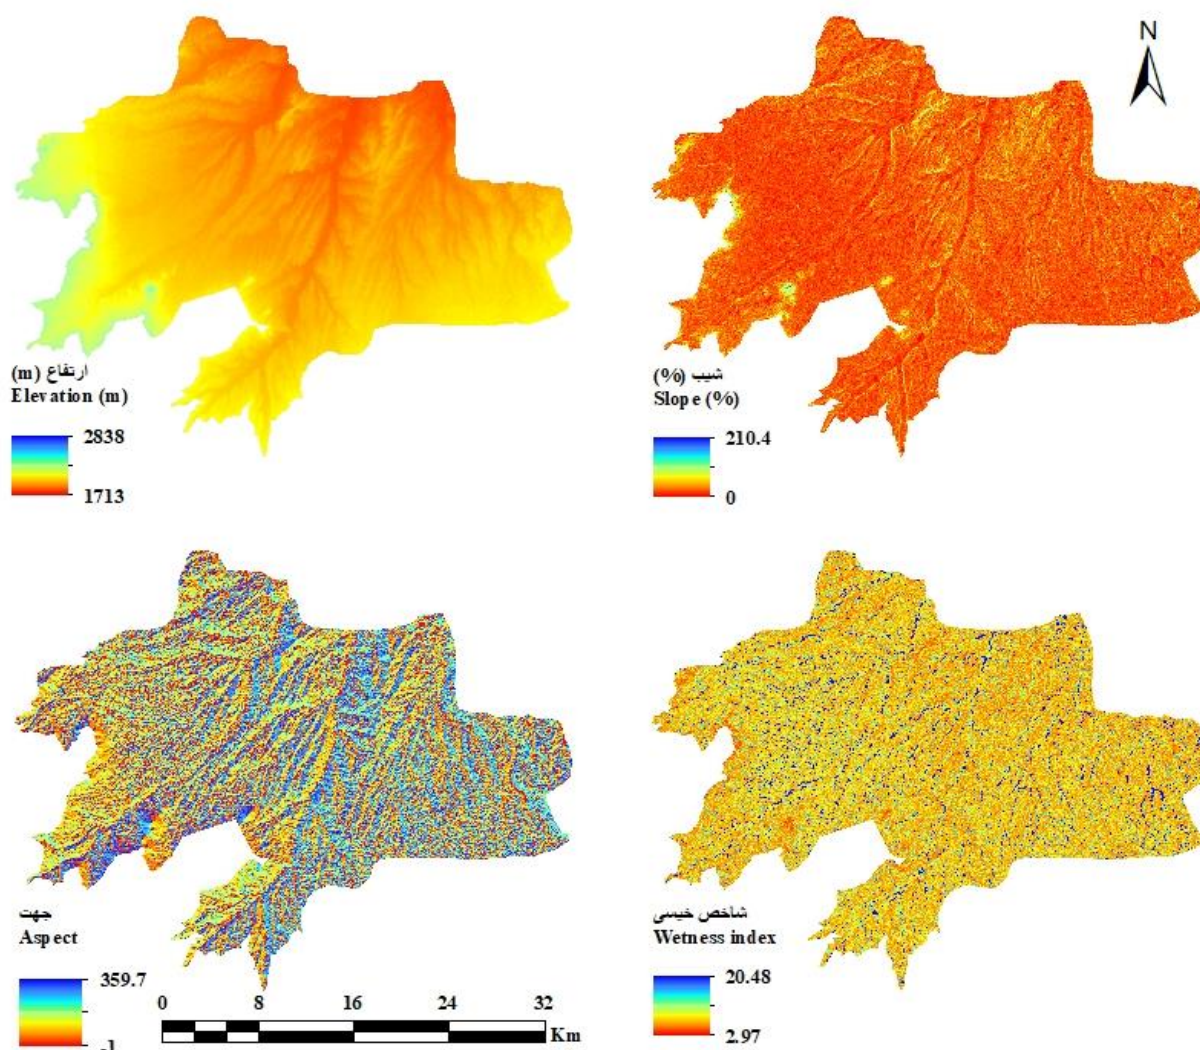
که در آن α سطح دریافت کننده ویژه (m^2/m) و β درجه شیب است. سطح دریافت کننده ویژه به صورت مساحت حوزه آبخیز بالادست هر نقطه به طول مسیر دریافت کننده جریان در آن نقطه تعریف می‌شود (۱). کلیه شاخص‌های فوق با استفاده از نرم‌افزار ArcGIS 10.2 محاسبه شدند (شکل ۲).

نمونه‌برداری و تجزیه‌های خاک

نمونه‌برداری از خاک‌های منطقه مطالعاتی در تابستان سال ۱۳۹۳ صورت گرفت. در مجموع تعداد ۱۵۰ نمونه خاک به روش سیستماتیک (شبکه‌ای) با فواصل منظم ۲×۲ کیلومتر جمع‌آوری شد (شکل ۱). در هر نقطه تعداد ۶ نمونه در دایره‌ای به شعاع ۱ متر از عمق ۰ تا ۲۰ سانتی‌متری برداشته شد. سپس نمونه‌ها با هم مخلوط شدند و یک نمونه مرکب بعنوان معرف آن نقطه بدست آمد. نمونه‌ها در دمای آزمایشگاه هوا خشک شدند و سپس از الک ۲ میلی‌متری عبور داده شدند. مقدار ماده آلی آنها به روش والکی و بلک (۲۶) اندازه‌گیری شد.

