نشریه آب و خاک (علوم و صنایع کشاورزی)
جلد ۲۵، شماره ۶، بهمن - اسفند ۱۳۹۰، ص. ۱۳۶۴-۱۳۵۳

Journal of Water and Soil
Vol. 25, No. 6, Jan-Feb 2012, p. 1353-1364

کاربرد مدل‌های رگرسیونی در پیش‌بینی کلاس خاک در بخشی از مناطق ایران مرکزی (منطقه زرند کرمان)

اعظم جعفری[۱]- شمس اله ایوبی[۲*]- حسین خادمی[۳]

تاریخ دریافت: ۸۹/۱۱/۳
تاریخ پذیرش: ۹۰/۵/۳۰

چکیده

شناسایی رقومی خاک‌ها به‌عنوان ابزاری برای ایجاد اطلاعات مکانی خاک، راه‌حل‌هایی برای نیاز رو به افزایش نقشه‌های خاک با تفکیک مکانی بالا را تأمین می‌کند. بنابراین، باید روش‌های جدید به‌منظور به‌دست آوردن اطلاعات مکانی خاک با تفکیک مکانی بالا توسعه پیدا کند. به همین منظور مطالعه‌ای جهت پیش‌بینی کلاس‌های خاک با استفاده از مدل‌های رگرسیونی در منطقه زرند کرمان طراحی گردید. در این مطالعه، مدل‌های رگرسیونی شامل رگرسیون لاجیستیک چندجمله‌ای و رگرسیون درختی توسعه یافته چندکلاسه برای پیش‌بینی گروه بزرگ خاک به کمک داده‌های سنجش از دور، پارامترهای سرزمین و نقشه ژئومرفولوژی استفاده گردید. کیفیت پیش‌بینی مدل‌ها با شاخص‌های حاصل از آرایه خطا بررسی گردید. نتایج نشان داد در پیش‌بینی همه گروه‌های بزرگ خاک، سطوح ژئومرفیک به‌عنوان یک پیش‌بینی کننده مؤثر محسوب می‌شود. بعد از سطوح ژئومرفیک، پارامترهای سرزمین و شاخص‌های سنجش از دور در پیش‌بینی وارد شدند. در هر دو مدل خلوص نقشه برای همه گروه‌های بزرگ خاک در موقعیت‌های اعتبارسنجی و واسنجی بیشتر از ۰/۶ بود. نتایج نشان داد عملکرد پیش‌بینی برای گروه‌های بزرگ هاپلوجیپسید و هاپلوسالید بهتر از گروه‌های بزرگ کلسی‌جیپسید و هاپلوکمبید بود. در بین گروه‌های بزرگ خاک، مقادیر بالای دقت کاربر و قابلیت اطمینان تولیدکننده برای گروه بزرگ هاپلوسالید به‌دست آمد. خاک‌های با قابلیت اطمینان بهتر خاک‌هایی هستند که به شدت تحت تأثیر مشخصات توپوگرافی و ژئومرفولوژی قرار گرفتند (گروه‌های بزرگ هاپلوسالید، تری‌سامنت و هاپلوجیپسید) و خاک‌های با قابلیت اطمینان و دقت پیش‌بینی کمتر خاک‌هایی هستند که به سختی تحت تأثیر مشخصات توپوگرافی و ژئومرفولوژی (گروه‌های بزرگ هاپلوکمبید و کلسی‌جیپسید) قرار گرفتند.

واژه‌های کلیدی: نقشه‌برداری رقومی خاک، رگرسیون لاجیستیک چندجمله‌ای، رگرسیون درختی توسعه یافته

مقدمه

نیاز به اطلاعات خاک در سال‌های اخیر رو به افزایش است. نقشه‌های خاک در مطالعات زیادی از جمله ارزیابی اراضی، برنامه-ریزی استفاده از اراضی و هیدرولوژی کاربرد دارد. اطلاعات رقومی خاک‌ها براساس ابزارهای پردازش جدید و داده‌های رقومی مختلف به‌طور مداوم در حال افزایش است. شناسایی رقومی خاک‌ها به‌عنوان ابزاری برای ایجاد اطلاعات مکانی خاک، راه‌حل‌هایی برای نیاز رو به افزایش نقشه‌های خاک با تفکیک مکانی بالا را تأمین می‌کند. بنابراین، باید استراتژی‌ها و روش‌های جدید به‌منظور به‌دست آوردن اطلاعات مکانی خاک با تفکیک مکانی بالا توسعه پیدا کند (۲۴).

نقشه‌برداری رقومی خاک یک مدل آماری یا عددی را بین متغیرهای محیطی و خصوصیات خاک توسعه می‌دهد. برای مدل-سازی رقومی خاک؛ داده‌های سنجش از دور، ویژگی‌های پستی و بلندی، داده‌های صحرایی، پوشش گیاهی، اقلیم و زمین‌شناسی همراه با دانش کارشناس منجر به استنباط مشخصه خاک در مکان‌های بازدید نشده می‌شود. چنین روش‌هایی اطلاعات مناسب‌تری از خاک و زمین‌نما برای کاربردهای مدل‌سازی تأمین می‌کنند (۲۴). در سال‌های اخیر، به‌دلیل افزایش منابع داده‌های کمکی یا محیطی، نقشه‌برداری رقومی خاک پیشرفت سریعی نموده است (۸). یکی از تکنیک‌های نقشه‌برداری، رگرسیون لاجیستیک[۴] است که با ایجاد مدل لاگیت[۵]،

۱،۲و۳- به ترتیب دانشجوی دکتری، دانشیار و استاد گروه خاکشناسی، دانشکده کشاورزی، دانشگاه صنعتی اصفهان
(*- نویسنده مسئول: Email:ayoubi@cc.iut.ac.ir)

4- Logistic Regression
5- Logit

Archive of SID
www.SID.ir

احتمال حضور کلاس خاک معینی را پیش‌بینی می‌کند. این مدل، احتمال حضور یک کلاس خاک را به متغیرهای پیش‌بینی کننده ارتباط می‌دهد. روش‌های رگرسیون لاجیستیک به‌طور موفقیت‌آمیزی در علوم خاک و زمینه‌های مربوطه از جمله پیش‌بینی خطرات زمین‌لغزه (۱۷) احتمال حضور کلاس‌های زهکشی خاک (۶) یا ارتباط انواع خاک به ویژگی‌های پستی و بلندی استفاده شده است. بایلی و همکاران (۲) روابط بین سری‌های خاک یک منطقه و تعدادی از متغیرهای همان منطقه (از جمله شیب، جهت شیب و ارتفاع نسبی) را با استفاده از رگرسیون لاجیستیک چندجمله‌ای[1] به‌دست آوردند. دابلاگیلو و همکاران (۷) به کمک متغیرهای کمکی (پارامترهای سرزمین) برای تخمین توزیع مکانی کلاس‌های خاک در ایالت وست فولد، جنوب شرق نروژ، از لاجیستیک رگرسیون چندجمله‌ای استفاده کردند. نتایج نشان داد از بین پارامترهای سرزمین، ارتفاع، شیب، جهت و مدت زمان تابش خورشیدی در توزیع مکانی کلاس‌های خاک نقش تعیین‌کننده‌ای دارند. هنگل و همکاران (۱۴) موفقیت رگرسیون لاجیستیک چندجمله‌ای در پیش‌بینی گروه‌های خاک WRB را گزارش دادند و نتایج آنها نشان داد موفقیت مدل شدیداً به همبستگی کلاس‌های خاک با پیش‌بینی‌کننده‌ها بستگی دارد.

