

مقاله پژوهشی

برآورد مقدار کربن آلی خاک با استفاده از داده‌های طیفی در گستره VIS-NIR-SWIR-TIR

حمیدرضا متین فر^{۱*} - محبوبه جلالی^۲ - زهرا دیبایی^۳

تاریخ دریافت: ۱۴۰۰/۰۴/۱۲

تاریخ پذیرش: ۱۴۰۰/۰۵/۲۰

چکیده

شناخت توزیع مکانی کربن آلی خاک یکی از ابزارهای کاربردی در پیشبرد مدیریت پایدار اراضی و محیط زیست می‌باشد. داده‌های مدلسازی مکانی همراه با تکنیک‌های یادگیری ماشینی به منظور بررسی میزان کربن آلی خاک مبتنی بر داده‌های سنسور از دور به صورت گسترده مورد توجه قرار گرفته است. هدف از این مطالعه، استفاده از تصاویر با دامنه طیفی مرئی تا مادون قرمز حرارتی و داده‌های زمینی برای مدلسازی میزان کربن آلی خاک می‌باشد. با استفاده از الگوی نمونه‌برداری تصادفی ۱۵۶ نمونه از خاک سطحی (۳۰-۰ سانتی‌متر) جمع‌آوری شد. داده‌ها به دو دسته ۸۰ درصد برای آموزش و ۲۰ درصد جهت اعتبارسنجی دسته‌بندی شدند و از سه الگوریتم یادگیری ماشین شامل جنگل تصادفی، کویست و رگرسیون حداقل مربعات جزئی برای برآورد و تهیه نقشه کربن آلی خاک استفاده شد. متغیرهای کمکی جهت پیش‌بینی کربن آلی خاک شامل باندها و شاخص‌های منتج از سنجنده‌ی OLI و TIRS لندست ۸ می‌باشد. به منظور کاهش حجم داده‌ها و انتخاب ویژگی‌هایی با بیشترین تأثیر بر برآورد کربن آلی خاک، از روش آنالیز مؤلفه‌های اصلی استفاده شد. آنالیز مؤلفه‌های اصلی داده‌های سنسور از دور منجر به گزینش ۴ متغیر کمکی Band 10، RVI، TSAVI و Band 11 به عنوان مؤثرترین عوامل کمکی محیطی انتخاب گردیدند. همچنین مقایسه رویکردهای مختلف تخمین نشان داد که مدل جنگل تصادفی به ترتیب با مقادیر ضریب تبیین، خطای جذر میانگین مربعات و میانگین مربعات خطا ۰/۷۴، ۰/۱۷ و ۰/۰۲ بهترین کارایی را نسبت به سایر رویکردهای مورد استفاده در برآورد کربن آلی خاک سطحی در منطقه مطالعاتی ارائه نمود. به طور کلی نتایج این مطالعه بر قابلیت داده‌های سنسور از دور و مدل یادگیری جنگل تصادفی در تخمین مکانی کربن آلی خاک به طور همزمان دلالت دارد. لذا می‌تواند به عنوان روشی جایگزین برای روش‌های مرسوم آزمایشگاهی در تعیین برخی ویژگی‌های خاک از جمله کربن آلی خاک مورد توجه قرار گیرد.

واژه‌های کلیدی: توزیع مکانی، سنجنده لندست ۸، طیف مرئی مادون قرمز، کربن آلی خاک، مدلسازی

مقدمه

غذایی، تسریع فعالیت‌های بیولوژیکی و افزایش ظرفیت تبادل یونی خاک نیز تأثیر بسزایی دارد (۳، ۹ و ۳۴). اهمیت اصلی مواد آلی خاک در کیفیت، کمیت، پایداری خاک و سلامت محیط زیست می‌باشد (۹). کربن آلی خاک شاخص مهمی برای ارزیابی وضعیت حاصلخیزی خاک و از شاخص‌های اصلی کیفیت خاک است و هدررفت آن موجب تخریب اراضی می‌گردد (۲۱). وظیفه نهایی کربن آلی خاک حفظ تنوع زیستی^۳ جهت افزایش سلامت خاک در فرایند تولید هر ساله محصولات کشاورزی می‌باشد (۹). همچنین کربن آلی خاک بخشی از چرخه بسیار بزرگتر جهانی کربن، شامل چرخه کربن از طریق خاک، پوشش گیاهی، اقیانوس و اتمسفر می‌باشد (۱۲). ذخایر مخزن کربن آلی خاک در یک متر اولیه خاک (۱۵۰۰) پیکوگرم^۴ برآورد می‌شود که

ماده آلی بعنوان یک ویژگی بسیار مهم از خاک، اهمیت بسیاری در توسعه و مدیریت کشاورزی پایدار دارد. ماده آلی خاک تأثیر قابل توجهی بر فعل و انفعالات خاک-گیاه داشته و ارتباط تنگاتنگی با کیفیت خاک دارد. این ماده به عنوان شاخصی برای بیان تخریب و فرسایش خاک، فاکتور تنظیم کننده فرایندهایی از جمله دسترسی گیاه به نیتروژن توانایی خاک برای جذب مواد غذایی، و قابلیت دسترسی زیستی عناصر غذایی مورد نیاز گیاه محسوب می‌شود. همچنین بر تولید محصول، تشکیل ساختمان خاک، تنظیم و آزادسازی مواد

۱، ۲ و ۳- به ترتیب دانشیار، استادیار و دانشجوی دکتری گروه علوم و مهندسی خاک، دانشگاه لرستان

(* - نویسنده مسئول)

(Email: Matinfar.h@lu.ac.ir)

DOI: 10.22067/JSW.2021.71065.1062

همبستگی بالایی را بین ماده آلی و نیتروژن کل اندازه‌گیری شده و تخمینی کسب کردند (۲۴، ۱۴ و ۲).

نتایج مدل‌سازی CEC، درصد اشباع بازی، ماده آلی، رس و شن در برزیل حاکی از ارجحیت مدل‌سازی جنگل تصادفی^۶ نسبت به روش‌های PLS بوده است (۱۰). شناسایی توزیع مکانی خصوصیات خاک از جمله کربن آلی در هر منطقه کلید مهمی برای مدیریت صحیح اراضی در کشاورزی پایدار می‌باشد. بنابراین آگاهی و دانش در مورد توزیع منابع کربن و تغییرات آن برای تشخیص مکانیسم‌های کنترلی و پایداری میزان کربن فعلی در مدیریت این اراضی ارزشمند است (۱۶ و ۵). هدف از این مطالعه تعیین قابلیت داده‌های طیفی ماهواره ای در محدوده مرئی- مادون قرمز نزدیک، موج کوتاه و حرارتی و داده‌های زمینی برای مدل‌سازی میزان کربن آلی خاک می‌باشد.

مواد و روش‌ها

موقعیت منطقه مطالعاتی

منطقه مورد مطالعه واقع در استان لرستان، و منطقه سراب چنگایی می‌باشد (شکل ۱). این ناحیه دارای تابستان‌های گرم و خشک و زمستان‌های سرد و مرطوب است و فصل مرطوب از آبان ماه شروع و در اردیبهشت ماه خاتمه می‌یابد. میانگین بارندگی سالیانه آن ۵۱۶ میلی‌متر و حداکثر بارندگی در ماه فروردین به مقدار ۷۸/۱ میلی‌متر گزارش شده است. با توجه به نقشه رژیم‌های رطوبتی و حرارتی خاک‌های ایران، رژیم رطوبتی خاک‌های منطقه زیریک^۷ می‌باشد. از نظر فیزیوگرافی خاک‌های منطقه مورد مطالعه بر روی واحد دشت‌های دامنه‌ای با حداقل و حداکثر شیب دو و پنج درصد قرار دارند. جهت شمال-جنوب، جهت شیب غالب در منطقه مطالعاتی می‌باشد. مواد مادری خاک‌ها بر اساس نقشه زمین‌شناسی منطقه با مقیاس ۱/۱۰۰۰۰۰ (سازمان زمین‌شناسی کشور)، شامل مواد مادری با منشأ آهکی که مربوط به دوران زمین‌شناسی کرتاسه تا پلیوسن می‌باشد. رده‌بندی خاک‌های منطقه بر اساس سامانه رده‌بندی آمریکایی (۲۰۱۴) و نقشه خاک با مقیاس ۱:۵۰۰۰۰ موجود در دو رده اینسپتی‌سول و انتی‌سول قرار دارند. کار بری اراضی محدوده مطالعاتی زراعت ابی، شامل گندم، جو و ذرت می‌باشد.