شاخص‌های توپوگرافی

برای پیش‌بینی تغییرات مکانی ماده آلی خاک از شاخص‌های توپوگرافی بعنوان متغیر کمکی استفاده شد. شاخص‌های توپوگرافی در این مطالعه از نقشه‌های DEM تهیه شده توسط سازمان نقشه‌برداری



شکل ۲- نقشه‌های شاخص‌های توپوگرافی منطقه مورد مطالعه
Figure 2- Maps of topographic indices of the study area

لایه مخفی بر مبنای توصیه کولومگروف برابر $2n+1$ در نظر گرفته شد که در آن n تعداد متغیرهای ورودی است (۲). متغیرهای ورودی کانیدا شده برای ایجاد شبکه عصبی مصنوعی پارامترهای توپوگرافی بودند که از نقشه رقمی ارتفاع بدست آمدند. این متغیرها عبارت بودند از ارتفاع، مقدار شیب، جهت شیب و شاخص خیسبی. قبل از مدل‌سازی کلیه متغیرهای ورودی با استفاده از رابطه زیر استاندارد شدند:

$$Z = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

که در آن Z مقدار استاندارد شده، x_i مقدار هر داده، x_{\min} مقدار حداقل داده‌ها و x_{\max} مقدار حداکثر داده‌ها می‌باشد. این تبدیل مقدار داده‌ها را بین ۰ و ۱+ استاندارد و بی بعد می‌کند. داده‌های مورد

مدل‌سازی با استفاده از شبکه عصبی مصنوعی

به منظور پیش‌بینی روند کلی تغییرات ماده آلی خاک از شبکه عصبی مصنوعی استفاده شد. شبکه عصبی مورد استفاده در این مطالعه از نوع پیش‌خور^۱ و دارای دو لایه بود. نرون‌های لایه مخفی آن از نوع سیگموئیدی و نرون‌های لایه خروجی آن از نوع خطی بود. این نوع شبکه به دلیل کارایی بالای آن در انطباق با مسائل بویژه در سیستم‌های غیرخطی بطور گسترده‌ای توسط محققین مختلف مورد استفاده قرار گرفته است (۷، ۱۰ و ۳۰). برای آموزش شبکه از الگوریتم پس‌انتشار^۲ لونبرگ-مارکوات استفاده شد. تعداد نرون‌های

- 1- Feed forward
- 2- Backpropagation

روش ارزیابی صحت

برای ارزیابی عملکرد هر کدام از روش‌های درون‌یابی از روش ارزیابی مقاطع استفاده شد. بدین منظور از سه شاخص آماری میانگین خطا (ME)، ضریب نیکویی برازش یا ضریب تبیین (R^2) و شاخص نش-ساتکلیف (NS) (۱۹) استفاده شد، که به صورت زیر تعریف می‌شوند:

$$ME = \frac{1}{N} \sum_{i=1}^N [\hat{Z}(x_i) - Z(x_i)] \quad (۳)$$

$$R^2 = \frac{\sum_{i=1}^N [(\hat{Z}(x_i) - \bar{Z}(x_i))(Z(x_i) - \bar{Z}(x_i))]^2}{\sum_{i=1}^N (\hat{Z}(x_i) - \bar{Z}(x_i))^2 \sum_{i=1}^N (Z(x_i) - \bar{Z}(x_i))^2} \quad (۴)$$

$$NS = 1 - \frac{\sum_{i=1}^N [\hat{Z}(x_i) - Z(x_i)]^2}{\sum_{i=1}^N [Z(x_i) - \bar{Z}(x_i)]^2} \quad (۵)$$

در این فرمول‌ها، N تعداد کل نمونه‌ها، $Z(x_i)$ مقادیر اندازه‌گیری شده، $\hat{Z}(x_i)$ مقادیر پیش‌بینی شده، $\bar{Z}(x_i)$ میانگین مقادیر اندازه‌گیری شده و $\bar{Z}(x_i)$ میانگین مقادیر برآورد شده ماده آلی خاک در مکان x_i می‌باشد. لازم به ذکر است که در مواردی که ارزیابی یک مدل بر اساس داده‌هایی که خود مدل با استفاده از آنها بدست آمده است انجام گیرد، تنها از شاخص R^2 استفاده می‌شود؛ زیرا در چنین مواردی شاخص‌های R^2 و NS با هم برابر خواهند شد. اما در مواردی که ارزیابی یک مدل بر اساس یک گروه داده مستقل انجام شود، از هر دو شاخص استفاده می‌شود. مقدار شاخص NS از $-\infty$ تا ۱ متغیر است. مقدار ۱ بیانگر برازش کامل مقادیر برآورد شده بر مقادیر اندازه‌گیری شده است. برای مقادیر NS کمتر از صفر کارایی مدل ضعیف، بین صفر تا ۰/۵ متوسط و بزرگتر از ۰/۵ رضایت‌بخش خواهد بود (۱۷ و ۲۱).

نتایج و بحث

ویژگی‌های توپوگرافی و خاک‌های منطقه

در جدول (۲) دامنه تغییرات و توزیع برخی از ویژگی‌های خاک-های مورد مطالعه برای کل داده‌ها و همچنین زیرمجموعه‌های مختلف آنها (داده‌های آموزش، اعتبارسنجی و آزمون) ارائه شده است. مقدار ماده آلی خاک‌ها بین ۰/۳۴ تا ۴/۵۱ درصد تغییر می‌کند. مقدار ۰/۳۴ مربوط به زمینی با کاربری بایر و مقدار ۴/۵۱ درصد مربوط به کاربری گندم آبی بوده است. در ستون آخر مقدار P value آزمون کای اسکور نشان داده شده است. بر اساس این آزمون توزیع آماری داده‌های آموزش، اعتبارسنجی و آزمون برای هر کدام از متغیرها با توزیع کل داده‌های آن متغیر یکسان است. این موضوع

استفاده برای ایجاد شبکه عصبی به طور تصادفی به سه گروه آموزشی (۷۵ درصد)، اعتبارسنجی (۱۵ درصد) و آزمون (۱۵ درصد) تقسیم شدند.