یکی دیگر از تکنیک‌های رگرسیون مورد استفاده در نقشه‌برداری خاک، طبقه‌بندی و رگرسیون درختی است (۱۵). پیشرفت‌های آماری اخیر در این مدل‌ها از جمله فرآیند تصادفی، منجر به ایجاد مدل قوی‌تری به نام رگرسیون درختی توسعه یافته[2] شده است. هدف این مدل‌ها بهبود عملکرد یک مدل تک درخت از طریق برازش مدل‌های متعدد و ترکیب آنها برای پیش‌بینی است. توابع رگرسیون درختی توسعه یافته ممکن است خطی، منحنی یا غیرخطی باشند. شواهد تجربی نشان داده رگرسیون درختی توسعه یافته یکی از بهترین روش‌های مدل‌سازی می‌باشد. باور و کوهاوی (۳) و فریدمن و همکاران (۱۰) رگرسیون درختی توسعه یافته و رگرسیون درختی معمولی را روی چهارده پایگاه داده مقایسه کردند و نتیجه گرفتند رگرسیون درختی توسعه یافته بهترین است. گرینند و همکاران (۱۳) توانایی رگرسیون درختی توسعه یافته را برای پیش‌بینی دقیق لنداسکیپ در نواحی بازدید نشده را بررسی کردند. آنها دریافتند توانایی تخمین مدل در موارد برون‌یابی پایین است اما برای درون‌یابی توانایی بالایی دارد. کاربرد رگرسیون درختی توسعه یافته در علوم اکولوژی گزارش شده (۹) اما تاکنون مطالعه‌ای در زمینه پیش‌بینی خصوصیات خاک انجام نشده است.

در این مطالعه سعی شده است یک نقشه خاک قابل قبولی از گروه‌های بزرگ خاک براساس اطلاعات محدود به کمک مدل‌های رگرسیون لاجیستیک چندجمله‌ای و رگرسیون درختی توسعه یافته تهیه شود. بنابراین، این مطالعه به‌منظور پاسخگویی به سئوالات زیر طراحی گردید.

۱- آیا می‌توان با استفاده از پایگاه داده محدود به نقشه خاک با کیفیت بالا دست پیدا کرد؟

۲- کدامیک از فاکتورهای محیطی قدرت پیش‌بینی‌کنندگی بالایی دارند؟

۳- کدام روش یا مدل در پیش‌بینی کلاس خاک توانایی بالایی دارد؟

مواد و روش‌ها

تشریح منطقه مطالعاتی

منطقه مورد مطالعه در جنوب شرق ایران، تقریباً در فاصله ۷۰ کیلومتری شهر کرمان بین عرض جغرافیایی '۲۵ °۳۰ تا °۳۱ درجه شمالی و طول جغرافیایی '۱۰ °۵۶ تا '۵۰ °۵۶ درجه شرقی قرار گرفته است. این منطقه مساحتی حدود ۹۰۰۰۰ هکتار را می‌پوشاند و از اطراف توسط رشته‌کوه‌هایی (از جنس آهک، دولومیت و شیل) که روند شمال‌غربی و جنوب‌شرقی دارند، احاطه شده است. لندفرم‌های اصلی این منطقه شامل مخروطه‌افکنه‌های قدیمی و جدید، سطوح رسی (دق) و تپه‌های شنی می‌باشد (شکل ۱). پسته، مهم‌ترین محصول این منطقه است و باغات پسته روی سطوح رسی یا دق‌ها می‌باشد. متوسط سالانه بارندگی، درجه‌حرارت و تبخیر و تعرق به ترتیب ۶۱ میلی‌متر، ۱۷ درجه‌سانتی‌گراد و ۱۷۵۰ میلی‌متر می‌باشد.

طرح نمونه‌برداری و تشریح پروفیل

یک طرح نمونه‌برداری طبقه‌بندی شده[3] با استفاده از نقشه‌های رقومی زمین‌شناسی، ژئومرفولوژی و توپوگرافی پیاده گردید. در این مطالعه، لایه نمونه‌برداری[4] منطبق بر تفاوت در لندفرم‌ها (نقشه ژئومرفولوژی)، توپوگرافی (نقشه ارتفاع رقومی) و زمین‌شناسی تعریف گردید، به‌طوری‌که در هر طبقه، موقعیت‌های تصادفی نمونه‌برداری انتخاب گردید که اندازه نمونه‌ها متناسب با مساحت طبقه بود. در نهایت، ۱۲۳ خاکرخ حفر، تشریح، نمونه‌برداری، آنالیز و براساس معیارهای تاکسونومی آمریکائی (۲۶) طبقه‌بندی گردید. تشریح پروفیل در منطقه مورد مطالعه هفت گروه بزرگ خاک را نشان داد که شامل هاپلوسالیدز، هاپلوجیپسیدز، هاپلوکلسیدز، کلسی‌چیپسیدز، هاپلوکمبیدز، تری‌سامنتز و تری‌ارتنتز[5] بود.

1- Multinomial logistic regression
2- Boosted Regression Tree (BRT)

3- Stratified Sampling Scheme
4- Sampling strata
5- Haplosalids, Haplogypsids, Haplocalcids, Calcigypsids, Haplocambids, Torripsamments and Torriorthents

Archive of SID

www.SID.ir

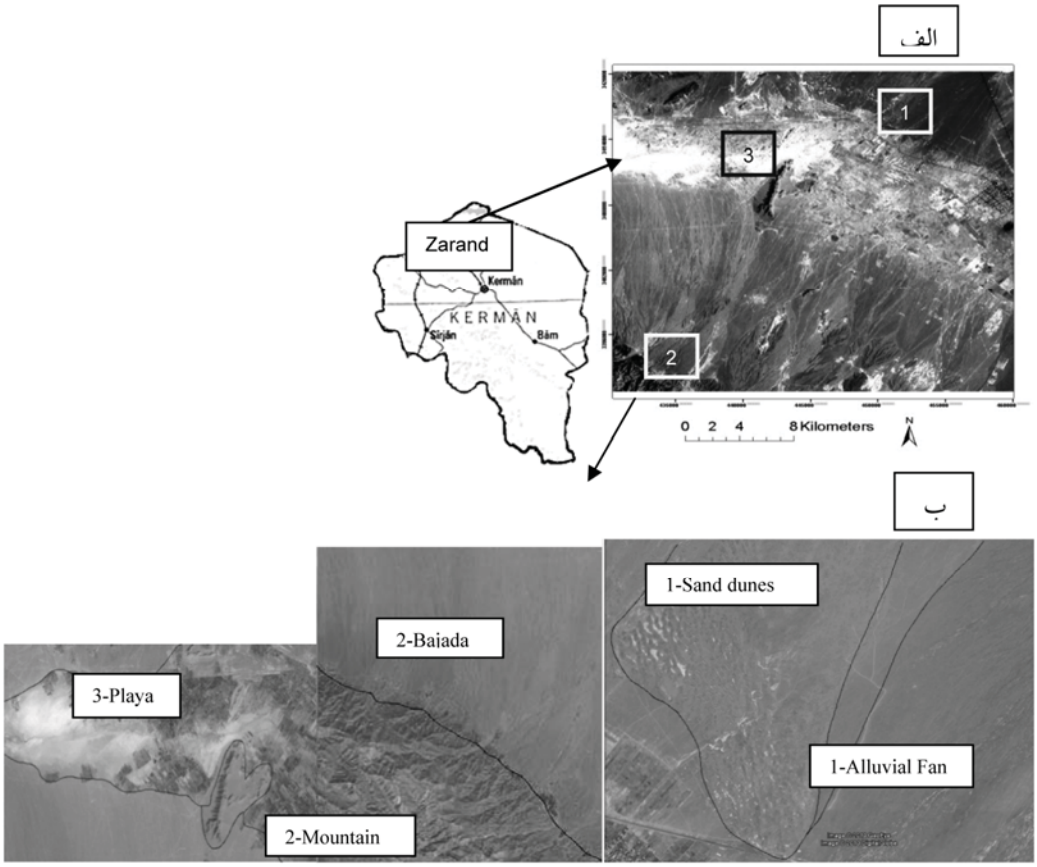

شکل ۱- منطقه مطالعاتی نزدیک شهر کرمان (الف: تصویر ماهواره‌ای لندست **ETM (RGB: 243)**، ب: تصویر تهیه شده توسط **Google Earth**)

متغیرهای کمکی

یک سین تصویر ماهواره‌ای +ETM برای تعیین شاخص‌های گیاهی و شاخص رس و یک مدل رقومی ارتفاع با تفکیک مکانی ۳۰ متر که از وب سایت مدل رقومی ارتفاع جهانی استر (Aster Global Elevation Digital Model) به‌دست آمد (۲۷) برای تعیین ویژگی‌های پستی و بلندی استفاده گردید.