کربن بیشتری از آنچه که در اتمسفر (تقریباً ۸۰۰ پیکوگرم) و پوشش گیاهی (۵۰۰ پیکوگرم) است (۱۳). این مخزن دائمی کربن آلی دائماً بین مخازن مختلف جهانی کربن در اشکال مختلف در حال چرخش است (۲۰). مقدار مواد آلی خاک عموماً بر اساس مقدار کربن آلی خاک (SOC^۱) اندازه‌گیری می‌شود. محققین نشان دادند که تغییرات کاربری اراضی منجر به درخطر افتادن محتوا و ترکیب مواد آلی خاک شده است، بنابراین پایش مستمر میزان کربن آلی خاک می‌تواند نقشی مهمی در کنترل کیفیت و عملکرد خاک داشته باشد (۲۵ و ۲۸). از آنجا که روش‌های معمول آزمایشگاهی اندازه‌گیری کربن آلی خاک، به ویژه در مقیاس‌های مکانی بزرگ خصوصاً در سطح ملی، عمدتاً پرهزینه و زمان‌بر هستند و آنالیزهای شیمیایی آزمایشگاهی اندازه‌گیری کربن آلی با ورود کروم شش ظرفیتی ناشی از دی کرومات پتاسیم در ایجاد بسیاری از سرطان و بیماری‌های نورودژنراتیو مثل پارکینسون و آلزایمر نقش دارد (۸). به همین دلیل، امروزه استفاده موفقیت‌آمیز از روش‌های رقومی همچون فناوری سنسجش از دور و نزدیک در تخمین بسیاری از ویژگی‌های خاک و گیاه، محققین علوم خاک را به سوی استفاده از این فناوری نوین سوق داده است. استفاده از داده‌های سنسجند OLI ماهواره لندست ۸ جهت پیش-بینی ویژگی شاخص سطح برگ در مراحل مختلف رشد گیاه ذرت دانه‌ای (۲۹) و استفاده از محدوده مرئی-مادون قرمز نزدیک توسط سنسجند‌های مختلف از جمله این موارد است (۶). تخمین کربن آلی خاک در تکنیک‌های سنسجش از دور و نزدیک اغلب در محدوده مرئی و مادون قرمز نزدیک انجام می‌شود (۲۳، ۷، ۱۰ و ۴).

در سال‌های اخیر تکنیک‌های چندمتغیره شبیه الگوریتم رگرسیون حداقل مربعات جزئی^۲ و شبکه‌های عصبی مصنوعی^۳ و کوبیست^۴ به منظور ایجاد مدل‌های تخمین کربن آلی خاک استفاده شده است. برخی طول موج‌ها با مقدار کربن آلی در خاک ارتباط دارند (۳۵ و ۳۷). در برخی از مطالعات طیف‌سنجی مرئی-مادون قرمز در سطح آزمایشگاهی برای کمی نمودن کربن آلی و نیتروژن کل خاک موفق بوده است. در تحقیقی برآورد مقدار ماده آلی خاک را با استفاده از مدل‌های آماری و رگرسیون حداقل مربعات جزئی و رگرسیون مؤلفه اصلی PCA^۵ انجام شد. نتایج مدل‌سازی به روش رگرسیون حداقل مربعات جزئی نشان داد که مقادیر R²، RMSE و RPD در مرحله اعتبارسنجی برای پیش‌بینی ماده آلی به ترتیب ۰/۸۵، ۰/۱۴ و ۲/۷۸ بوده است (۲۹). سایر مطالعاتی که از مدل PLSR استفاده کردند نیز

1 Soil Organic Carbon

2 Partial least-squares regression

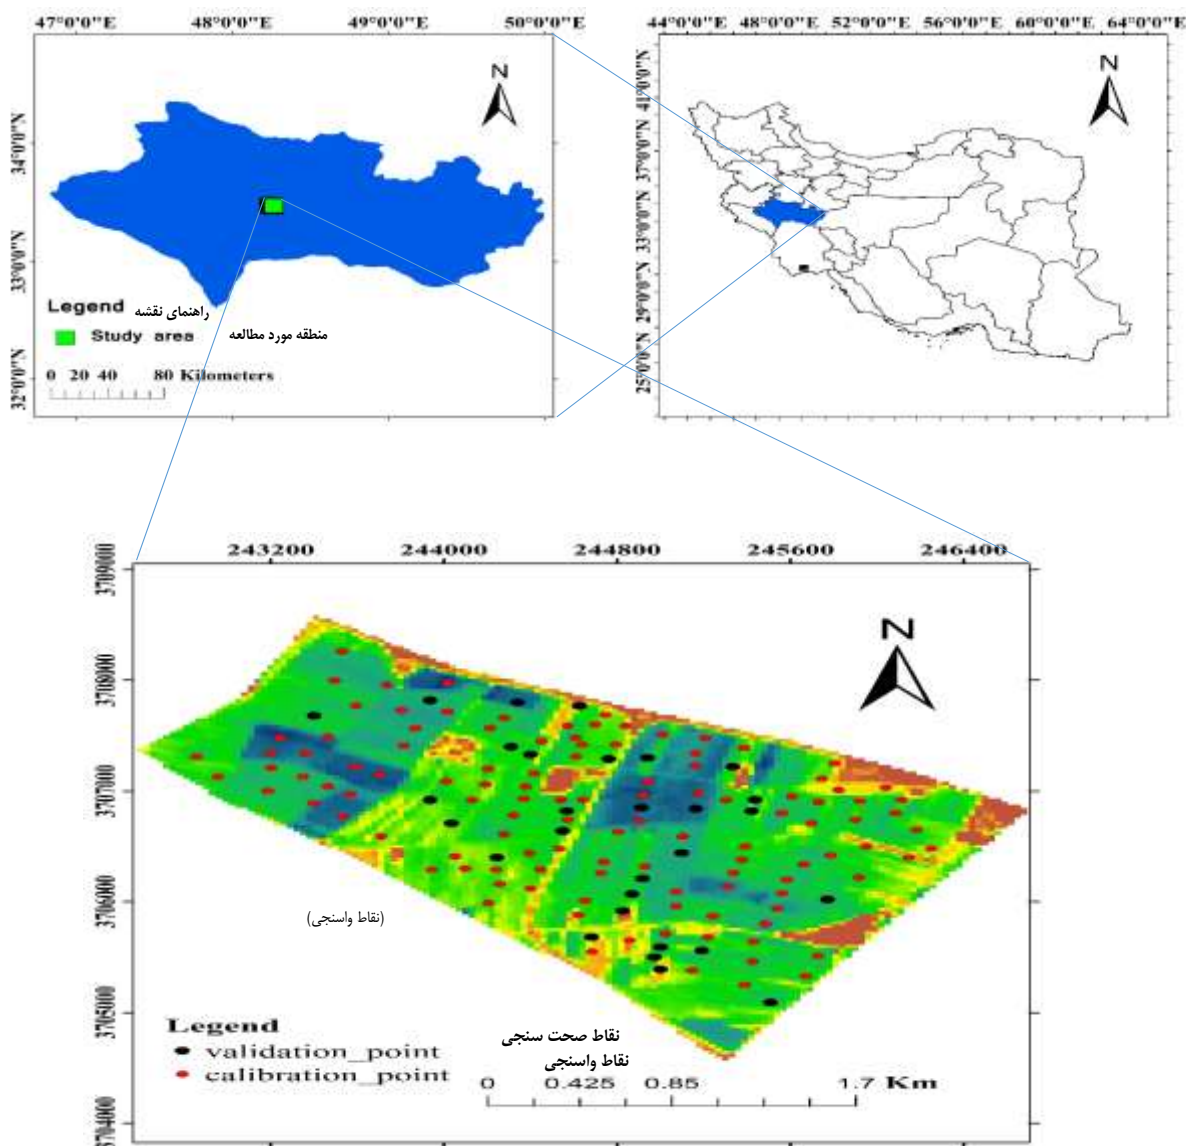
3 Artificial Neural Network (ANN)

4- Cubist

5- Principal Component Analysis

6- Random Forest

7- Xeric



شکل ۱- موقعیت منطقه و نقاط مورد مطالعه
Figure 1- Location of the study area and points

متغیرهای کمکی محیطی

در مطالعه حاضر، از باندهای مربوط به تصاویر سنجنده‌ی OLI لندست ۸ (۸ ژوئن ۲۰۱۸)، در مسیر و ردیف ۱۶۶ و ۳۷ تصاویر از پایگاه اینترنتی (USGS) دریافت شده است (۳۹). با توجه به هدف پژوهش، باندهای مرئی (باندهای ۲، ۳ و ۴)، مادون قرمز نزدیک (باند ۵)، مادون قرمز طول موج کوتاه (باندهای ۶ و ۷) با اندازه پیکسل‌های ۳۰ متر و باندهای حرارتی (باندهای ۱۰ و ۱۱) با اندازه پیکسل‌های ۱۰۰ متر برای استخراج ارزش‌های طیفی متناظر با نقاط زمینی و تجزیه و تحلیل استفاده شد.