برای انتخاب بهترین متغیرهای ورودی از بین متغیرهای فوق از روش پیشرو استفاده شد. بدین صورت که ابتدا از بین شبکه‌های عصبی با یک متغیر ورودی بهترین شبکه عصبی بر مبنای کمترین میانگین مربعات خطا (MSE) انتخاب گردید. سپس به این مدل به ترتیب متغیرهای دیگر اضافه شدند؛ با این شرط که باعث کاهش معنی‌داری در خطاهای مدل گردند. آزمون مورد استفاده برای اینکار آزمون t student در سطح معنی‌داری ۰/۰۵ بود.

روش‌های درون‌یابی

روش اصلی در این مطالعه برای برآورد تغییرات مکانی ماده آلی خاک روش شبکه عصبی مصنوعی-کریجینگ بود؛ اما به منظور مقایسه از روش کریجینگ معمولی نیز استفاده شد. در روش شبکه عصبی مصنوعی-کریجینگ ابتدا با استفاده از شبکه عصبی مصنوعی رابطه بین ماده آلی با شاخص‌های توپوگرافی بدست آمد. با استفاده از مدل بدست آمده نقشه اولیه ماده آلی خاک تهیه شد. سپس مقدار باقیمانده‌ها با استفاده از روش کریجینگ معمولی درون‌یابی شد. در نهایت نقشه نهایی ماده آلی خاک از جمع نقشه اولیه با نقشه باقیمانده‌ها بدست آمد (۱۴، ۲۰). کلیه محاسبات و تهیه نقشه‌ها در این مطالعه با استفاده از نرم‌افزارهای Arc و MATLAB 8.6.0 و GIS 10.2 انجام گرفت.

طبقه‌بندی وضعیت کمی ماده آلی خاک

در این مطالعه وضعیت مقدار ماده آلی خاک‌ها با توجه به کلاس بافتی آنها در ۴ سطح خیلی کم، کم، متوسط و زیاد طبقه‌بندی شده است، که معیارهای این طبقه‌بندی در جدول (۱) آورده شده است (۲۳). بر این اساس طبقه‌بندی وضعیت کمی ماده آلی خاک در منطقه مورد مطالعه با توجه به نقشه بافت خاک انجام شد. این نقشه، که در شکل (۳) نشان داده شده‌اند، از مطالعات قبلی در این منطقه بدست آمده است (۱۶). بطوری که نقشه بافت خاک نشان می‌دهد بخش اعظم خاک‌های این منطقه (۶۴ درصد) دارای بافت سنگین لوم رسی می‌باشند. تنها حدود ۱۹ درصد از خاک‌های منطقه دارای بافت متوسط لومی بوده و بقیه خاک‌های منطقه دارای سایر بافت‌ها هستند که بطور پراکنده در منطقه توزیع یافته‌اند.

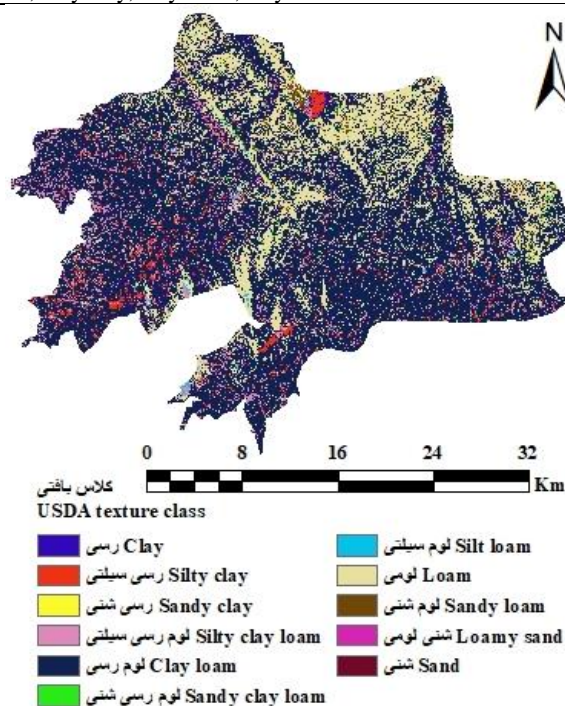
در این مطالعه وضعیت مقدار ماده آلی خاک‌ها با توجه به کلاس بافتی آنها در ۴ سطح خیلی کم، کم، متوسط و زیاد طبقه‌بندی شده است، که معیارهای این طبقه‌بندی در جدول (۱) آورده شده است (۲۳).

تقسیم‌بندی خوب داده‌ها را نشان می‌دهد که برای بدست آوردن یک شبکه عصبی پایدار و کارآمد ضروری است.

جدول ۱- ارزیابی وضعیت ماده آلی خاک بر اساس کلاس بافتی آن (۲۳)

Table 1- Soil organic matter evaluation according to USDA textural classes (23)

کلاس بافت خاک USDA texture class	وضعیت ماده آلی خاک SOM content			
	خیلی کم Very low	کم Low	متوسط Medium	زیاد High
لوم شنی، شنی، شنی لومی Sandy loam, sand, loamy sand	<0.8	0.8-1.4	1.5-2	>2
سیلتی، لوم سیلتی، لوم رسی شنی، رسی شنی، لومی Silt, silty loam, sandy clay loam, sandy clay, loam	<1	1-1.8	1.9-2.5	>2.5
لوم رسی سیلتی، رسی سیلتی، لوم رسی، رسی Silty clay loam, silty clay, clay loam, clay	<1.2	1.2-2.2	2.3-3	>3



شکل ۳- نقشه بافت خاک‌های منطقه مورد مطالعه (۱۶)

Figure 3- Soil texture map of the study area (16)

افزایش معنی‌داری را در دقت مدل ایجاد نکرده‌اند ($P > 0.05$) و لذا شبکه عصبی بدست آمده با دو متغیر ارتفاع و جهت شیب بعنوان بهترین مدل انتخاب گردید. این نتایج نشان می‌دهند که در بین شاخص‌های توپوگرافی فوق، شاخص‌های ارتفاع و جهت شیب بیشترین تأثیر را بر پراکنش مکانی ماده آلی خاک دارند. در یک منطقه معمولاً با افزایش ارتفاع مقدار بارندگی نیز افزایش می‌یابد. افزایش بارندگی افزایش پوشش گیاهی و به تبع آن افزایش ماده آلی خاک را به دنبال دارد. جهت شیب نیز از طریق تأثیر بر میزان انرژی تابشی دریافتی در واحد سطح بر میزان درجه حرارت خاک و در نتیجه سرعت تجزیه ماده آلی خاک تأثیر می‌گذارد. در نیمکره شمالی شیب