ویژگی‌های پستی و بلندی حاصل از مدل رقومی ارتفاع و شاخص‌های سنجش از دور در جدول ۱ ارائه گردیده است. مرحله پیش پردازش این پارامترها و شاخص‌ها در نرم افزار SAGA انجام گردید (۱۸). نقشه‌های ویژگی‌های پستی و بلندی، شاخص‌های سنجش از دور و ژئومرفولوژی به سیستم مرجع جهانی یکسانی (WGS 84 UTM 40N) تبدیل شدند. سپس همه مقادیر ویژگی-های پستی و بلندی، شاخص‌های سنجش از دور و سطوح مختلف ژئومرفولوژی معادل با نقاط نمونه‌برداری، افق‌های مشخصه و گروه-های بزرگ خاک در یک جدول گردآوری شدند و در نهایت این جدول به همراه نقشه‌های رستری متغیرهای کمکی به نرم افزار R منتقل گردید.

پیش‌بینی کلاس‌های خاک با روش رگرسیون لاجیستیک چندجمله‌ای

مدل لاجیستیک مورد خاصی از مدل خطی تعمیم یافته[1] است که به دو صورت قابل اجرا است: مدل لاجیستیک دوتایی و مدل لاجیستیک چندجمله‌ای. در مدل لاجیستیک دوتایی، متغیر وابسته به شکل حضور یا عدم حضور (صفر و یک) است، مثلا حضور یا عدم حضور افق مشخصه. در حالیکه در مدل لاجیستیک چندجمله‌ای، متغیر وابسته دارای چند کلاس یا طبقه است مثلاً کلاس‌های خاک در یک منطقه. بنابراین در این مطالعه، در اجرای مدل لاجیستیک چند جمله‌ای گروه بزرگ خاک به‌عنوان متغیر هدف می‌باشد که یک متغیر طبقه‌ای است. بنابراین، متغیر وابسته (گروه بزرگ خاک) دارای بیش از یک سطح است و حل آن به صورت دوتایی[2] امکان‌پذیر نیست، در این صورت باید یک سطح متغیر وابسته به‌عنوان طبقه مرجع[3] انتخاب شود. یک مدل لاجیستیک چندجمله‌ای با طبقه مرجع به شکل زیر نمایش داده می‌شود:

1- Generalized linear model
2- Binary
3- Reference category

Archive

www.SID.ir

جدول ۱- داده‌های محیطی مورد استفاده به‌عنوان متغیرهای پیش‌بینی‌کننده در مدل‌سازی

داده‌های محیطی	مقیاس	ماهیت فاکتور	نام	تشریح	نوع متغیر	منبع
مدل رقومی ارتفاع (DEM)	۳۰ متر	توپوگرافی	El	Elevation (m)	کمی	
			Sl	Slope angle (%)		
			MCur	Mean Curvature		
			PrCur	Profile Curvature		
			PlCur	Plan Curvature		
			WI	Wetness Index		
			TWI	Topographic Wetness Index		
			MrVBF	Multi-resolution Valley Bottom Flatness index		(۱۱)
تصویر لندست (ETM)		انعکاس نور	NDVI	Normalized Difference Vegetation Index	کمی	(۲۳)
			RVI	Ratio Vegetation Index		(۱۹)
			PVI	Perpendicular Vegetation Index		(۲۰)
			CI	Clay Index		(۸)
نقشه ژئومرفولوژی	۱:۱۰۰۰۰۰	ژئومرفولوژی	GS	Hierarchical Four level classification (18 geomorphic surfaces(GS))	کیفی	(۱۶)
نقشه ژئولوژی	۱:۱۰۰۰۰۰	زمین‌شناسی	Geol	Lithological units (9 classes)	کیفی	

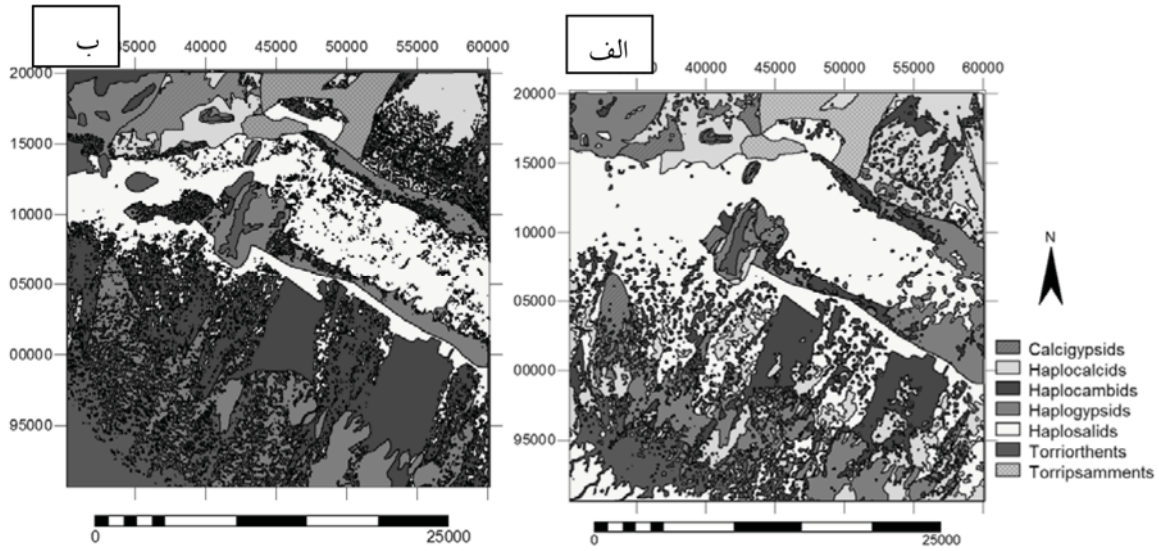

شکل ۲- توزیع مکانی گروه‌های بزرگ خاک حاصل از روش‌های مورد استفاده (الف: رگرسیون لاجیستیک چندجمله‌ای و ب: رگرسیون درختی توسعه یافته چندکلاسه)

$$\log(\frac{\pi_{ij}}{\pi_{iJ}}) = \alpha_j + \beta_j x_i, \; j = 1,2,...,J-1 \qquad (۱)$$

که α_j یک ثابت، β_j یک بـرداری[1] از ضـرایب رگرسـیون بـرای $j = 1,2,...,J-1$ و x_i برداری از متغیرهای توصیفی است.

این مدل مشابه مدل لاجیـستیک دوجملـه‌ای[2] اسـت بـه اسـتثناء اینکه توزیع احتمال متغیر هدف به جای دوجمله‌ای، چندجمله‌ای است و به جای یک معادله، J-1 معادله داریم.

1- Vector

2- Binary Logistic Regression

www.SID.ir

$$\Pr(y_i = j) = \pi_{ij} = \frac{\exp(\beta_j x_i)}{1 + \sum_{j=1}^{j} \exp(\beta_j x_i)} \quad (۲)$$

بنابراین، احتمال طبقه مرجع:

$$\Pr(y_i = 0) = \pi_{iJ} = \frac{1}{1 + \sum_{j=1}^{j} \exp(\beta_j x_i)} \quad (۳)$$

این روش در R با استفاده از بسته nnet قابل اجرا است. قبل از اجرای مدل، کلاس مرجع باید انتخاب شود. در این مطالعه، کلسی-جیپسیدز براساس پیش فرض مدل، به‌عنوان کلاس مرجع انتخاب شد. اهمیت ضریب رگرسیون هر متغیر پیش‌بینی‌کننده برای هر متغیر وابسته با استفاده از معیار آماری والد[1] ارزیابی گردید (۲۲). این معیار در واقع از تقسیم ضریب رگرسیون هر متغیر مستقل به خطای استاندارد آن به‌دست می‌آید (۸). بنابراین، ما می‌توانیم اهمیت هر پیش‌بینی‌کننده را استنباط کنیم، بدین معنی که هر چه مقدار مطلق این پارامتر بزرگتر باشد، اهمیت متغیر پیش‌بینی‌کننده بیشتر می شود. در انتخاب مدل اقتصادی هر دوی معیار Wald و AIC[2] (۱) استفاده گردید.