نمونه‌برداری و تجزیه و تحلیل آزمایشگاهی

جهت تعیین نقاط نمونه‌برداری پس از تفسیر چشمی تصویر رنگی کاذب و مشاهدات میدانی بر اساس الگوی نمونه‌برداری تصادفی، ۱۵۶ نقطه انتخاب و نمونه‌های خاک از عمق ۰-۳۰ سانتی‌متری برداشت شد. نمونه‌ها پس از انتقال به آزمایشگاه هوا خشک شده و از الک ۲ میلی‌متری عبور داده شدند. سپس مقدار کربن آلی به روش والکی و بلک (۴۰)، اندازه‌گیری و محاسبه شد.

جدول ۱- شاخص‌های گیاهی منتج از داده‌های طیفی
Table 1- Plant indices resulting from spectral data

شاخص Index	مخفف Abbreviation	رابطه Formula	منبع References
(شاخص گیاهی درصد مادون قرمز نزدیک) Infrared Percentage Vegetation Index	IPVI	$\frac{NIR}{NIR + Red}$	(41)
(شاخص گیاهی تعدیل کننده اثر خاک) Soil Adjusted Vegetation Index	SAVI	$\frac{(1 + L) (NIR - Red)}{(NIR + Red + L)}$	(17)
(شاخص تغییر یافته گیاهی تعدیل کننده اثر خاک) Transformed Soil Adjusted Vegetation Index	TSAVI	$\frac{a(NIR - aRed - b)}{Red + a(NIR - a) + 0.08(1 + a^2)}$	(1)
(شاخص گیاهی تعدیل کننده اثر خاک (۲)) Soil Adjusted Vegetation Index2	SAVI2	$\frac{NIR}{Red + \frac{b}{a}}$	(26)
(شاخص نسبی) Ratio Vegetation Index	RVI	$\frac{NIR}{Red}$	(41)
(شاخص بهینه شده گیاهی تعدیل کننده اثر خاک) Optimized Soil Adjusted Vegetation Index	OSAVI	$\frac{1.16 (NIR - Red)}{(NIR + Red + 0.16)}$	(33)

جنگل تصادفی

مدل جنگل تصادفی (RF^۱) یک روش نوین و قدرتمند در فرآیند مدل سازی می‌باشد که پیشرفت قابل ملاحظه‌ای در تکنولوژی داده‌کاوی ارائه داده است. رویکرد جنگل تصادفی مبتنی بر روش‌های جدید ترکیب اطلاعات است که در آن تعداد زیادی درخت تصمیم ایجاد گردیده است. سپس تمام درختان با هم برای پیش‌بینی ترکیب می‌شوند. در روش یادگیری جنگل تصادفی، هر درخت تصمیم‌گیری با استفاده از یک نمونه تصادفی از داده‌های آموزشی، آموزش می‌بیند. همچنین انتخاب متغیرهای پیش‌بینی کننده نیز که برای تقسیم‌بندی گره‌ها استفاده می‌شود. جنگل تصادفی در حقیقت مجموعه‌هایی از درخت‌های پیش‌بینی کننده با احتمال یکسان و دارای پراکندگی یکسان هستند. این روش بر پایه انتخاب خطای داده‌های بزرگ‌تر به عنوان خطای اصلی و ایجاد همبستگی بین خطاهای دیگر داده‌ها است. انتخاب خطای عمومی بر اساس بزرگ‌ترین داده‌ها، پیش‌بینی دقیق‌تر و قابل اعتمادتری به ما می‌دهد و زمانی این پیش‌بینی دقیق‌تر می‌شود که داده‌های ورودی به مدل بدون اعمال تغییرات باشد. این الگوریتم به عنوان یکی از کارآمدترین الگوریتم‌های یادگیری است و برای بسیاری از مجموعه داده‌ها، طبقه‌بندی با صحت بالایی ارائه می‌نماید. ویژگی مثبت این طبقه‌بندی کننده این است که بر روی

تصحیحات هندسی با نقاط کنترل زمینی و دقت نیم پیکسل انجام شد و تصحیح اتمسفری به روش جسم سیاه بر روی تصاویر انجام شد. شاخص‌های گیاهی تبدیلات ریاضی هستند که بر اساس باندهای مختلف سنجنده‌ها تعریف شده و برای ارزیابی و بررسی گیاهان در مشاهدات ماهواره‌ای چند طیفی طراحی شده‌اند. محاسبه و استخراج کلیه داده‌های مزبور برای تمام نقاط نمونه‌برداری در پنجره Raster calculator نرم‌افزار ArcGIS 10.4.1 صورت گرفت. در نهایت کلیه متغیرهای محیطی (سنجش از دور) جهت فرآیند مدل‌سازی به پیکسل سائز یکسان ۱۵ × ۱۵ متر با استفاده از بسته Resampling در نرم‌افزار Arc GIS 10.7.1 تبدیل شدند. همچنین در این پژوهش، شناسایی مؤثرترین متغیرهای کمکی در پیش‌بینی کربن آلی خاک بر اساس آنالیز مؤلفه‌های اصلی که در نرم‌افزار SPSS 21 قابل اجرا است صورت پذیرفت. روش آنالیز مؤلفه‌های اصلی به منظور کاهش حجم داده‌ها، به صورت گزینش ویژگی‌هایی که بیشترین تأثیر را بر متغیر مؤثر در برآورد متغیر وابسته دارند، به صورت زیر مجموعه‌ای از کل ویژگی‌های مورد بررسی خاک استفاده شد (۳۲).

برآورد کربن آلی خاک

در این تحقیق از رویکردهای جنگل تصادفی، کوبیست و رگرسیون حداقل مربعات جزئی برای مدل سازی مکانی کربن آلی خاک استفاده شد.

1- Random Forest

مدل‌سازی مورد استفاده در برآورد میزان کربن آلی خاک از آماره‌های ضریب تبیین R^2 ، ریشه میانگین مربعات خطا^۴ (RMSE) و میانگین خطای استاندارد (MSE)^۵ استفاده شد که معادلات این روش‌ها به شرح زیر است:

اگر انحراف معیار متغیرهای X و Y به ترتیب به صورت Sx و Sy باشد و کواریانس آنها با علامت Covxy نشان داده شود ضریب تبیین از رابطه زیر قابل محاسبه است:

$$R^2 = \frac{s_{xy}^2}{s_{xx} s_{yy}} \quad \text{رابطه (۱)}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \text{رابطه (۲)}$$

در رابطه ۲، n: تعداد داده‌ها، y_i : مقدار اندازه‌گیری شده کربن آلی خاک، \hat{y}_i : مقدار پیش‌بینی شده کربن آلی خاک می‌باشد (۵۰).

$$MSE = \frac{1}{n} \sum_{i=1}^n [Y_i - \hat{Y}_i]^2 \quad \text{رابطه (۳)}$$

در رابطه ۳، y_i : مقدار اندازه‌گیری شده کربن آلی خاک، \hat{y}_i : مقدار پیش‌بینی شده کربن آلی خاک و n تعداد داده‌ها می‌باشد (۴۵).

نتایج و بحث

خلاصه آماری داده‌های مشاهداتی برای کربن آلی خاک به عنوان متغیر اصلی و سایر متغیرهای کمکی در جدول ۲ ارائه شده است. نتایج آماره‌های توصیفی نشان داد که کربن آلی خاک از ۰/۰۲ تا ۲/۳۴ درصد با میانگین ۰/۵۶ و ضریب تغییرات ۶۹/۶۴ درصد بر اساس استاندارد ویلینگ (۴۲) در کلاس تغییرپذیری بالا (۳۵/۰) قرار می‌گیرد. با توجه به مقدار میانگین کربن آلی خاک می‌توان بیان داشت که میزان کربن آلی خاک در منطقه پایین می‌باشد. در عین حال بالا بودن مقدار ضریب تغییرات کربن آلی مؤید تغییرپذیری مکانی زیاد آن در منطقه مورد مطالعه می‌باشد. این تغییرات شدید می‌تواند به تغییر کاربری اراضی، مدیریت اراضی و سایر عناصر محیطی در منطقه مورد مطالعه نسبت داده شود (۳۶). به عبارتی دیگر، پایین بودن میزان کربن آلی خاک را می‌توان به جمع‌آوری بقایای گیاهی و عدم بازگشت آنها به خاک نسبت داد. یکی دیگر از عوامل کاهش مقدار کربن آلی، تغییر کاربری اراضی است که عمدتاً تأثیر منفی بر کیفیت و عملکرد خاک دارد (۴۳). به طور کلی، چگونگی استفاده از زمین، عملیات خاکورزی، شدت و تناوب عملیات کشت، شخم، کوددهی، نوع محصول کشت شده بر کاهش و افزایش میزان کربن آلی خاک مؤثر است.