پیش‌بینی ماده آلی خاک با استفاده از شبکه عصبی مصنوعی

در جدول (۳) کارایی شبکه‌های عصبی مصنوعی با متغیرهای ورودی مختلف آورده شده است. در بین مدل‌های تک متغیره، ارتفاع بهترین متغیر ورودی بوده است زیرا کمترین مقدار MSE با این متغیر بدست آمده است. در گام بعدی سایر متغیرهای ورودی به این متغیر اضافه شده‌اند تا بهترین شبکه عصبی دو متغیره بدست آید. در اینجا متغیر جهت شیب بیشترین افزایش معنی‌دار را در دقت پیش‌بینی مدل تک متغیره ایجاد کرده ($P < 0.05$) و بعنوان متغیر دوم وارد مدل شده است. افزودن متغیرهای درجه شیب و شاخص خیزی به این مدل

های جنوبی انرژی تابشی بیشتری در واحد سطح دریافت می‌کنند؛ لذا مقدار آن در خاک کمتر است (۱۲). معمولاً در این شیب‌ها سرعت تجزیه ماده آلی خاک بیشتر بوده و

جدول ۲- آماره‌های توصیفی برخی از ویژگی‌های خاک‌های مورد مطالعه
Table 2- Descriptive statistics of selected soil parameters

متغیر Variable	گروه Data group	تعداد نمونه No. of samples	کمترین Minimum	بیشترین Maximum	میانگین Mean	انحراف معیار Standard deviation	چولگی Skewness	کشییدگی Kurtosis	P Value
ماده آلی (%) Organic matter (%)	کل All	150	0.34	4.51	1.82	0.68	1.12	5.28	-
	آموزش Training	104	0.34	4.51	1.82	0.70	1.20	5.75	1.00
	اعتبارسنجی Validation	23	0.84	3.79	1.85	0.72	1.05	3.97	1.00
	آزمون Test	23	0.93	2.91	1.80	0.55	0.51	2.64	1.00
شیب (%) Slope (%)	کل All	150	0.10	25.96	5.83	4.29	1.44	6.48	-
	آموزش Training	104	0.13	25.96	5.99	4.58	1.60	6.69	1.00
	اعتبارسنجی Validation	23	0.13	11.40	5.48	3.26	0.10	2.14	0.94
	آزمون Test	23	0.10	15.02	5.50	3.94	0.61	2.94	1.00
جهت (درجه) Aspect (degree)	کل All	150	0	359.42	176.44	107.15	0.02	1.78	-
	آموزش Training	104	0	355.09	175.63	108.94	0.04	1.76	0.95
	اعتبارسنجی Validation	23	31.13	332.24	182.80	98.48	0.08	1.80	0.97
	آزمون Test	23	0	359.42	173.76	111.59	-0.06	1.77	0.99
شاخص خیزی Wetness index	کل All	150	4.75	43.58	9.37	6.74	3.28	14.80	-
	آموزش Training	104	4.75	39.07	9.33	6.46	3.33	15.30	0.99
	اعتبارسنجی Validation	23	4.86	43.58	9.26	8.06	3.83	19.26	0.94
	آزمون Test	23	4.76	34.43	9.64	6.89	2.58	10.44	1.00


جدول ۳- کارایی شبکه‌های عصبی مصنوعی برگزیده شده

Table 3- Performance of selected ANN models

متغیرهای ورودی Input variables	تعداد گره No. of nodes	MSE (%) ²	ME (%)	NS	R ²	P Value
ارتفاع Elevation	3	131.07	-0.037	0.23	0.23	-
ارتفاع، جهت شیب Elevation, Aspect	5	114.88	0.01	0.33	0.33	0.0106

بخش‌های بعدی پس از حذف این تغییرات از کل تغییرات مکانی ماده آلی خاک باقیمانده تغییرات، که تغییرات کوتاه‌برد می‌باشند، توسط روش کریجینگ به دام انداخته شده و دقت پیش‌بینی افزایش داده می‌شود.

در شکل (۴) مقادیر پیش‌بینی شده ماده آلی خاک با استفاده از مدل شبکه عصبی انتخاب شده در برابر مقدار اندازه‌گیری شده آن نشان داده شده است. هرچند که مدل بدست آمده تنها می‌تواند در حدود ۳۳ درصد از تغییرات ماده آلی خاک را توصیف کند، با این وجود از نظر نشان دادن روند کلی تغییرات ماده آلی خاک ارزشمند است.



شکل ۴- مقادیر اندازه‌گیری شده ماده آلی خاک در برابر مقادیر پیش‌بینی شده آن با استفاده از شبکه عصبی مصنوعی
Figure 4- Measured vs. predicted soil organic matter using artificial neural network

استفاده از مدل شبکه عصبی مصنوعی بدست آمده حذف شد، مقادیر باقیمانده‌ها به روش کریجینگ معمولی درون‌یابی شدند. ویژگی‌های واریوگرام باقیمانده‌ها در جدول (۴) نشان داده شده است. در اینجا نیز مشابه بودن واریوگرام‌های به‌دست‌آمده در جهت‌های مختلف بیانگر همسانگرد بودن این پارامتر در منطقه مورد مطالعه بود. نتایج حاصل از ارزیابی مقاطع (شکل ۵-ب) نشان داد که دقت این روش در مقایسه با روش کریجینگ معمولی به مقدار قابل توجهی افزایش یافته، بطوری‌که این روش می‌تواند ۸۹ درصد از تغییرات مکانی ماده آلی خاک را توصیف کند. مقدار شاخص نش-ساتکلیف برابر ۰/۸۲ است که بیانگر کارایی بالای این روش در پیش‌بینی تغییرات مکانی ماده آلی خاک است. همچنین مقدار شاخص ME در این روش نسبت به روش کریجینگ معمولی به اندازه کافی به صفر نزدیک شده است که بیانگر عدم وجود خطاهای سیستماتیک در این روش است.