پیش‌بینی کلاس‌های خاک با روش رگرسیون درختی توسعه یافته (BRT)

روش رگرسیون درختی توسعه یافته، ترکیبی از دو تکنیک آماری قوی بوستینگ و رگرسیون درختی است. بوستینگ یک روش مرحله-ای رو به جلو است، که مدل‌های درختی به‌طور تکرارپذیری با زیرمجموعه‌ای از داده‌های آموزشی برازش داده می‌شود. زیرمجموعه-های داده‌های آموزشی مورد استفاده در هر تکرار از برازش مدل به‌طور تصادفی بدون جایگزینی انتخاب می‌شوند. سهم داده‌های آموزشی مورد استفاده توسط مدل‌ساز با پارامتری به نام کسر کل[3] (کسری از کل داده‌های موجود) تعیین می‌شود. این فرآیند در واقع فرآیند تصادفی بودن[4] را به مدل اعمال می‌کند که دقت مدل را افزایش و برازش بیش از حد[5] را کاهش می‌دهد (۹).

در ابتدا، ۵۰ درخت به‌طور معمولی برازش داده می شود. سپس باقی‌مانده‌های حاصل از برازش اولیه با مجموعه دیگری از ۵۰ درخت برازش داده می شود، باقی‌مانده‌های حاصله دوباره با ۵۰ درخت دیگر برازش داده می‌شود و این‌کار ادامه می‌یابد تا این‌که تابع خطا حداقل شود. در مورد رگرسیون درختی، تابع خطا در واقع انحراف مدل است.

در برازش BRT، دو پارامتر باید مشخص شود: نرخ یادگیری[6] و پیچیدگی درخت[7]. نرخ یادگیری، سهم هر درخت متوالی را در مدل نهایی تعیین می‌کند. پیچیدگی درخت اثرات اصلی (tree complexity=1) یا اثرات متقابل بین متغیرها (tree complexity=2,3,..) را نشان می‌دهد. در نهایت، نرخ یادگیری و پیچیدگی درخت با هم تعداد کل درختان در مدل نهایی را تعیین می-کنند (۵ و ۷).

مدل‌های BRT با استفاده از کد BRT تأمین شده توسط الیت و همکاران (۹) و همچنین بسته "gbm" (۲۱) در نرم افزار R برازش داده شدند. برای برازش مدل BRT، پارامترهای قراردادی کد BRT استفاده شد که نرخ یادگیری ۰/۰۱، پیچیدگی درخت ۱ و اعتبارسنجی متقابل[8] ۱۰ مرتبه بود. اگرچه با سعی و خطا، به‌دلیل انحراف کمتر، مقدار پارامتر کسر کل (کسری از کل داده های موجود) از ۰/۷۵ به ۰/۵ تغییر پیدا کرد. از آنجایی‌که متغیر وابسته یا متغیر مورد پیش‌بینی، گروه بزرگ خاک است و یک متغیر طبقه‌ای است، روش BRT چندکلاسه[9] انتخاب گردید.

ارزیابی دقت مدل‌ها و مقایسه آنها

برای مقایسه دقت پیش‌بینی مدل‌های مورد استفاده، داده‌ها به‌طور تصادفی به داده‌های آموزشی و اعتبارسنجی تقسیم شدند. داده‌های آموزشی، ۸۰درصد و داده‌های اعتبارسنجی، ۲۰درصد کل داده‌ها را شامل شدند. هر مدل با داده‌های آموزشی برازش داده شد و سپس پیش‌بینی برای داده‌های اعتبارسنجی انجام گردید. اعتبارسنجی با مقایسه داده‌های مشاهده شده و پیش‌بینی شده صورت گرفت. یک آرایه خطا[10] (۱۲) برای محاسبه معیارهای دقت استفاده گردید. خلوص نقشه (MP) ارتباط بین همه داده‌های مورد استفاده و داده‌های صحیح طبقه‌بندی شده (tt، ff) را تشریح می‌کند:

$$MapPurity = \frac{tt + ff}{tt + tf + ft + ff} \quad (۴)$$

دقت استفاده کننده (UA) شامل کلاس‌های حضور صحیح پیش‌بینی شده (tt) به مجموع کلاس‌های حضور صحیح پیش‌بینی شده (tt) و کلاس‌های عدم حضور که به غلط جزء کلاس‌های حضور مشاهده شده (واقعی)، پیش‌بینی شدند (tf) می‌باشد:

$$User'sAccuracy = \frac{tt}{tt + tf} \quad (۵)$$

قابلیت اطمینان تولید کننده (PR) ارتباط بین همه کلاس‌های

1- Wald Statistic
2- Akaike Information Criteria
3- Bag Fraction
4- Stochasticity
5- Overfitting

6- Learning rate
7- Tree Complexity
8- Cross Validation
9- Multiclass-BRT
10- Error matrices

Archive of SID

www.SID.ir

صحیح پیش‌بینی شده (tt) و مجموع کلاس‌های صحیح پیش‌بینی شده و کلاس‌های حضور مشاهده شده (واقعی) که به غلط جزء کلاس‌های عدم حضور پیش‌بینی شدند (ft) می‌باشد:

$$\text{Producer's Reliability} = \frac{tt}{tt + ft} \qquad (۶)$$

یک نقشه خوب دارای مقادیر خلوص نقشه، دقت استفاده کننده و قابلیت اطمینان تولید کننده نزدیک به یک است (۵).

نتایج و بحث

مدل‌سازی ارتباط خاک-ژئومرفولوژی-سرزمین توسط رگرسیون لاجیستیک

نتایج مدل‌سازی توسط روش رگرسیون لاجیستیک و متغیرهای وارد شده در مدل‌سازی جهت پیش‌بینی کلاس‌های خاک در جدول ۲ ارائه شده است. همان‌طوری‌که نتایج این جدول نشان می‌دهد سطح ژئومرفیک یک پیش‌بینی کننده قدرتمند محسوب می‌شود، در حالی‌که سطوح دیگر ژئومرفولوژی (زمین‌نما، شکل زمین و سنگ‌شناسی[1]) در پیش‌بینی تأثیری نداشتند. این نتیجه را می‌توان چنین تشریح کرد که سطوح ژئومرفیک در طول یک دوره زمین‌شناسی همراه با شرایط تشکیل خاک نزدیک به فرآیندهای خاک‌سازی کنونی در مناطق خشک تشکیل شدند، چرا که سطوح ژئومرفیک آخرین و نزدیک‌ترین سطح به شرایط خاک در مقیاس بزرگ می‌باشد. بعد از سطوح ژئومرفیک، ویژگی‌های پستی و بلندی جزء مؤثرترین پارامترها برای پیش‌بینی بودند (جدول ۲) که تأیید کننده این مطلب است که در این ناحیه توپوگرافی یا پستی و بلندی، مهم‌ترین فاکتور خاک‌سازی می‌باشد.