مجموعه داده‌های بزرگ بسیار خوب عمل می‌کند. مهم‌ترین ویژگی جنگل‌های تصادفی عملکرد بالای آن‌ها در اندازه‌گیری اهمیت متغیرهاست که مشخص می‌کند هر متغیر چه نقشی در پیش‌بینی پاسخ دارد. مدل‌سازی با روش جنگل تصادفی، ابتدا بر روی داده‌های آموزشی سپس بر روی داده‌های اعتبارسنجی اجرا می‌شود. در نهایت مدلی انتخاب می‌شود که دارای کمترین خطای OOB^۱ باشد. در نهایت برای مدل‌سازی RF از بسته Caret (kuhn, 2015) در محیط نرم‌افزار RStudio 3.5.0 استفاده شد.

کوبیست^۲

روش کوبیست در واقع هیبریدی از رگرسیون‌های معمولی و رگرسیون درختی است که مدل‌های رگرسیونی چندگانه را از داده‌ها ایجاد می‌کند. کوبیست یکسری قواعد "اگر-سپس" ایجاد کرده که هر قاعده یک مدل خطی چند متغیره دارد. بر خلاف درخت رگرسیونی که فقط از یک درخت استفاده می‌کند، کوبیست از چند رگرسیون چند متغیره استفاده می‌کند و از میانگین همه درختان برای رسیدن به پیش‌بینی نهایی بهره می‌گیرد. از مزایای دیگر این روش، زمان کمتر برای پردازش آن است.

رگرسیون حداقل مربعات جزئی (PLSR)

PLSR، یک روش نسبتاً جدید برای ساختن معادلات رگرسیونی تک متغیره و چند متغیره می‌باشد. بنابراین ممکن است چندین متغیر وابسته داشته باشیم. برای ایجاد ارتباط بین متغیرهای وابسته و متغیرهای مستقل، PLS متغیرهای تبیینی جدیدی ایجاد می‌کند. برخلاف مدل‌بندی مبتنی بر کواریانس، کمترین مجذورات جزئی (PLS)، به جای بازتولید ماتریس کواریانس تجربی، بر بیشترین واریانس تبیین شده متغیرهای وابسته با استفاده از متغیرهای مستقل تمرکز دارد. یکی از مهم‌ترین دلایل استفاده از تکنیک رگرسیون حداقل مربعات جزئی این است که این تکنیک به فرض نرمال بودن جامعه و حجم نمونه متکی نیست. همچنین این تکنیک امکان بررسی هم‌زمان روابط متغیرهای کمکی و متغیرهای قابل مشاهده را فراهم می‌آورد.

اعتبارسنجی نتایج مدل‌سازی

برای مدل‌سازی کربن آلی خاک، داده‌ها به دو گروه داده‌های واسنجی (۸۰٪ داده‌ها) و داده‌های اعتبارسنجی (۲۰٪ داده‌ها) تقسیم شدند. در انتها به منظور ارزیابی دقت در هر یک از روش‌های

3- Coefficient of determination
4- Root mean square error
5- Mean square error

1- Out of Bag
2- Cubist

جدول ۲- آنالیز آماری کربن آلی خاک سطحی و متغیرهای سنجش از دور

Table 2- Statistical analysis of surface soil organic carbon and remote sensing variables

پارامترها Parameters	کربن آلی Organic Carbon	Band10	Band11	شاخص گیاهی نسبتی RVI	شاخص گیاهی تغییر یافته تعدیل کننده اثر خاک TSAVI
میانگین Mean	0.56	33134	30126	1.38	0.01
انحراف معیار Standard Deviation	0.39	1530	1122	0.81	0.0
چولگی Skewness	1.68	0.82	0.88	2.182	0.84
کشیدگی Kurtosis	3.98	-0.57	-0.48	3.738	-0.13
حداقل Minimum	0.02	29695	27514	0.8	-0.014
حداکثر Maximum	2.34	35216	31610	4.38	-0.006
ضریب تغییرات Coefficient of Variation (%)	69.64	4.62	3.72	58.70	./0

قرمز حرارتی (TIR^۲) می‌تواند ۹۳٪ از کل تغییرات کربن آلی خاک را نشان دهد.

جدول ۳- متغیرهای محیطی مهم برای پیش‌بینی کربن آلی خاک با استفاده از آنالیز مؤلفه‌های اصلی

Table 3- Important environmental variables for soil organic prediction using principal component analysis

متغیرها Covariates	جنس متغیرها Covariates type
TSAVI	Spectral reflection
RVI	Spectral reflection
BAND 10	Spectral reflection
BAND 11	Spectral reflection

جدول ۴- نتایج تجزیه و تحلیل مؤلفه اصلی

Table 4- Results of principal component analysis

مؤلفه‌ها Components	واریانس % of Variance	واریانس تجمعی Cumulative of Variance %
PC1	70.506	78.50
PC2	14.825	93.33
PC3	4.816	98.14

پیش‌بینی مکانی و مدلسازی کربن آلی انتخاب متغیرهای کمکی (داده کاوی)

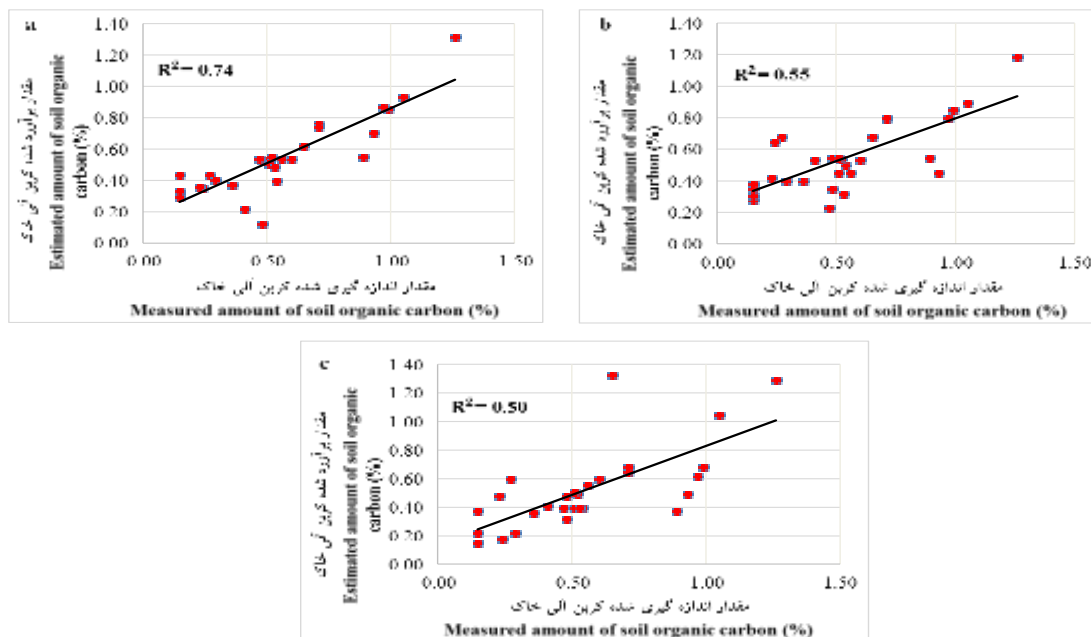
نتایج حاصل از انتخاب متغیرهای کمکی مؤثر در پیش‌بینی کربن آلی خاک، بر اساس آنالیز مؤلفه‌های اصلی و آزمون KMO^۱ برای داده‌های سنجش از دور منجر به گزینش ۴ متغیر کمکی گردید (جدول ۳). متغیرهای سنجش از دور توانستند ۹۸/۱۴ درصد تغییرات متغیرهای مستقل را در منطقه مطالعاتی توجیه نمایند (جدول ۴). تجزیه متغیرهای محیطی با استفاده از روش PCA ضمن ارائه یک تفسیر گرافیکی، به خوبی روابط موجود بین متغیرهای محیطی را نشان می‌دهد. با در نظر گرفتن حداقل همبستگی، شاخص‌های سنجش از دور در مؤلفه اول شامل شاخص گیاهی تغییر یافته تعدیل کننده اثر خاک (TSAVI) و شاخص گیاهی نسبی (RVI)، مؤلفه دوم باند حرارتی ۱۰ و مؤلفه سوم باند حرارتی ۱۱ را نشان داد.