نتایج فوق نشان می‌دهند که مقدار ماده آلی خاک در منطقه مورد مطالعه دارای دو مؤلفه است. یک مؤلفه قطعی و یک مؤلفه تصادفی. مؤلفه قطعی که بیانگر روند کلی تغییرات ماده آلی خاک است ۳۳ درصد از تغییرات کلی ماده آلی خاک را در بر می‌گیرد. این مؤلفه با استفاده از یک مدل شبکه عصبی مصنوعی و به کمک شاخص‌های توپوگرافی استخراج گردید. باقیمانده تغییرات که دارای همبستگی مکانی بود توسط روش کریجینگ معمولی قابل توصیف بود.

درون‌یابی به روش کریجینگ معمولی

در روش کریجینگ معمولی بهترین نتایج بر مبنای مقدار نرمال شده ماده آلی خاک بدست آمد. ویژگی‌های واریوگرام در این روش در جدول (۴) نشان داده شده است. مشابه بودن واریوگرام‌های به‌دست‌آمده در جهت‌های مختلف بیانگر همسانگرد بودن این پارامتر در منطقه مورد مطالعه بود. نتایج حاصل از ارزیابی مقاطع (شکل ۵-الف) نشان داد که این روش دارای خطاهای سیستماتیک می‌باشد؛ بدین معنی که در مقادیر کمتر کربن آلی خاک دارای خطای بیش برآوردی و در مقادیر بیشتر آن دارای خطای کم‌برآوردی است. مقدار شاخص نش-ساتکلیف برای این روش کم و منفی است. این روش تنها می‌تواند ۳۷ درصد از تغییرات مکانی ماده آلی خاک را توجیه کند. همه این نتایج نشان می‌دهند که روش کریجینگ معمولی نیز به تنهایی برای برآورد تغییرات مکانی ماده آلی خاک در منطقه مورد مطالعه کافی نیست و برای توصیف دقیق‌تر این تغییرات بایستی از متغیرهای کمکی نیز بهره گرفت. این مسأله ممکن است ناشی از تراکم پایین نقاط نمونه‌برداری باشد؛ زیرا همانطور که پیشتر نیز اشاره شد، برای حصول نتایج مطلوب در روش کریجینگ معمولی بایستی تراکم نقاط نمونه‌برداری بالا باشد (۱۱).

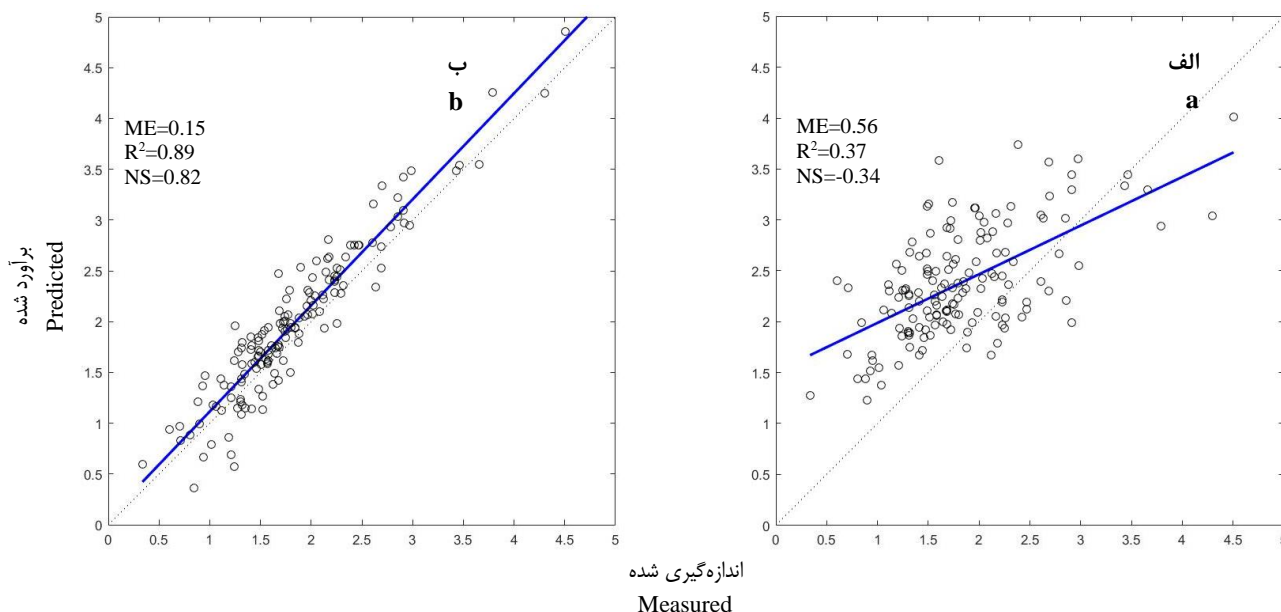
درون‌یابی به روش شبکه عصبی مصنوعی - کریجینگ

در این روش پس از آنکه روند کلی داده‌های ماده آلی خاک با

جدول ۴- پارامترهای واریوگرام‌های برازش داده شده

Table 4- Parameters of optimized variogram models

متغیر Variable	طول گام (m) Lag distance (m)	مدل Model	اثر قطعه‌ای Nugget	آستانه Sill	دامنه (m) Range (m)	ناهمسانگردی Anisotropy
ماده آلی (%) Organic matter (%)	1237	Spherical	0.19	0.39	6357	No
باقیمانده‌ها (%) Residuals (%)	863	Spherical	0.10	0.25	2897	No