هیچ کدام از شاخص‌های سنجش از دور در پیش‌بینی گروه بزرگ خاک توسط رگرسیون لاجیستیک سهمی نداشتند. بعد از سطح ژئومرفیک، شاخص خیسی و شاخص همواری دره با درجه تفکیک بالا (MrVBF) مهم‌ترین پیش‌بینی کننده بودند (جدول ۳). شاخص همواری دره با درجه تفکیک بالا (MrVBF) در تشخیص سطوح دره‌ای شکل کمک می‌کند و شاخص خیسی درجه رطوبت را نشان می‌دهد (۲۸). این پارامترها فرآیند انتقال رسوب به‌ویژه جریان رسوبات و مواد در حال حرکت را نشان می‌دهند (۲۸). بنابراین، این شاخص‌ها به‌طور غیرمستقیم نیروی رانشی در تشخیص بعضی از گروه‌های بزرگ خاک مورد مطالعه به‌ویژه هاپلوسالید، هاپلوکلسید و کلسی‌جیپسید هستند. نقش مؤثر فرآیندهای ژئومرفولوژی توسط اسکول و همکاران (۲۵) در پیش‌بینی کلاس‌های خاک به اثبات رسیده است. همچنین، دبلاگیلو و اتزلمولر (۷) تأثیر معنی‌دار ویژگی‌های پستی و بلندی را روی توزیع گروه‌های خاک توسط روش لاجیستیک چندجمله‌ای نشان دادند. در حقیقت، حضور ویژگی‌های پستی و بلندی به همراه فرآیندهای ژئومرفیک در پیش‌بینی کلاس‌های خاک نشان داد که این فاکتورها برآیند و نتیجه نیروهای مؤثر خاک‌سازی در منطقه مورد مطالعه هستند. نقشه گروه بزرگ خاک حاصل از روش رگرسیون لاجیستیک چندجمله‌ای در شکل ۲ نشان داده شده است.

مدل‌سازی ارتباط خاک-ژئومرفولوژی-سرزمین توسط مدل رگرسیون درختی توسعه یافته

مدل BRT چندکلاسه مستقیماً گروه‌های بزرگ خاک را از متغیرهای پیش‌بینی کننده تخمین می‌زند. بهترین مدل برای پیش‌بینی مشابه روش رگرسیون لاجیستیک براساس بیشترین مقدار AUC و کمترین انحراف انتخاب گردید. نقشه ژئومرفولوژی به‌عنوان مهم‌ترین تخمین‌گر برای همه گروه‌های بزرگ خاک تشخیص داده شد، که مجدداً نقش مؤثر فرآیندهای ژئومرفولوژی در توسعه خاک را تأیید می‌کند. این نتیجه همچنین در مورد رگرسیون لاجیستیک چندجمله‌ای نشان داده شد. بنابراین، براساس نتایج به‌دست آمده از مدل‌سازی، نقش انکارناپذیر فرآیندهای ژئومرفولوژی در این مطالعه تأیید می‌شود.

به‌دلیل فراوانی بالای گروه بزرگ هاپلوسالید و همچنین حضور پوشش گیاهی در پلایا، شاخص‌های سنجش از دور همچون PVI و NDVI و همچنین ویژگی‌های پستی و بلندی مانند MrVBF برای برازش این گروه بزرگ در مدل‌ها وارد شدند. برای دیگر گروه‌های بزرگ خاک عمدتاً ویژگی‌های پستی و بلندی عوامل توجیه‌کننده بودند. نقشه گروه‌های بزرگ خاک حاصل از روش‌های BRT چندکلاسه در شکل ۲ نشان داده شده است.

در پیش‌بینی گروه‌های بزرگ خاک توسط این روش‌ها تفاوت‌هایی وجود دارد، به‌ویژه گروه بزرگ تری‌ارتنت تخمین زده شده توسط مدل لاجیستیک چندجمله‌ای به گروه بزرگ هاپلوسالید طبقه‌بندی شدند در حالی‌که در مدل BRT پیش‌بینی بهتری انجام شده است.

همچنین، باید به تعدادکم نمونه‌های تری‌ارتنت توجه کرد، هرچند که مدل BRT پیش‌بینی بهتری برای این گروه بزرگ به‌ویژه در قسمت شمال‌غربی منطقه مورد مطالعه نشان داد (شکل ۲). همان‌طوری‌که مورد انتظار بود مدل BRT گروه بزرگ تری‌سامنت را در تپه‌های شنی، هاپلوجیپسید را در تپه‌های گچی و هاپلوکلسید را در مخروطه‌افکنه‌ها به خوبی پیش‌بینی کرد (شکل ۲). این نتیجه توسط مدل لاجیستیک نیز به‌دست آمد. بنابراین، مدل BRT پتانسیل بالایی برای پیش‌بینی دارد، به‌ویژه اگر پایگاه داده بزرگی موجود باشد.

1- Landscape, Landform and Lithology

Archive of SID

www.SID.ir

جدول ۲- متغیرهای مورد استفاده در پیش‌بینی گروه بزرگ خاک

مدل‌های مورد استفاده در پیش‌بینی	متغیرهای مورد استفاده در مدل	متغیرها بر اساس اهمیت
مدل رگرسیون لاجیستیک چندجمله‌ای	GS+ MrVBF+ El+ WI	GS***,MrVBF***, WI**, El*
مدل رگرسیون درختی توسعه یافته	GS+ MrVBF+ PVI+ WI+ PrCur	GS***, MrVBF***,WI***,PVI**,PrCur**

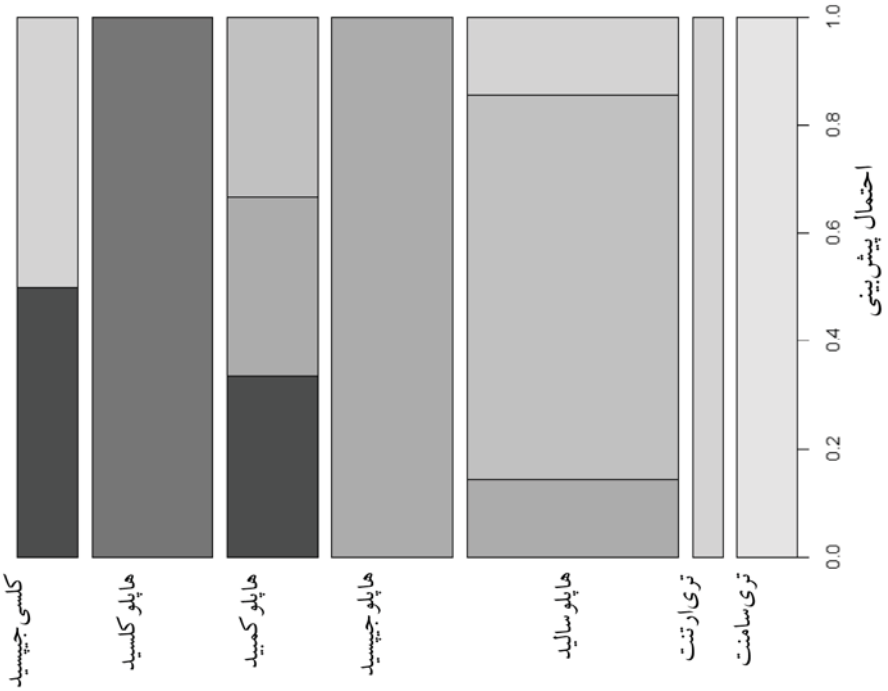

شکل ۳- احتمال پیش‌بینی گروه‌های بزرگ خاک حاصل از مدل لاجیستیک چندجمله‌ای برای داده‌های اعتبارسنجی

مقایسه مدل‌های پیش‌بینی‌کننده

خلوص نقشه، دقت استفاده‌کننده و قابلیت اعتبار تولیدکننده برای گروه های بزرگ خاک برای مدل‌های مورد بررسی (مدل لاجیستیک و مدل درختی توسعه یافته) در جدول ۳ ارائه شده است. در داده‌های واسنجی، دقت و قابلیت اعتبار مدل‌ها تفاوت معنی‌داری نداشت هرچند که دقت برای گروه بزرگ کلسی‌جیپسید حاصل از مدل BRT چندکلاسه به‌طور قابل ملاحظه‌ای بالاتر بود. هدف واسنجی، اطمینان از دقت مدل در شناسایی ورودی‌ها و ارتباط شان است، بنابراین در صورت تشخیص روابط، واسنجی نتایج خوبی را در بر خواهد داشت. به نظر می‌رسد شناسایی خوب روابط در اصل به اندازه و توزیع نمونه در لایه‌ها بستگی دارد. در مکان‌های مختلف این منطقه وسیع، فقط ۵ نمونه کلسی‌جیپسید وجود داشت، بنابراین دقت پایین مورد انتظار است. جدول ۳ به‌طور واضح نشان می‌دهد که BRT به‌دلیل ساختار انعطاف‌پذیر و تکرار اپتیمم‌سازی آن، یک تکنیک قدرتمند است.