عدم انتخاب سایر شاخص‌های کمکی مورد استفاده در این مطالعه که انتظار می‌رفت بتوانند در مدل‌های پیش‌بینی، تغییرات کربن آلی را به خوبی رصد نمایند، نشان دهنده پیچیدگی پراکنش این متغیر در خاک‌های منطقه مطالعاتی می‌باشد. نتایج این مطالعه نیز مطابق با یافته‌های پولادی و همکاران (۳۱) می‌باشد، که اهمیت بالای داده‌های سنجش از دور را برای پیش‌بینی کربن آلی خاک تأیید نمودند. مک کارتی و همکاران (۳۰)، نشان داد که شاخص مادون

جدول ۵- ارزیابی الگوریتم‌های یادگیری ماشین در پیش بینی کربن آلی خاک سطحی

Table 5- Evaluation of machine learning algorithms in predicting surface soil organic carbon

شاخص ارزیابی	جنگل تصادفی	رگرسیون حداقل مربعات جزئی	کوبیست
Evaluation Index	Random forest	PLSR	Cubist
R2	0.74	0.55	0.5
RMSE	0.17	0.25	0.23
MSE	0.02	0.06	0.14



شکل ۲- مقادیر کربن آلی اندازه گیری شده در مقابل مقادیر پیش بینی شده بر اساس مدل‌های (a): RF، (b): PLSR و (c): Cubist

Figure 2- Measured organic carbon values versus predicted values based on models a):(RF), b):(PLSR), c):(Cubist)

روش جنگل تصادفی با حداقل RMSE و MSE به ترتیب برابر ۰/۱۷ و ۰/۰۲ و بیشترین R^2 برابر با ۰/۷۴ به دست آمد. نتایج این تحقیق با مطالعه زراعت پیشه و همکاران (۴۴)، نیز همسو می باشد که مدل جنگل تصادفی را در مقایسه با مدل‌های کوبیست، رگرسیون درختی و رگرسیون چند متغیره به عنوان مدل برتر معرفی نمودند. جمشیدی و همکاران (۲۱)، در مطالعه‌ی خود ارزیابی روش‌های رقومی در تهیه نقشه سه بعدی کربن آلی خاک را بررسی نمودند. نتایج آن‌ها نشان داد که مدل جنگل تصادفی با RMSE برابر با ۰/۴۹ نسبت به روش‌های کوبیست و رگرسیون خطی چند متغیره در تمامی اعماق از خطای کمتر و توانایی بیشتری در نشان دادن توزیع مکانی مقادیر کربن آلی خاک برخوردار است، هنگل و همکاران (۱۸). همچنین هنگل و همکاران (۱۸)، در مطالعه‌ی خود عملکرد دو روش جنگل تصادفی و رگرسیون خطی را برای نقشه برداری خصوصیات خاک بررسی نمودند، نتایج حاصل از

فلاح‌کار و همکاران (۱۲) دریافتند که شاخص‌های سنجش از دور معمولاً پیش‌بینی کننده‌های قوی کربن آلی خاک هستند که نتایج این مطالعات، مطابق با نتایج مطالعه حاضر بود اسوارنا و همکاران (۱۱).


ارزیابی کارایی مدل‌ها

نتایج ارزیابی روش‌های جنگل تصادفی، کوبیست و رگرسیون حداقل مربعات جزئی در تخمین کربن آلی خاک در جدول ۵ آورده شده است. برای شناسایی دقیق‌ترین روش، اساس قضاوت کمترین مجذور میانگین مربع خطاها ($RMSE^1$)، میانگین مربع خطاها (MSE) و بیشترین R^2 می باشد. طبق نتایج به دست آمده از جدول ۵، بهترین روش مدل سازی برای نقشه برداری رقومی کربن آلی خاک،

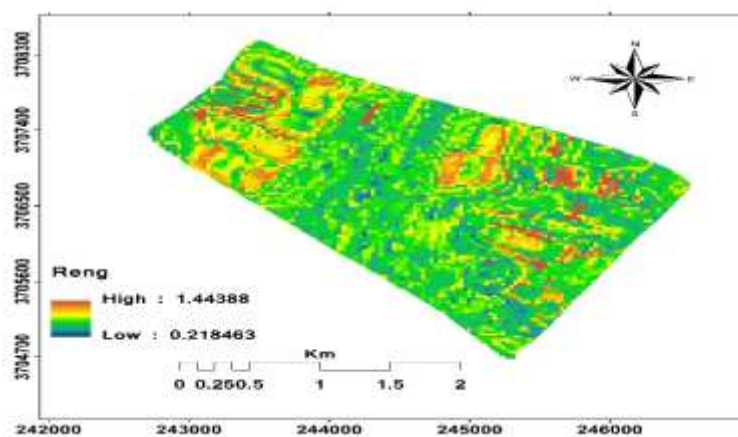
1- Root Mean Square Error

شده در مقابل مقادیر اندازه گیری شده کربن آلی برای مدل های RF، PLSR و Cubist ارائه شده است. مدل جنگل تصادفی نسبت به سایر مدل های مورد استفاده دارای بالاترین میزان صحت و حداقل خطا برای تخمین کربن آلی خاک می باشد.


اعتبارسنجی نشان داد که الگوریتم جنگل تصادفی به طور مداوم از الگوریتم رگرسیون خطی با کاهش ۱۵-۷۵ درصدی خطای جذر میانگین مربعات (RMSE) در خواص و عمق خاک، بهتر عمل می کند، هوت (۱۹). در شکل ۲، نمودار پراکنش داده های پیش بینی



PLSR
رگرسیون حداقل مربعات جزء

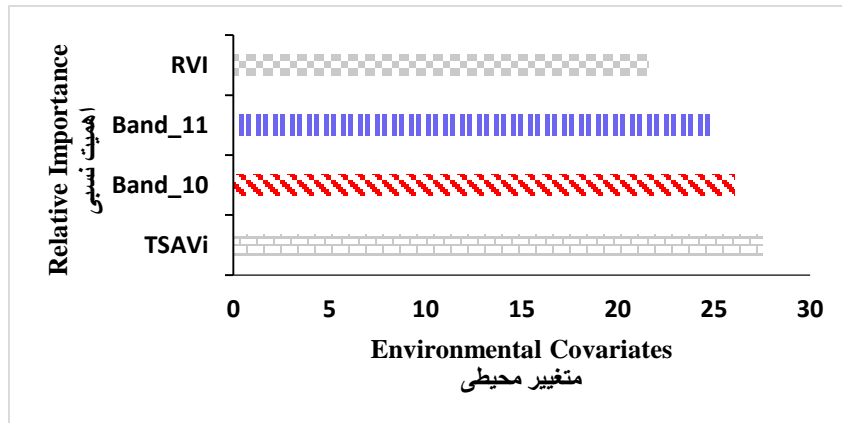


Random Forest
جنگل تصادفی



Cubist Model
مدل کویبست


شکل ۳- توزیع مکانی کربن آلی خاک با استفاده از مدل های پیش بینی
Figure 3- Spatial distribution of soil organic carbon using prediction model