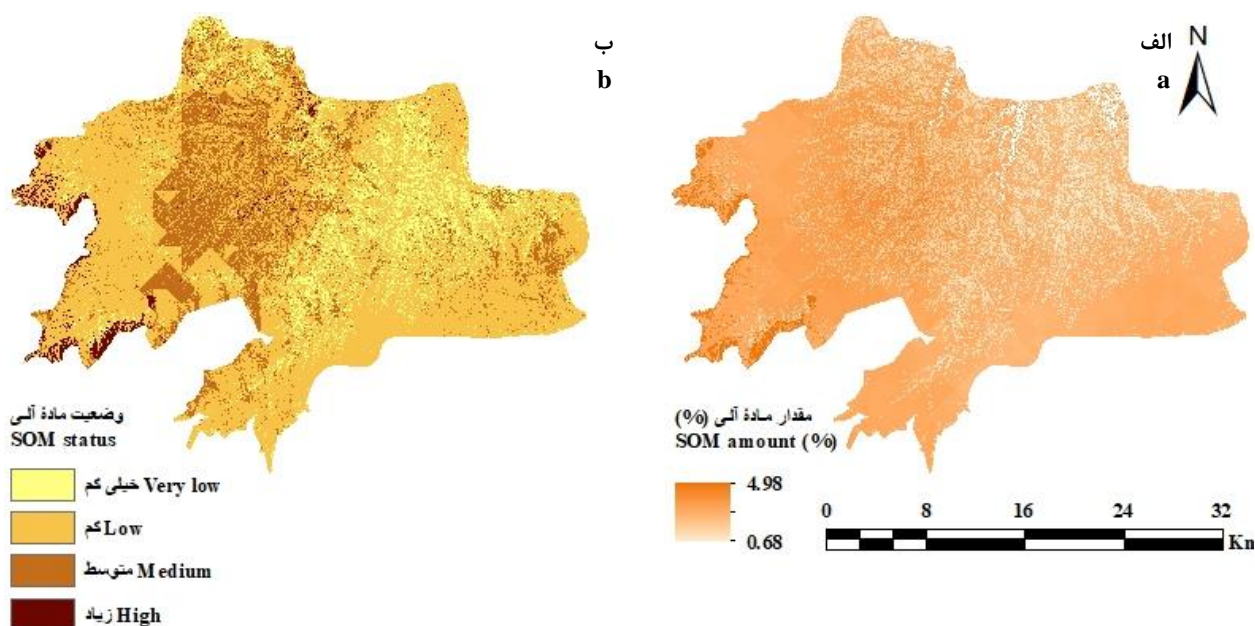


شکل ۵- ارزیابی مقاطع درون‌یابی ماده آلی خاک به روش‌های الف: کریجینگ معمولی و ب: شبکه عصبی مصنوعی - کریجینگ
Figure 5- Cross-validation of soil organic matter interpolation based on a) ordinary kriging and b) ANN-kriging methods

نقشه‌های مقدار و وضعیت ماده آلی خاک

در شکل ۶-الف نقشه مقدار ماده آلی خاک در منطقه مورد مطالعه که با استفاده از تکنیک شبکه عصبی مصنوعی - کریجینگ تهیه شده است، نشان داده شده است. همانطور که ملاحظه می‌شود مقدار ماده آلی خاک بتدریج از شمال شرق به جنوب غرب افزایش می‌یابد. این موضوع را می‌توان به افزایش تراکم کشت آبی و تولید بیشتر بیوماس گیاهی و به تبع آن ترسیب بیشتر کربن آلی در خاک نسبت داد. در شکل ۶-ب نقشه وضعیت ماده آلی خاک در منطقه مورد مطالعه نشان داده شده است. این نقشه از همپوشانی نقشه مقدار ماده آلی خاک و نقشه بافت خاک (شکل ۲) بر اساس معیارهای داده شده در جدول (۱) بدست آمده است. همانطور که این نقشه نشان می‌دهد مقدار ماده آلی در حدود ۱۳ درصد از خاک‌های منطقه در وضعیت خیلی کم و در حدود ۶۶ درصد آن در وضعیت کم قرار دارد. حدود ۱۹ درصد از خاک‌های منطقه از نظر مقدار ماده آلی در وضعیت متوسطی قرار دارند. این در حالیست که تنها در حدود ۲ درصد از این

خاک‌ها از نظر ماده آلی خاک در وضعیت بالایی قرار دارند. این نتایج بیانگر آنند که خاک‌های منطقه مورد مطالعه از نظر ماده آلی وضعیت مناسبی ندارند. کمبود ماده آلی این خاک‌ها ممکن است ناشی از فرسایش خاک تحت شرایط اقلیم مدیترانه‌ای و اراضی تپه‌ای توأم با فعالیت‌های زراعی شدید یا نامناسب در منطقه باشد. در این مناطق معمولاً فراوانی باران‌های فرسایش‌زا در اوایل فصل کشت گیاهان (بهار و پاییز) که زمین لخت و عاری از پوشش گیاهی است زیاد است. فرسایش خاک باعث از دست رفتن مقدار قابل توجهی خاک خوب زراعی که حاوی هوموس و عناصر غذایی است می‌شود. افزایش ماده آلی خاک در این منطقه می‌تواند با انجام اقدامات حفاظت خاک مانند شخم حفاظتی، خاکورزی بدون شخم، استفاده از گیاهان علوفه ای در تناوب زراعی، بازگرداندن بقایای گیاهی به خاک، کود سبزی و همچنین افزودن کودهای آلی به خاک مانند کمپوست، کود دامی، لجن فاضلاب و غیره صورت پذیرد.