در هر دو مدل، خلوص نقشه برای همه گروه‌های بزرگ در موقعیت‌های اعتبارسنجی بالاتراز ۰/۶ بود (جدول ۳) که حاکی از پیش‌بینی نسبتاً خوب با هر دو روش است در مقایسه با مقدار ۰/۷ که برای نقشه‌برداری سنتی خاک، مقدار هدف است (۲۸). همچنین، جدول ۳ نشان می‌دهد که دقت پیش‌بینی برای همه انواع خاک ها یکسان نیست. عملکرد ضعیف‌تر برای گروه‌های بزرگ کلسی‌جیپسید و هاپلوکمبید در هر دو روش مشاهده شد. قابلیت اطمینان تولیدکننده برای داده‌های اعتبارسنجی حاصل از مدل لاجیستیک چندجمله‌ای (جدول ۳) را به‌صورت یک آرایه خطا در جدول ۴ و شکل ۳ نشان داده شده است که می توان عملکرد ضعیف را برای گروه‌های بزرگ کلسی‌جیپسید و هاپلوکمبید مشاهده کرد. به‌عنوان مثال از دو نمونه خاک کلسی‌جیپسید، یکی به درستی پیش‌بینی شده اما نمونه دیگر به‌عنوان گروه بزرگ تری‌ارتنت پیش‌بینی شده است (جدول ۴).

همچنین در شکل ۳ ستون مربوط به گروه بزرگ کلسی‌جیپسید به دو قسمت تقسیم شده که یک قسمت آن همان نمونه صحیح پیش‌بینی شده و دیگری رنگ مربوط به ستون گروه بزرگ تری‌ارتنت را نشان می‌دهد که مطابق جدول ۴ صحیح می‌باشد.

Archive

www.SID.ir

جدول ۳- کیفیت پیش‌بینی مدل‌های مورد استفاده برای گروه‌های بزرگ خاک

گروه بزرگ خاک	داده‌های واسنجی						داده‌های اعتبارسنجی					
	رگرسیون لاجیستیک چندجمله‌ای			رگرسیون درختی توسعه یافته			رگرسیون لاجیستیک چندجمله‌ای			رگرسیون درختی توسعه یافته		
	MP	UA	PR	MP	UA	PR	MP	UA	PR	MP	UA	PR
نقشه رقومی حاصله	۰/۷۸	–	–	۰/۷۳	–	–	۰/۷۴	–	–	۰/۶۵	–	–
کلسی‌جیپسید		۰/۵	۰/۲		۱	۰/۲		۰/۵	۰/۵		۰	۰
هاپلوکلسید		۰/۷۱	۰/۶۷		۱	۰/۶۱		۱	۱		۱	۰/۷۵
هاپلوکمبید		۰/۶۹	۰/۵۶		۰/۵۶	۰/۹۴		۰	۰		۰/۲۵	۰/۶۷
هاپلوجیپسید		۰/۶۴	۰/۷۴		۰/۶۰	۰/۷۴		۰/۵۷	۱		۰/۶	۰/۷۵
هاپلوسالید		۰/۶۵	۰/۷۶		۰/۹۵	۰/۷۲		۰/۸۳	۰/۷۱		۱	۰/۷۱
تری‌ارتنت		۰/۷۱	۰/۶۳		۰/۶۷	۰/۷۵		۰/۵	۱		۰	۰/۷۵
تری‌سامنت		۱	۱		۱	۱		۱	۱		۱	۱

MP: Map Purity, UA: User Accuracy, PR: Producer Reliability

جدول ٤- قابلیت اطمینان تولیدکننده حاصل از مدل لاجیستیک چندجمله‌ای برای داده‌های اعتبارسنجی

مشاهده شده ~~پیش‌بینی شده~~	کلسی‌جیپسید	هاپلوکلسید	هاپلوکمبید	هاپلوجیپسید	هاپلوسالید	تری‌ارتنت	تری‌سامنت
کلسی‌جیپسیدز	۱		۱	–	–	–	–
هاپلوکلسیدز	–	۴	–	–	–	–	–
هاپلوکمبیدز	–	–	–	–	–	–	–
هاپلوجیپسیدز	–	–	۱	۴	۱	–	–
هاپلوسالیدز	–	–	۱	–	۵	–	–
تری‌ارتنتز	۱	–	–	–	۱	۱	–
تری‌سامنتز	–	–	–	–	–	–	۲
تعداد کل	۲	۴	۳	۴	۷	۱	۲

البته باید ذکر گردد با این تعداد نمونه کم نمی‌توان به‌طور قطع نتیجه گرفت عملکرد مدل لاجیستیک چند جمله‌ای برای گروه بزرگ هاپلوکلسید ۵۰٪ است چرا که ممکن است این نتیجه به‌صورت تصادفی به‌دست آمده باشد. در جدول ۳، شاخص‌های کیفیت حاصل از لاجیستیک چندجمله‌ای برای داده‌های اعتبارسنجی مربوط به کلسی‌جیپسید، نتایج بالا را تأیید می‌کند. در مورد گروه بزرگ هاپلوکمبید هم از سه نمونه هیچ کدام به درستی پیش‌بینی نشدند (جدول ۴) در واقع یک نمونه به کلسی‌جیپسید، یک نمونه هم به هاپلوسالید و نمونه سوم هم به هاپلوجیپسید پیش‌بینی شدند. در شکل ۳ این نتایج تأیید می‌گردد به‌طوری‌که ستون مربوط به گروه بزرگ هاپلوکمبید به سه قسمت تقسیم شده که شامل کلسی‌جیپسید، هاپلوسالید و هاپلوجیپسید می‌باشند. طبق جدول ۳ شاخص‌های کیفیت حاصل از لاجیستیک چندجمله‌ای برای داده‌های اعتبارسنجی مربوط به هاپلوکمبید صفر است که تأییدکننده نتایج بالا می‌باشد. احتمال دارد پیش‌بینی‌های با درجه بالای عدم قطعیت نتیجه مدل مفهومی ناقص باشند (در مورد گروه‌های بزرگ کلسی‌جیپسیدز و هاپلوکمبیدز). البته قضاوت در مورد ضعف و ناتوانی مدل‌ها منطقی نیست چرا که تعداد نسبتاً کم نمونه‌ها (۱۰۰ داده آموزشی و ۲۳ داده اعتبارسنجی) برای چنین منطقه وسیعی، تشخیص رابطه پیش‌بینی دقیق را برای طبقه‌بندی کلاس‌های خاک دچار مشکل می‌کند. علاوه براین، هیچ خصوصیت مشخصه‌ای برای گروه بزرگ هاپلوکمبید وجود ندارد که بتواند برای طبقه‌بندی کمک کند.

شاید اگر این مطالعه در یک مقیاس تفصیلی‌تر یا حتی با به‌کار بردن پیش‌بینی کننده‌های بیشتری انجام می‌شد، پیش‌بینی‌های دقیق‌تری برای گروه بزرگ هاپلوکمبید به‌دست می‌آمد. علاوه بر این، میزان اریب‌بودن[1] در نمونه‌برداری (فقدان مشخص‌سازی کامل فضای پیش‌بینی‌کننده با توجه به متغیر پاسخ) در عدم قطعیت سهیم است (۳). تعداد نمونه‌ها، سطح منطقه مورد مطالعه و مقیاس نقشه از جمله پارامترهایی هستند که نتایج و عملکرد پیش‌بینی را تحت تأثیر قرار

1- Bias

Archive of SID

www.SID.ir

می‌دهند و همچنین به‌دلیل طرح نمونه‌برداری مورد استفاده در این مطالعه، یک بایاسی در توزیع انواع خاک ها اتفاق می‌افتد که خود می‌تواند دلیلی باشد بر اینکه چرا پیش‌بینی خاک‌های با حضور خیلی محدود دقت کمتری دارد در مقایسه با خاک‌های فراوان‌تر که دقت بیشتری دارد (جدول ۳).