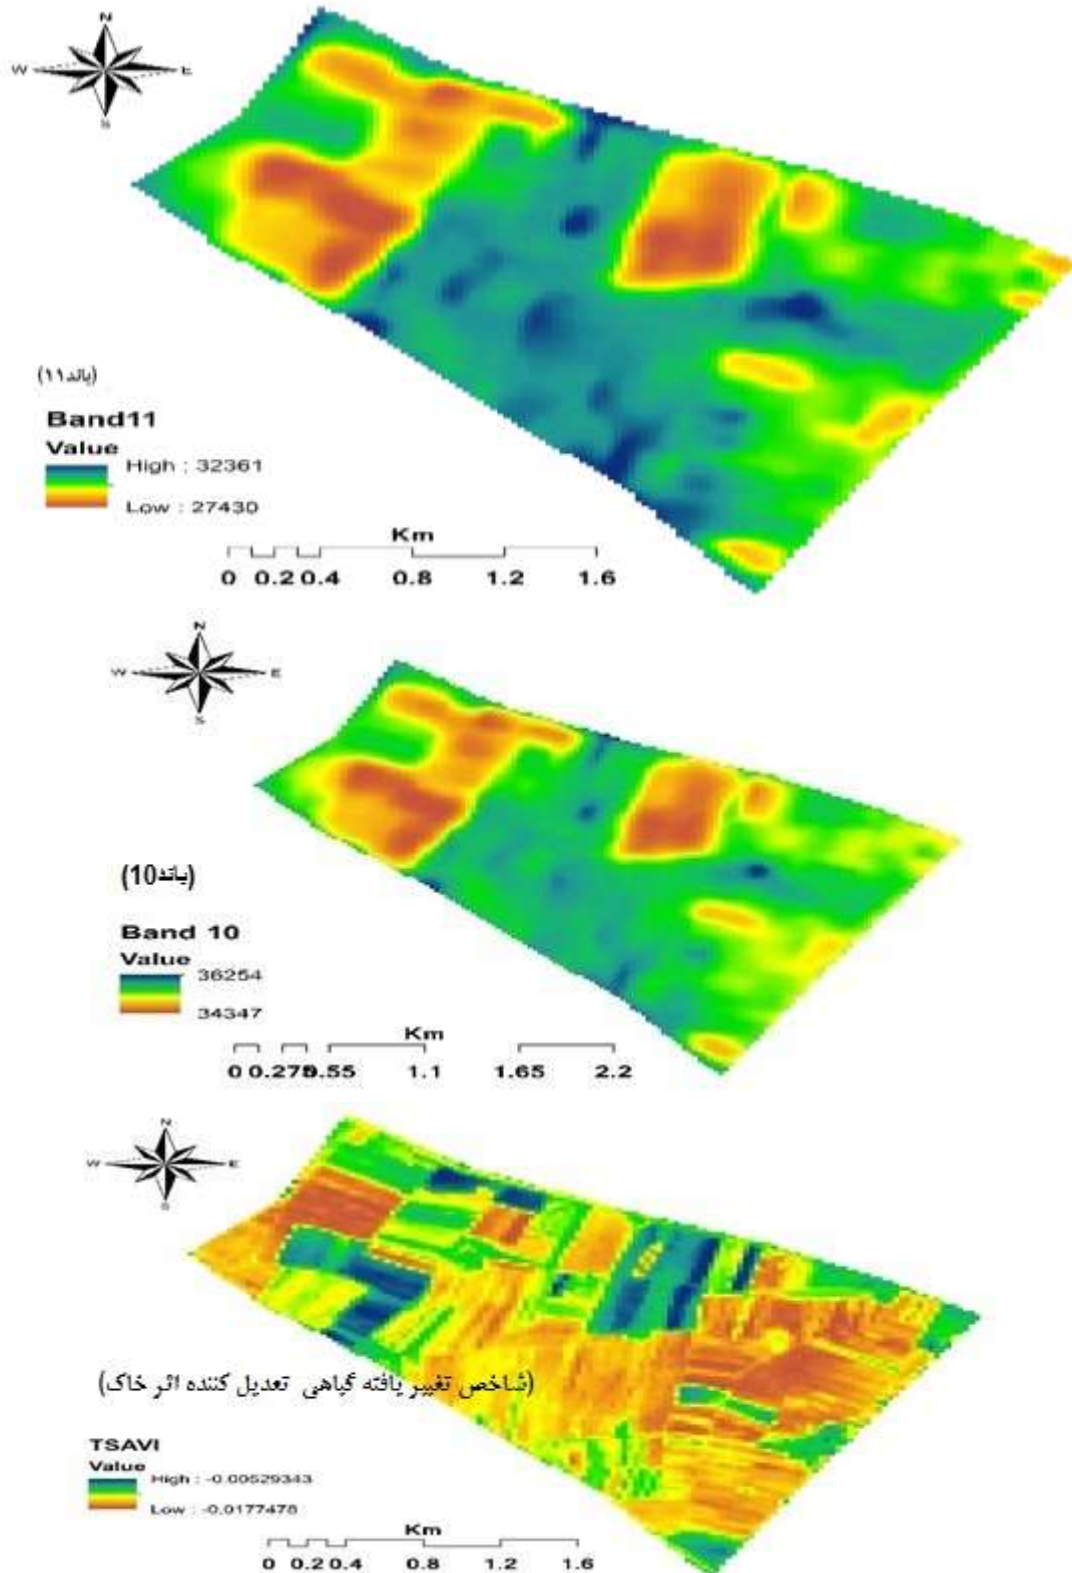


شکل ۴- اهمیت نسبی متغیرهای سنجش از دور در پیش بینی کربن آلی خاک بر اساس آنالیز حساسیت %IncMSE در مدل جنگل تصادفی
 Figure 4- Relative importance of remote sensing variables in predicting soil organic carbon based on % IncMSE sensitivity analysis in random forest model

تشکیل دهنده خاک و بخشی از آن تابع شیوه‌های مدیریتی (مانند عملیات مدیریتی خاک، کودهی، تناوب زراعی و فرسایش) می‌باشد. انگیرام و همکاران (۲۰)، بیان داشتند که در یک اکوسیستم، میزان ترسیب کربن آلی خاک تحت تاثیر دو عامل مدیریت اراضی و چگونگی فرایندهای زیستی ریزجانداران خاکی می‌باشد. قابل ذکر است که فعالیت زیستی ریزجانداران خاک، به وسیله عواملی چون اقلیم، رطوبت خاک، پوشش گیاهی و فرسایش‌پذیری خاک کنترل می‌شود (۱۵).

بررسی نقشه‌های پیش‌بینی حاصل، گویای قابلیت بالای مدل RF به عنوان بهترین مدل برای تخمین کربن آلی خاک می‌باشد (شکل ۳). مقدار کربن آلی خاک الگوی تصادفی نداشته و دارای تغییرات مکانی می‌باشد، همانطور که در نقشه‌های پیش‌بینی کربن آلی خاک نشان داده شده است، روند کاهشی کربن آلی خاک در نواحی مرکزی و جنوبی اراضی نسبت به نواحی شمالی شدیدتر می‌باشد. به عبارتی، بیشترین مقدار کربن آلی خاک در خاک‌های منطقه در نواحی شرقی و غربی قرار دارد. به نظر می‌رسد که علت پراکندگی کربن آلی خاک ناشی از تغییرپذیری ذاتی فاکتورهای





شکل ۵- نقشه توزیع مکانی متغیرهای کمکی مؤثر در پیش بینی کربن آلی خاک

Figure 5- Spatial distribution map of auxiliary variables effective in predicting soil organic carbon

آنالیز حساسیت

سنجش از دور در این مطالعه تأیید می‌شود. به نظر می‌رسد در مناطقی که توزیع پیش‌بینی کننده‌ها یکنواخت‌تر و تغییرپذیری کمتری داشته باشد، مدل‌ها سریع‌تر رابطه پیش‌بینی کننده و متغیر وابسته را تشخیص می‌دهند و ارتباط برقرار می‌کنند. این موضوع در مورد هماهنگی توزیع مکانی کربن آلی خاک و شاخص‌های سنجش از دور همچون TSAVI، RVI، کاملاً صادق است (شکل ۶).

نتیجه‌گیری

در این مطالعه، با توجه به اهمیت کربن آلی خاک، کارایی سه مدل مختلف نقشه‌برداری رقومی به منظور تهیه نقشه کربن آلی خاک در خاک‌های دشت-خرم آباد مورد ارزیابی قرار گرفت. نتایج نشان داد که متغیرهای کمکی از جمله TSAVI، RVI، Band 10 و Band 11 مهم‌ترین متغیرها در برآورد کربن آلی خاک این ناحیه می‌باشند. دامنه وسیع تغییرات کربن آلی خاک می‌تواند متأثر از نوع کاربری اراضی و رفتارهای مدیریتی کشاورزان باشد. همچنین، نتایج گویای این موضوع است که مدل‌های مختلف، صحت‌های مختلفی را در برآورد کربن آلی خاک داشتند و نتایج برتری مدل جنگل تصادفی را نسبت به سایر مدل‌ها نشان داد. از سوی دیگر می‌توان بیان داشت که استفاده از سنجش از دور و تصاویر ماهواره‌ای می‌تواند بر محدودیت‌های ناشی از روش‌های سنتی غلبه کند و به عنوان یک جایگزین مناسب جهت بررسی تغییرات کربن آلی خاک با امکان نمایش نتایج در مقیاس‌های زمانی و مکانی مختلف استفاده شود. با توجه به مشخص شدن میزان کربن آلی خاک و پراکنش مکانی آن‌ها در سراسر منطقه، نتایج حاضر می‌تواند مبنای علمی و همچنین پایگاه اطلاعاتی و داده مناسبی جهت اجرای هر گونه عملیات صحرائی، مدیریت نهاده‌های کشاورزی هر گونه مطالعه مرتبط در کشاورزی پایدار با خصوصیات خاک در این منطقه باشد.