شکل ۶- نقشه‌های الف- مقدار و ب- وضعیت ماده آلی خاک در منطقه مورد مطالعه
Figure 6- Maps of soil organic matter a) content and b) status of the study area

مصنوعی نشان داد که ارتفاع و جهت شیب اثر معنی‌داری بر روند تغییرات مکانی ماده آلی خاک دارند. استفاده از این متغیرها بعنوان متغیر کمکی دقت روش کریجینگ را برای درون‌یابی ماده آلی خاک به مقدار قابل ملاحظه‌ای افزایش داد. این روش توانست ۸۹ درصد از تغییرات ماده آلی خاک را توصیف کند. همچنین نقشه بدست آمده وضعیت ماده آلی خاک‌های منطقه نشان داد که در حدود ۷۹ درصد از خاک‌های منطقه از نظر ماده آلی در وضعیت خیلی کم و کم قرار دارند. این مسأله لزوم حفظ و حراست از ماده آلی و ترسیب آن در خاک را در برنامه‌های مدیریت خاک در این منطقه آشکار می‌سازد.

نتیجه‌گیری

در این پژوهش کارایی روش‌های کریجینگ معمولی، شبکه‌های عصبی مصنوعی و نیز روش تلفیقی شبکه عصبی مصنوعی - کریجینگ برای توصیف تغییرات ماده آلی خاک مورد ارزیابی قرار گرفت. نتایج بدست آمده نشان داد در صورتی که تراکم نقاط نمونه برداری کم باشد، روش کریجینگ معمولی به تنهایی قادر به توصیف تغییرات مکانی ماده آلی خاک نیست. هرچند که مدل شبکه عصبی بدست آمده تنها توانست در حدود ۳۳ درصد از تغییرات ماده آلی خاک را توصیف کند، با این وجود از آن برای حذف روند کلی تغییرات ماده آلی خاک استفاده شد. نتایج بدست آمده از شبکه‌های عصبی

منابع

- 1- Beven K.J., and Kirkby M.J. 1979. A physically based, variable contributing area model of basin hydrology. *Hydrological Sciences Bulletin*, 24:43-69.
- 2- Bishop C.M. 1995. *Neural networks for pattern recognition*. Oxford University Press, Oxford, 482.
- 3- Burgess T.M., and Webster, R. 1980. Optimal interpolation and isarithmic mapping of soil properties: the semivariogram and punctual kriging. *Soil Science*, 31:315-331.
- 4- Burrough P.A. 1986. *Principles of geographical information systems for land resources assessment*. Oxford university press, New York.
- 5- Chivenge P.P., Murwira H.K., Giller K.E., Mapfumo P., and Six J. 2007. Long-term impact of reduced tillage and residue management on soil carbon stabilization: implications for conservation agriculture on contrasting soils. *Soil and Tillage Research*, 94:328-337.
- 6- Eldeiry A., and Garcia L.A. 2009. Comparison of Regression kriging and cokriging techniques to estimate soil salinity using Landsat images. *Hydrology Days*, 27:38.
- 7- Guo P.T., Wu W., and Sheng Q.K. 2013. Prediction of soil organic matter using artificial neural network and topographic indicators in hilly areas. *Nutrient Cycling in Agroecosystems*, 95:333-344.

- 8- Ingleby H.R., and Crowe T.G. 2001. Neural network models for predicting organic matter content in Saskatchewan soils. *Canadian Biosystems Engineering*, 43:71-75.
- 9- Istok J.D., Smyth J.D., and Flint A.L. 1993. Multivariate geostatistical analysis of groundwater contaminant: a case history. *Groundwater*, 31:63-74.
- 10- Li Z.Y. 1998. Supervised classification of multi-spectral remote sensing image using B-P neural network. *Journal of Infrared and Millimeter Waves*, 17:153-156.
- 11- Liao K., Xu S., Wu J., and Zhu Q. 2013. Spatial estimation of surface soil texture using remote sensing data. *Soil Science and Plant Nutrition*, 59(4):488-500.
- 12- Mahmoodi S., and Hakimian M. 1998. Fundamentals of soil science. Tehran university press, Tehran. (In Persian)
- 13- Marchetti A., Piccini C., Francaviglia R., and Mabit L. 2012. Spatial distribution of soil organic matter using geostatistics: A key indicator to assess soil degradation status in central Italy. *Pedosphere*, 22(2):230-242.
- 14- McBratney A.B., and Webster R. 1986. Choosing functions for semivariograms of soil properties and fitting them to sampling estimates. *Journal of Soil Science*, 37:617-639.
- 15- McBratney A.B., Santos M.L.M., and Minasny B. 2003. On digital soil mapping. *Geoderma*, 117: 3-52.
- 16- Mirzaie M. 2015. Prediction of soil organic matter based on soil characteristics, topography and remote sensing data using artificial neural networks. M.Sc. thesis, University of Kurdistan, Sanandaj. (In Persian with English abstract)
- 17- Moore A.D., McLaughlin R.A., Mitasova H., and Line D.E. 2007. Calibrating WEPP model parameters for erosion prediction on construction sites. *Transactions of the ASABE*, 50(2):507-516.
- 18- Mulla D.J., and McBratney A.B. 2000. Soil Spatial Variability. p. 343-373. In A.W. Warrick (ed.) *Soil Physics Companion*. CRC Press, NewYork.
- 19- Nash J.E., and Sutcliffe J.V. 1970. River flow forecasting through conceptual models: Part I. A discussion of principles. *Journal of Hydrology*, 10(3):282-290.
- 20- Odeh I.O.A., McBratney A.B., and Chittleborough D.J. 1995. Further results on prediction of soil properties from terrain attributes: Heterotopic cokriging and regression-kriging. *Geoderma*, 67(3-4):215-226.
- 21- Quinton J.N. 1997. Reducing predictive uncertainty in model simulations: A comparison of two methods using the European Soil Erosion Model (EUROSEM). *Catena*, 30(2): 101-117.
- 22- Shouse P.J., Gerik T.J., Russell W.B., and Cassel D.K. 1990. Spatial distribution of soil particle size and aggregate stability index in a clay soil. *Soil Science*, 149:351-360.
- 23- Societ`a Italiana dei Laboratori Pubblici di Agrochimica (SILPA). 1999. From soil analysis to the fertilization advice. ASSAM, Agenzia Servizi SettoresAgroalimentare delle Marche, Regione Marche, Jesi, Italy. (In Italian)
- 24- Triantafilis J., Odeh I.O.A., and McBratney A.B. 2001. Five geostatistical models to predict soil salinity from electromagnetic induction data across irrigated cotton. *Soil Science Society of America Journal*, 65:869-878.
- 25- Vauclin M., Vieira S.R., Vachaud G., and Nielsen D.R. 1983. The use of cokriging with limited field observations. *Soil Science Society of America Journal*, 47:175-184.
- 26- Walkley A., and Black I.A. 1934. An examination of the Degtjareffmethod for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Science*, 37:29-38.
- 27- Wu C., Wu J., Luo Y., Zhang L., and DeGloria S.D. 2009. Spatial prediction of soil organic matter content using cokriging with remotely sensed data. *Soil Science Society of America Journal*, 73:1202-1208.
- 28- Yadav V., and Malanson G. 2007. Progress in soil organic matter research: litter decomposition, modeling, monitoring and sequestration. *Progress in Physical Geography*, 31:131-154.
- 29- Yates S.R., and Warrick A.W. 1987. Estimating soil water content using cokriging. *Soil Science Society of America Journal*, 51:23-30.
- 30- Zhao Z., Yang Q., Benoy G., Chow T.L., Xing Z., Rees H.W., and Meng F.R. 2010. Using artificial neural network models to produce soil organic carbon content distribution maps across landscapes. *Canadian Journal of Soil Science*, 90:75-87.