در حالی‌که همه نتایج برای داده‌های واسنجی (جدول ۳) عملکرد خوب BRT را پیشنهاد کرد، داده‌های اعتبارسنجی نتایج عکسی را برای روش BRT (جدول ۳) نشان داد. بالاترین خلوص نقشه برای پیش‌بینی گروه‌های بزرگ خاک توسط لاجیستیک چندجمله‌ای رقم خورد. هر دو مدل در موقعیت‌های اعتبارسنجی، گروه‌های بزرگ کلسی‌جیپسید و هاپلوکمبید را ضعیف پیش‌بینی کردند. نتایج ضعیف عمدتاً به‌دلیل اندازه کم نمونه در منطقه وسیع (۱۰۰ موقعیت آموزشی و ۲۳ موقعیت اعتبارسازی) و نمایش ضعیف انواع خاک‌ها با حضور خیلی محدود در منطقه تحقیقاتی در مقایسه با نمایش بیشتر انواع دیگر خاک (۴) بود. علاوه براین، اگر معیارهای تشخیص برای بعضی خاک‌ها ناشناخته باشد، شناسایی آنها به‌طور دقیق خیلی مشکل است. این مسئله برای هاپلوکمبیدهای مورد مطالعه واقعیت داشت، هرچند که با افزایش داده پیش‌بینی آنها بهبود یافت (جدول ۳).

نتایج نشان داد که حداکثر کاهش در عملکرد پیش‌بینی، مربوط به پیش‌بینی گروه‌های بزرگ کلسی‌جیپسید، هاپلوکلسید و هاپلوکمبید بود. تعداد این گروه‌های بزرگ خاک در داده‌های واسنجی و اعتبارسازی کمتر بود در حالیکه عملکرد پیش‌بینی برای گروه‌های بزرگ هاپلوسالید و هاپلوجیپسید بهتر بود (جدول ۳)، چرا که این گروه‌های بزرگ خاک در داده‌های واسنجی و اعتبارسازی تعداد نمونه بیشتری را شامل می‌شدند. بنابراین، به نظر می‌رسد مدل BRT به تعداد نمونه حساس‌تر است، به‌طوری‌که هرچه داده‌های بیشتری برای برازش مدل استفاده شود، تغییرپذیری کلاس‌های خاک بهتر نشان داده می‌شود و پیش‌بینی کلاس‌های خاک در داده‌های آزمایشی بهبود یافته است.

روش لاجیستیک چندجمله‌ای، گروه بزرگ تری‌ارتنت را بهتر پیش‌بینی کرده است (جدول ۳) هرچند که در این روش هم بعضی از تری‌ارتنت‌ها به هاپلوجیپسیدها طبقه‌بندی شده‌اند (جنوب غربی شکل ۲). شکل ۳ پیش‌بینی غلط گروه بزرگ تری‌ارتنت به کلاس‌های دیگر را نشان نمی‌دهد اما جدول ۴ پیش‌بینی غلط کلاس‌های دیگر به گروه بزرگ تری‌ارتنت را به خوبی نشان می‌دهد که باعث دقت کاربر پایین می‌شود. این مسئله با توجه به نتایج جدول ۳ کاملاً مشخص و واضح است. تعداد کم این نوع خاک‌ها و در نتیجه فقدان ارتباط خوب بین پیش‌بینی‌کننده‌ها و این گروه بزرگ خاک، خود عاملی بر قابلیت اطمینان پایین این خاک‌ها می‌باشد. اگرچه نقشه گروه بزرگ خاک حاصل از مدل BRT نسبت به مدل لاجیستیک چندجمله‌ای بیشتر با واقعیت انطباق داشت، عملکرد پیش‌بینی مدل‌های BRT برای گروه بزرگ تری‌ارتنت در داده‌های واسنجی بالا بود (شکل ۲) به‌ویژه در قسمت شمال‌غربی که مدل لاجیستیک چندجمله‌ای، گروه بزرگ تری‌ارتنت را به گروه بزرگ هاپلوسالید و هاپلوجیپسید طبقه‌بندی کرده است. این نتیجه مجدداً حساسیت BRT را به تعداد نمونه کم نشان می‌دهد. برای گروه بزرگ تری‌سامنت به‌دلیل ارتباط مستقیم بین این گروه خاک و داده‌های توصیفی (جدول ۲) حتی با تعداد کم نمونه، همه مدل‌ها عملکرد پیش‌بینی بالایی را نشان دادند (جدول ۳).

در بین گروه‌های بزرگ خاک، بهترین پیش‌بینی برای گروه بزرگ هاپلوسالید به‌دست آمد، مقادیر بالای دقت کاربران و قابلیت اطمینان تولیدکننده در جدول ۳ این مسئله را نشان می‌دهد. پیش‌بینی دقیق کلاس هاپلوسالید با توزیع مکانی شاخص‌هایی همچون شاخص خیسی، NDVI و لندفرم پلایا به‌ویژه در مرکز آن همبستگی بالایی دارد. دبلاگیلو و ازلمولر (۷) نشان دادند نواحی با احتمال بالا برای هر گروه بزرگ خاک با لندسکیپ‌های کاملاً شناخته شده منطبق است. پارامترهای سنجش از دور (بازتاب نوری) در پیش‌بینی گروه‌های بزرگ هاپلوسالید، تری‌ارتنت و هاپلوجیپسید تعیین‌کننده هستند، نواحی مشترک در نقشه‌های آنها گویای این حقیقت است.

زمانی‌که پارامترهای حاصل از سرزمین و سنجش از دور و فرآیندهای ژئومرفولوژی همه با هم در پیش‌بینی شرکت کنند، بهترین نتایج پیش‌بینی حاصل می‌شود. به نظر می‌رسد جایی‌که توزیع پیش‌بینی‌کننده‌ها یکنواخت‌تر باشد و تغییرپذیری کمتری داشته باشد، مدل‌ها سریع‌تر رابطه پیش‌بینی کننده و متغیر وابسته را تشخیص می‌دهند و ارتباط برقرار می‌کنند. به‌طورکلی، این روش های پیش‌بینی گروه‌های بزرگ خاک (لاجیستیک چندجمله‌ای و BRT چندکلاسه) که بیشتر شبیه یک روش جعبه سیاه عمل می‌کنند، نقشه خاک با درجه خلوص بالایی تولید کردند.

نتیجه‌گیری

نتایج حاصل از این مطالعه به‌طور خلاصه بیان می‌شود:

نقشه ژئومرفولوژی یک ابزار مهم برای روش های نقشه‌برداری رقومی خاک است که به افزایش دقت پیش‌بینی کمک می‌کند. از آنجایی‌که فرآیندهای ژئومرفولوژی در متن سرزمین عمل می‌کنند، هر دو عامل، به‌ویژه در مناطق خشک توسعه و تکامل خاک را تحت تأثیر قرار می‌دهند.

پیش‌بینی‌کننده‌های انتخاب شده با توجه به شرایط تشکیل خاک در لندسکیپ به تفسیر داده‌ها کمک می‌کنند. زمانی‌که همه فاکتورهای خاک‌سازی به‌طور همزمان در روش مدل‌سازی استفاده شوند، بهترین پیش‌بینی‌ها حاصل می‌شود.

نقشه گروه بزرگ خاک حاصل از روش رگرسیون درختی توسعه

Archive of SID

www.SID.ir

یافته با واقعیت سازگارتر بود.

نتایج نشان داد مدل رگرسیون درختی توسعه یافته به پایگاه داده کوچک حساس است.

تلفیق داده‌های جغرافیایی با نرم افزار R، فرصتی را برای پیش-بینی کلاس‌های خاک فراهم می‌کند و نرم‌افزارهای بر پایه GIS (مثل SAGA) و نرم‌افزارهای آماری قوی (مثل R) به آسانی نقشه-برداران خاک را حمایت می‌کند. انتظار می‌رود روش‌های توسعه یافته آنالیز رقومی سرزمین و تشریح واضح فرآیندهای ژئومرفولوژی–زمین-شناسی–پدولوژی به‌عنوان کلید تکنولوژی در نقشه‌برداری رقومی خاک وارد شود.