در این تحقیق، نتایج تجزیه و تحلیل حساسیت نشان داد که اهمیت نسبی متغیرهای کمکی برای پیش‌بینی نحوه توزیع کربن آلی خاک متفاوت بوده و برخی متغیرهای کمکی از توانایی بیشتری برخوردار بودند. نتایج اهمیت متغیرهای کمکی در نقشه‌های تولید شده توسط مدل RF بر اساس الگوریتم آنالیز حساسیت INCMSE% در شکل ۴، ارائه شده است. با توجه به شکل ۴، اهمیت نسبی متغیرهای کمکی به دست آمده بر اساس مدل RF، شامل TSAVI (۶۵/۲۷ درصد)، باند حرارتی ۱۰ (۲۶/۲۳ درصد)، RVI (۷۰/۲۱ درصد)، باند حرارتی ۱۱ (۲۴/۹۵ درصد) جزو با اهمیت‌ترین متغیرها در تخمین نقشه تولید شده می‌باشند. بر همین اساس می‌توان بیان داشت که شاخص‌های سنجش از دور نقش مهمی در مدل داشتند. صباغ زاده و همکاران (۳۸)، در مطالعه خود به این نتیجه رسیدند که شاخص‌های گیاهی مانند TSAVI بیشترین ضرایب تبیین و کمترین مقدار مجذور خطای مربعات را با داده‌های زمینی دارند (۳۸). در مطالعه‌ای دیگر، برای مدل‌سازی کربن آلی خاک در خاک‌های سطحی ایران پس از تعیین اهمیت نسبی متغیرها، نتیجه‌گیری شد که RVI مهم‌ترین متغیر کمکی برای پیش‌بینی کربن آلی خاک در منطقه نیمه‌خشک است (۴۴). همچنین مک کارتی (۳۰) نشان داد که شاخص منتج از مادون قرمز حرارتی (TIR) می‌تواند ۹۳٪ از کل تغییرات کربن آلی خاک را نشان دهد مک کارتی و همکاران (۳۰). کومار و همکاران (۲۲)، در مطالعه‌ای پیش‌بینی توزیع کربن آلی خاک را با استفاده از داده‌های سنجش از دور در حوضه آبخیز سارسیکاتیگر انجام دادند. نتایج مطالعه آن‌ها نشان داد که داده‌های حاصل از سنجش از دور پتانسیل بالایی در پیش‌بینی کربن آلی خاک در مقیاس وسیع دارند (۲۲). در شکل ۶، میزان تغییرپذیری متغیرهای کمکی در منطقه مورد مطالعه نشان داده شده است. بر اساس نتایج به دست آمده از مدل‌سازی، نقش مهم و اثرگذار داده‌های

منابع

- 1- Baret F., and Guyot G. 1991. Potentials and limits of vegetation indices for LA APAR assesment. Remote Sensing of Environment 35: 161-173.
- 2- Camdevyren H., Demyr N., Kanik A., and Keskin S. 2005. Use of principal component scores in multiple linear regression models for prediction of Chlorophyll-a in reservoirs. Ecological Modelling 181: 581-589.
- 3- Chang C.-W., Laird D.A., Mausbach M.J., and Hurburgh C.R. 2001. Near-infrared reflectance spectroscopy – principal components regression analyses of soil properties. Soil Science Society of America Journal 65(2): 480–490.
- 4- Chang C.W., Laird D.A., and Hurburgh Jr C.R. 2005. Influence of soil moisture on near-infrared reflectance spectroscopic measurement of soil properties. Soil Science 170(4): 244-255.
- 5- Chen D.Z., Zhang J.X., and Chen J.M. 2010. Adsorption of methyl tert-butyl ether using granular activated carbon: Equilibrium and kinetic analysis. International Journal of Environmental Science & Technology 7(2): 235-242.
- 6- Chen F., Kissel D.E., West L.T., and Adkins W. 2000. Field-scale mapping of surface soil organic carbon using

- remotely sensed imagery. *Soil Science Society of America Journal* 64(2): 746-753.
- 7- Dalal R.C., and Henry R.J. 1986. Simultaneous determination of moisture, organic carbon, and total nitrogen by near infrared reflectance spectrophotometry 1. *Soil Science Society of America Journal* 50(1): 120-123.
 - 8- Dashti A., Soodi M., and Amani N. 2015. Evaluation of Cr (VI) induced Neurotoxicity and Oxidative Stress in PC12 Cells. *Modares Journal of Medical Sciences: Pathobiology* 18(1): 55-65.
 - 9- Datta A., Setia R., Barman A., Guo Y., and Basak N. 2019. Carbon Dynamics in Salt-affected Soils. Springer Nature Singapore Pte Ltd. https://doi.org/10.1007/978-981-13-5832-6_12.
 - 10- De Santana F B., de Souza A M., and Ronei Poppi J. 2018. Visible and near infrared spectroscopy coupled to random forest to quantify some soil quality parameters. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy* 191: 454-462.
 - 11- Eswaran H., Van Den Berg E., and Reich P. 1993. Organic carbon in soils of the world. *Soil Science Society of America Journal* 57(1): 192-194.
 - 12- Falahatkar S., Hosseini S.M., Ayoubi S., and Salmanmahiny A. 2016. Predicting soil organic carbon density using auxiliary environmental variables in northern Iran. *Archives of Agronomy and Soil Science* 62(3): 375-393.
 - 13- FAO I. 2015. Status of the World's Soil Resources (SWSR)-technical summary. Food and Agriculture Organization of the United Nations and Intergovernmental Technical Panel on Soils, Rome, Italy.
 - 14- Gelsleichter Y.A., dos Anjos L.H.C., Costa E.M., Valente G., Debiassi P., Homem Antunes M.A., and Robson Altiellys Tosta Marcondes. 2019. Machine Learning Algorithms for Soil Properties Prediction with Treated Vis-NIR Spectrums from the Itatiaia National Park. *Geoderma*. doi:10.20944/preprints201911.0053.v1.
 - 15- Habibzade A.M., Nikjou R., and Peyrovan H.R. 2013. Survey amount of runoff and sediment in Marn East Azerbaijan. *Rangeland Scientific Research Journal* 17(43): 71-91. (In Persian)
 - 16- He T., Wang J., Lin Z., and Cheng Y. 2009. Spectral features of soil organic matter. *Geo-spatial Information Science* 12(1): 33-40.
 - 17- He Y., Huang M., García A., Hernández A., and Song H. 2007. Prediction of soil macronutrients content using near-infrared spectroscopy. *Computers and Electronics in Agriculture* 58(2): 144-153.
 - 18- Heng T., Heuvelink G.B., Kempen B., Leenaars J.G., Walsh M.G., Shepherd K.D., and Tondoh J.E. 2015. Mapping soil properties of Africa at 250 m resolution: Random forests significantly improve current predictions. *PloS one*. 10:6.
 - 19- Huete A., Huete A.R. 1988. Soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment. Remote Sensing of Environment* 25: 295-309.
 - 20- Ingram L.J., Stahl P.D., Schuman G.E., Buyer J.S., Vance G.F., Ganjegunte G.K., and Derner J.D. 2008. Grazing impacts on soil carbon and microbial communities in a mixed-grass ecosystem. *Soil Science Society of America Journal* 72(4): 939-948.
 - 21- Jamshidi M., Delavar M.A., Taghizadehe-Mehrjerdi R., and Brungard C. 2019. Evaluating Digital Soil Mapping Approaches for 3D Mapping of Soil Organic Carbon. *Soil Research Journal (Soil and Water Sciences)* 33(2): 228-240. (In Persian)
 - 22- Kumar N., Velmurugan A., Hamm N.A., and Dadhwal V.K. 2018. Geospatial mapping of soil organic carbon using regression kriging and remote sensing. *Journal of the Indian Society of Remote Sensing* 46(5): 705-716.
 - 23- Lal R. 2006. Enhancing crop yields in the developing countries through restoration of the soil organic carbon pool in agricultural lands. 2006. *Land Degradation and Development* 17(2): 197-209.
 - 24- Ludwig B., Khanna P.K., Bauhus J., and Hopmans P. 2002. Near infrared spectroscopy of forest soils to determine chemical and biological properties related to soil sustainability. *Forest Ecology Management* 171(1-2): 121-132.
 - 25- Mahmoudzadeh H., Matinfar H.R., Taghizadeh-Mehrjardi R., and Kerry R. 2020. Spatial prediction of soil organic carbon using machine learning techniques in western Iran. 2020. *Geoderma Regional* 21) e00260.
 - 26- Major D.J., Baret F., and Guyot G. 1990. A ratio vegetation index adjusted for soil brightness *International Journal of Remote Sensing* 11: 727-740.
 - 27- Matinfar H.R., Sarvi Moganloo V., and Dibaei Z. 2017. Evaluation of the ability of red and infrared wavelengths near the OLI sensor in estimating the leaf area index of different stages of grain growth of corn (Moghan plain). In: *Geomatic Tehran*. (In Persian)
 - 28- Matinfar H.R., and Sadikhani R. 2015. Measurement of soil moisture using remote sensing Measurement of soil moisture using remote sensing. In: *The first national conference on sustainable management of soil resources and the environment. Kerman Shahid Bahonar University*. 2015 (In Persian)
 - 29- Matinfar H.R., Mahmoodzadeh H., and Fariabi A. 2018. Estimation Soil Organic Matter (SOM) Content Using Visible and Near Infrared Spectral data, PLSR and PCR Statistical Models. *Iranian Remote Sensing & GIS*. 10(2): 15-32. (In Persian)
 - 30- McCarty G.W., Reeves J.B., Reeves V.B., Follett R.F., and Kimble J.M. 2002. Mid-infrared and nearinfrared diffuse reflectance spectroscopy for soil carbon measurements. *Soil Science Society of America Journal* 66: 640-646.
 - 31- Pouladi N., Møller A.B., Tabatabai S., and Greve M.H. 2019. Mapping soil organic matter contents at field level