Prediction of Soil Organic Matter Spatial Distribution Using Topographic Indicators and Artificial Neural Network-Kriging Technique

M. A. Mahmoodi^{1*} - M. Mirzaie² - S. M. T. Hosseini³

Received: 25-09-2017

Accepted: 23-04-2018

Introduction: Soil organic matter (SOM) is an important soil quality factor that affects physical, chemical and biological properties of soil. Accurate estimation of SOM variability provides critical information especially in precision agriculture. Geostatistics and geographic information system (GIS) are powerful tools for characterizing and mapping the spatial distribution and variability of soil properties. Kriging is a basic geostatistical technique that provides the best linear unbiased estimation for a spatially dependent variable. This method will produce satisfying results if enough sample points are available. Unfortunately, laboratory measurements of the SOM are costly and time-consuming. Artificial neural network-kriging (ANNK) is another geostatistical method that extends kriging of a primary variable to the readily available auxiliary variables based on their relationship with the primary variable. This relationship is captured using an artificial neural network (ANN) model. The residuals of the model were then interpolated using kriging, and added to the prediction obtained from the ANN model. Terrain attributes, derived from digital elevation models (DEMs), are useful for estimating SOM at landscape scale. Topographic indicators including slope, aspect, elevation, and topographic wetness index may be the dominant factors affecting SOM variability in an area with same parent material and climate. Hence, these factors can be used as auxiliary variables for estimating spatial variability of SOM using ANNK. The objective of this study was to estimate SOM spatial variability using ANNK and topographic indices and assess its status in hilly areas of Ghorveh in Kurdistan province (Iran).

Materials and Methods: A total of 150 soil samples from a depth of 0-15 cm were systematically collected in a grid spaced 2 Km × 2 Km. The SOM content of soil samples was measured in the laboratory. Topographic indicators including slope, aspect, elevation, and topographic wetness index were derived from the DEM. ANN was used to predict SOM variability based on topographic index combinations. The feed-forward network consisted of an input layer, one hidden layer with sigmoid neurons, and an output layer with linear neurons. The network was trained with Levenberg-Marquardt backpropagation algorithm. According to the Kolmogorov's theorem, the number of nodes in the hidden layer was $2n+1$, in which n is the number of input neurons. The optimal subset of topographic index combinations correlating best with the SOM was selected as the best ANN model. This model was used to generate an initial SOM surface. The residuals of ANN model were interpolated using ordinary kriging (OK) and combined with the initial SOM surface to produce the final ANNK SOM surface. The SOM status map was derived from overlaying of soil texture and SOM maps in four different levels (very low, low, medium and high).

Results and Discussion: The results of ANN suggested that elevation was the most important variable determining the distribution of SOM across the landscape. Further, aspect was the other variable which had a significant influence on SOM distribution. The selected two inputs ANN model (elevation and aspect) can explain about 33% of total variance of SOM. The cross-validation results indicated that the OK and ANNK techniques can explain about 37 and 89% of total variance of SOM, respectively. The ANNK technique performed better than the OK and ANN techniques since it was able to capture most of the small variations of SOM. The resulting SOM status map indicated a low and very low SOM content in relation with soil texture in most regions surveyed (79%). Low SOM level can be attributed to the erosive processes under Mediterranean climate on hills coupled with intensive and/or inappropriate agricultural practices. Based on the results of this study, proper agronomical and environmental planning such as soil conservation strategy is highly required in this area to restore and increase the SOM content in agricultural soils, combat soil erosion and maintain soil ecological functions and productivity. The SOM replenishment can be achieved in the degraded areas (*i.e.*, low SOM content) by adopting conservative practices such as conservation tillage or no-tillage (*e.g.*, direct seeding), improving land use rotations with forage crops, returning crop residues to soil, growing green manure crops, and

1, 2 and 3- Assistant Professor, Graduated M.Sc. Student and Instructor, Department of Soil Science, University of Kurdistan, Sanandaj, Iran, Respectively

(* - Corresponding Author Email: a.mahmoodi@uok.ac.ir)

supplying the soil with proper exogenous organic matter (compost, manure, sewage sludge, *etc.*). Furthermore, the results highlighted the potential of ANNK in combination with GIS to provide improved distribution patterns of SOM.

Keywords: Artificial neural network-kriging, Soil organic matter, Spatial variability, Terrain attributes