منابع

1- Akaike H. 1973. Information theory and an extension of the maximum likelihood principle. p. 267–281. In B.N. Petrov and Csaki F. (eds) 2th International Symposium on Information Theory. Akademiai Kiado, Budapest.
2- Bailey N., Clements T., Lee, J.T., and Thompson S. 2003. Modelling soil series data to facilitate targeted habitat restoration: a polytomous logistic regression approach. Journal of Environmental Management, 67(4): 395–407.
3- Bauer E., and Kohavi R. 1999. An empirical comparison of voting classification algorithms: Bagging, boosting, and variants. Machine Learning, 36: 105–139.
4- Beaudette D.E., and O'Geen A.T. 2008. New digital soil survey products to quantify soil variability over 28 multiple scales. Kearney Foundation of Soil Science: Understanding and Managing Soil-29 Ecosystem Functions Across Spatial and Temporal Scales. 2006-2011 Mission.
5- Behrens T., Zhu A.X., Schmidt, K., and Scholten T. 2010. Multi-scale digital terrain analysis and feature selection for digital soil mapping. Geoderma, 155:175-185.
6- Campling P., Gobin, A., and Feyen J. 2002. Logistic modeling to spatially predict the probability of soil drainage classes. Soil Science Society of American Journal, 66:1390-1401.
7- Debella-Gilo M., and Etzelmuller B. 2009. Spatial prediction of soil classes using digital terrain analysis and multinomial logistic regression modeling integrated in GIS: Examples from Vestfold County, Norway. Catena, 77:8-18.
8- Deventer van A.P., Ward A.D., Gowda, P.H., and Lyon J.G. 1997. Using thematic mapper data to identify contrasting soil plains and tillage practices. Photogrammetric Engineering and Remote Sensing, 63(1):87-93.
9- Elith J., Leathwick, J.R., and Hastie T. 2008. A working guide to boosted regression trees. Journal of Animal Ecology, 77:802-813.
10- Friedman J., Hastie T., and Tibshirani R. 2000. Additive Logistic Regression: A Statistical View of Boosting. Annals of Statistics, 28(2):337-407.
11- Gallant J.C., and Dowling T.I. 2003. A multiresolution index of valley bottom flatness for mapping depositional areas. Water Resource Research, 39(1):1347.
12- Gamberger D., and Smuc T. 2001. Data Mining Server. http://www.dms.irb.hr/.
13- Grinand C., Arrouays D., Laroche, B., and Martin M.P. 2008. Extrapolating regional soil landscapes from an existing soil map: Sampling intensity, validation procedures, and integration of spatial context. Geoderma, 143:180-190.
14- Hengl T., Toomanian N., Reuter, H., and Malakouti M.J. 2007. Methods to interpolate soil categorical variables from profile observations: Lessons from Iran. Geoderma, 140:417-427.
15- Lagacherie P. 1992. Formalisation des lois de distribution des sols pour automatiser la cartographie pédologique à partir d'un secteur pris comme référence. Mémoire de Thèse, Université de Montpellier. Institut National de la Recherche Agronomique, France. p. 175.
16- Moameni A., and Zink J.A. 1997. Application of statistical quality control charts and geostatistics to soil quality assessment in a semi-arid environment of south-central Iran. ITC Journal, 1997-3/4.
17- Ohlmacher G.C., and Davis J.C. 2003. Using multiple logistic regression and GIS technology to predict landslide hazard in northeast Kansas, USA. Engineering Geology, 69:331–343.
18- Olaya V. 2004. A gentle introduction to Saga GIS. User manual, The SAGA User Group, Göttingen.
19- Pearson R.L., and Miller L.D. 1972. Remote mapping of standing crop biomass for estimation of the productivity of the short-grass Prairie, Pawnee National Grasslands, Colorado. p. 1357-1381. In Proceedings of the 8th International Symposium on Remote Sensing of Environment, ERIM International, Inc., Ann Arbor, Michigan, USA.
20- Richardson A.J., and Wiegand C.L. 1977. Distinguishing vegetation from soil background information. Photogrammetric Engineering and Remote Sensing, 43(12):1541-1552.
21- Ridgeway G. 2009. Package _gbm'. R-News. 08:05:15.
22- Rossiter D.G., and Loza A.V. 2010. Analyzing land cover change with logistic regression in R: Technical Note. International Institute for Geoinformation Science and Earth Observation (ITC), Enschede. Available at http://www.itc.nl/personal/rossiter.
23- Rouse J.W., Haas R.H., Schell, J.A., and Deering D.W. 1973. Monitoring vegetation systems in the Great Plains

Archive of SID

www.SID.ir

with ERTS. p. 309-317. In 3rd Proceeding ERTS Symposium, 10-14 December. 1973. NASA SP-351. Natl. Aeronaut. Space Admin., Washington, DC.
24- Scull P. R. 2002. Predictive soil mapping in the Mojave Desert of California. University of California, San Diego State University, PhD thesis.
25- Scull P., Franklin J., Chadwick, O.A., and McArthur D. 2003. Predictive soil mapping: a review. Progress Physical Geography, 27:171-197.
26- Soil Survey Staff. 2010. Keys to Soil Taxonomy, Eleventh edition, NRCS, USDA.
27- The Ministry of Economy, Trade and Industry of Japan (METI) and the National Aeronautics and Space Administration (NASA). 2009. Aster Global Digital Elevation Model (Aster GDEM). NASA Official. URL http://www.gdem.aster.ersdac.or.jp.
28- Wang D., and Laffan S.W. 2009. Characterisation of valleys from DEMs. In Proceedings of the 18th World IMACS Congress and MODSIM International Congress on Modeling and Simulation, 13-17 July. Cairns, Australia. Available at http://mssanz.org.au/modsim09.

Archive of SID

www.SID.ir

Journal of Water and Soil
Vol. 25, No. 6, Jan-Feb 2012, p. 1353-1364

نشریه آب و خاک (علوم و صنایع کشاورزی)
جلد ۲۵، شماره ۶، بهمن - اسفند ۱۳۹۰، ص. ۱۳۶۴-۱۳۵۳

Application of Regression Models for Prediction of Soil Classes in Some Regions of Central Iran (Zarand district, Kerman Province)

A. Jafari[1]- Sh. Ayoubi[2*]- H. Khademi[3]

Received:23-1-2011
Accepted:21-8-2011

Abstract

Soil digital survey as tool for soil spatial information provides pathways for producing of high resolution soil maps. Therefore, it should be developed strategic methods for making high resolution soil spatial information. Subsequently, this study was designed for prediction of soil classes by regression models in Zarand region of Kerman. Regression models includes of multinomial logistic regression and multiclass boosted regression tree were used for prediction of soil great groups by relating those with predictors such as remote sensing indices, terrain attributes and geomorphology map. A confusion matrix was used to calculate aspects of map accuracy. The geomorphology map at the fourth level (geomorphic surface) was a powerful predictor unlike the other levels (landscape, landform and lithology). Terrain attributes and finally remote sensing indices after geomorphic surface were imported as predictors in the prediction. The map purity over all soil great groups was above 0.60 in both calibration and validation locations. Poorer performance was observed for Calcigypsids and Haplocambids. Both methods provided good predictions for Haplosalids that shown by high values for users' accuracy and producers' reliability The results showed soils with better reliability are those highly influenced by topographic and geomorphic characteristics at least in this study area (e.g. Haplosalids, Haplogypsids and Torripsamments) and soils with very low reliability and accuracy of prediction are hardly influenced by the topographic and geomorphic characteristics (e.g. Haplocambids and Calcigypsids).

Keywords: Digital soil mapping, Multinomial logistic regression, Boosted regression tree

Archive of SID

1,2,3- PhD Student, Associate Professor and Professor, Department of Soil Science, College of Agriculture, Isfahan University of Technology, Respectively
(*- Corresponding Author Email: ayoubi@cc.iut.ac.ir)

www.SID.ir