- with Cubist, Random Forest and kriging. *Geoderma* 342: 85-92.
- 32- Qi Y., Darilek J.L., Huang B., Zhao Y., Sun W., and Gu Z. 2009. Evaluating soil quality indices in an agricultural region of Jiangsu Province, China. *Geoderma* 149(3-4): 325-334.
- 33- Rondeaux G., Steven M., and Baret F. 1996. Optimisation of soil-adjusted vegetation indices. *Remote Sensing of Environment* 55: 95-107.
- 34- Robertson G.P., Gross K.L., and Hamilton S.K. L. Doug 2014. Farming for ecosystem services: an ecological approach to production agriculture. *Bioscience* 64: 404-415.
- 35- Rossel R.V., McBratney P.A.B., Minasny D.B., Stenberg B., and Rossel R.A.V. 2010. Diffuse Reflectance Spectroscopy for High-Resolution Soil Sensing Proximal Soil Sensing. *Soil Science*. Germany, 434p.
- 36- Smith J.A. 2004. Reflecting on the development of interpretative phenomenological analysis and its contribution to qualitative research in psychology. *Qualitative Research in Psychology* 1(1): 39-54.
- 37- Song Y.Q., Yang L.A., Li B., Hu Y.M., Wang A.L., Zhou W., and Liu Y.L. 2017. Spatial prediction of soil organic matter using a hybrid geostatistical model of an extreme learning machine and ordinary kriging. *Sustainability* 9(5): 754.
- 38- Sabaghzadeh S., Zare M., and Mokhtari M. 2017. Estimating of above ground biomass of *Haloxylon* using satellite based vegetation indices (Case Study: Marak, Birjand). *Iranian Journal of Range and Desert Research* 23(4): 844-855. (In Persian)
- 39- U.S. Geology Survey. 2014. <http://geology.com/news/2010/free-lansatimages-from-USGS-2>. <http://glovis.usgs.gov>.
- 40- Walkley A., and Black I.A. 1934. An examination of the Degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. *Soil Science* 37(1): 29-38.
- 41- Wiegand C.L., Richardson A.J., Escobar D.E., and Gerbermann A.H. 1991. Vegetation indices in crop assessments. *Remote Sensing of Environment* 35(2-3): 105-119.
- 42- Wilding L.P. 1985. Spatial variability: its documentation, accommodation and implication to soil surveys. P 166-194, In: D.R. Nielsen and J. Bouma (eds.), *Soil Spatial Variability*, Pudoc, Wageningen, the Netherlands.
- 43- Walker, S.M., and Desanker, P.V. 2004. The impact of land use on soil carbon in Miombo Woodlands of Malawi. *Forest Ecology and Management* 203: 345-360.
- 44- Zeraatpisheh M., Ayoubi S., Jafari A., Tajik S., and Finke P. 2019. Digital mapping of soil properties using multiple machine learning in a semi-arid region, central Iran. *Geoderma* 338: 445-452.
- 45- Zhou J., Li Enming Wei., Haixia Li., Chuanqi Qiao Qiuqiu., and Danial J.A. 2019. Random Forests and Cubist Algorithms for Predicting Shear Strengths of Rockfill Materials. *Appl. Sci.* 9: 1621.



Estimation of the Amount of Soil Organic Carbon Using Spectral Data in the VIS-NIR-SWIR-TIR Spectral Range

H.R. Matinfar^{1*}- M. Jalali²- Z. Dibaei³

Received: 03-07-2021

Accepted: 11-08-2021

Introduction: Understanding the spatial distribution of soil organic carbon (SOC) is one of the practical tools in determining sustainable land management strategies. Over the past two decades, the use of data mining approaches in spatial modeling of soil organic carbon using machine learning techniques to investigate the amount of carbon to soil using remote sensing data has been widely considered. Accordingly, the aim of this study was to investigate the feasibility of estimating soil organic matter using satellite imagery and to assess the ability of spectral and terrestrial data to model the amount of soil organic matter.

Materials and Methods: The study area is located in Lorestan province, and Sarab Changai area. This area has hot and dry summers and cold and wet winters and the wet season starts in November and ends in May. A total of 156 samples of surface soil (0-30 cm) were collected using random sampling pattern. Data were categorized into two categories: 80% (117 points) for training and 20% (29 points) for validation. Three machine learning algorithms including Random Forest (RF), Cubist, and Partial least squares regression (PLSR) were used to prepare the organic soil carbon map. In the present study, auxiliary variables for predicting SOC included bands related to Lands 8 OLI measurement images, and in order to reduce the volume of data, the principle component analysis method (PCA) was used to select the features that have the greatest impact on quality.

Results and Discussion: The results of descriptive statistics showed that soil organic carbon from 0.02 to 2.34% with an average of 0.56 and a coefficient of variation of 69.64% according to the Wilding standard was located in a high variability class (0.35). According to the average amount of soil organic carbon, it can be said that the amount of soil organic carbon in the region is low. At the same time, the high value of organic carbon change coefficient confirms its high spatial variability in the study area. These drastic changes can be attributed to land use change, land management, and other environmental elements in the study area. In other words, the low level of soil organic carbon can be attributed to the collection of plant debris and their non-return to the soil. Another factor in reducing the amount of organic carbon is land use change, which mainly has a negative impact on soil quality and yield. In general, land use, tillage operations, intensity and frequency of cultivation, plowing, fertilizing, type of crop, are effective in reducing and increasing the amount of soil organic carbon. Based on the analysis of effective auxiliary variables in predicting soil organic carbon, based on the principle component analysis for remote sensing data, it led to the selection of 4 auxiliary variables TSAVI, RVI, Band10, and Band11 as the most effective environmental factors. Comparison of different estimation approaches showed that the random forest model with the values of coefficient of determination (R^2), root mean square error (RMSE) and mean square error (MSE) of 0.74, 0.17, and 0.02, respectively, was the best performance ratio another study used to estimate the organic carbon content of surface soil in the study area.

Conclusion: In this study, considering the importance of soil organic carbon, the efficiency of three different digital mapping models to prepare soil organic carbon map in Khorramabad plain soils was evaluated. The results showed that auxiliary variables such as TSAVI, RVI, Band 10, and Band11 are the most important variables in estimating soil organic carbon in this area. The wide range of soil organic carbon changes can be affected by land use and farmers' managerial behaviors. Also, the results indicated that different models had different accuracy in estimating soil organic carbon and the random forest model was superior to the other models. On the other hand, it can be said that the use of remote sensing and satellite imagery can overcome the limitations of traditional methods and be used as a suitable alternative to study carbon to soil changes with the possibility of displaying results at different time and space scales. Due to the determination of soil organic carbon content and their spatial distribution throughout the region, the present results can be a scientific basis as well as a suitable database and data for the implementation of any field operations, management of agricultural

1, 2 and 3- Associate Professor, Assistant Professor and Ph.D. Student of Soil Science, Lorestan University, respectively.

(*- Corresponding Author Email: matinfar.h@lu.ac.ir)

DOI: 10.22067/JSW.2021.71065.1062

inputs, and any study in sustainable agriculture with soil properties in this area. In general, the results of this study indicated the ability of remote sensing techniques and random forest learning model in simultaneous estimation of soil organic carbon location. Therefore, this method can be used as an alternative to conventional laboratory methods in determining some soil characteristics, including organic carbon.

Keywords: Modeling, Remote sensing, Soil organic carbon, Spatial distribution