

نقشه برداری رقومی بافت خاک با استفاده از رگرسیون درختی و شبکه عصبی مصنوعی در منطقه بیجار کردستان

کمال نبی الهی^{۱*} - احمد حیدری^۲ - روح اله تقی زاده مهرجردی^۳

تاریخ دریافت: ۱۳۹۲/۹/۵

تاریخ پذیرش: ۱۳۹۳/۵/۴

چکیده

در مطالعه حاضر جهت پهنه بندی رقومی کلاس های بافتی خاک در منطقه بیجار کردستان، ۱۰۳ پروفیل حفر، تشریح و از افق های سطحی A نمونه برداری شد. متغیرهای محیطی یا فاکتورهای خاک سازی که در این پژوهش استفاده شد شامل اجزاء سرزمین، داده های تصویر ETM⁺ ماهواره لندست و نقشه سطوح ژئومورفولوژی می باشد. همچنین، جهت ارتباط دادن بین داده های خاک (رس، شن و سیلت) و متغیرهای کمکی از مدل های شبکه عصبی مصنوعی و رگرسیون درختی بهره گرفته شد. نتایج این تحقیق نشان داد که مدل رگرسیون درختی دارای دقت بیشتری نسبت به شبکه عصبی مصنوعی به منظور پیش بینی هر سه پارامتر رس، شن و سیلت می باشد. برای جزء رس، مدل رگرسیون درختی و شبکه عصبی مصنوعی دارای ضریب تبیین و میانگین ریشه مربعات خطا ۰/۴۶، ۰/۸۱ و ۰/۱۷، ۱۲/۵۰ براساس داده های آزمون (۲۰ درصد) می باشد. نتایج نشان داد که برای پیش بینی رس، شن و سیلت پارامترهای سطوح ژئومورفولوژی، شاخص خسیسی، شاخص همواری دره با درجه تفکیک بالا، ارتفاع، طول شیب و باند ۳ مهم ترین بوده اند. در کل نتایج نشان داد که مدل های درختی دارای دقت بالاتری نسبت به روش شبکه عصبی مصنوعی بوده و همچنین تفسیر نتایج مدل درختی بسیار راحت تر می باشد. لذا پیشنهاد می شود که جهت تهیه نقشه رقومی خاک از مدل های درختی در مطالعات آینده استفاده شود.

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

مقدمه

خاک همچنین بر روی فرسایش پذیری خاک موثر است (۳۸). مطالعات صحرایی شناسایی خاک از روش های اولیه برای به دست آوردن خصوصیات خاک همچون بافت خاک است. معمولاً این داده های نقطه ای برای ایجاد نقشه های خاک درون یابی می شوند. روش های مختلف درون یابی مانند کریجینگ برای تولید نقشه های خاک استفاده شده است. برای مثال ولتز و وبستر (۳۵) مقدار رس خاک را بر اساس روش کریجینگ و روش اسپلاین با استفاده از داده های مزرعه ای جمع آوری شده از ۱۷۵ نقطه با طراحی نمونه برداری شبکه ای ۱۰۰ متر در ۱۰۰ متر پیش بینی کردند. ولتز و همکاران (۳۶) دریافت که سه روش درون یابی (کریجینگ، معکوس فاصله و همسایگی) ترکیب شده با اطلاعات طبقه بندی معمولی خاک، منجر به ایجاد صحت و دقت بیشتری در ارتباط با نقشه برداری خصوصیات خاک در مقایسه با استفاده از نقشه های طبقه بندی خاک در مقیاس ۱:۱۰۰۰۰۰ به تنهایی شدند. محدودیت بزرگ روش های درون یابی ذکر شده این است که فرض شده توزیع مکانی و تغییرات خصوصیات درون یابی شده پیوسته است. بنابراین این روش ها نیاز به مقدار زیادی داده برای تولید نقشه های خاک با قدرت تفکیک بالا دارند. روش های مختلف کریجینگ اصلاح شده جهت ایجاد اصلاح در

نقشه های با قدرت تفکیک بالا برای برنامه ریزی استفاده از زمین و دیگر فعالیت های مرتبط با جنگلداری، کشاورزی و حفاظت محیط زیست ضروری است (۱۱ و ۲۷). بافت یکی از مهمترین خصوصیات خاک است و به عنوان درصد نسبی مقادیر رس، شن و سیلت تعریف شده است. بافت خاک به طور مستقیم بر روی تخلخل خاک، ظرفیت نگهداری عناصر تغذیه ای و در دراز مدت بر روی حاصلخیزی خاک موثر است. خاک های سنگین رسی با خلل و فرج ریز زیاد، در پتانسیل های آبی کم دارای ظرفیت نگهداری آب بیشتراند و اغلب به دلیل شرایط زهکشی ضعیفی که دارند شرایط تهویه ای مناسبی برای رشد گیاه ندارند. از طرف دیگر خاک های شنی با خلل و فرج درشت زیاد، در شرایط خشک دارای ظرفیت نگهداری آب کمتراند. بافت

۱- استادیار گروه مهندسی علوم خاک، دانشکده کشاورزی، دانشگاه کردستان
(* نویسنده مسئول: Email: nabiollahy_k@yahoo.com)
۲- دانشیار گروه مهندسی علوم خاک، دانشکده مهندسی و فناوری کشاورزی، دانشگاه تهران
۳- استادیار گروه خاکشناسی، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان

خاک با استفاده از مدل رگرسیون درختی کردند. در مطالعه حاضر با استفاده از مدل رگرسیون درختی و شبکه عصبی مصنوعی از داده‌های کمکی مانند پارامترهای سرزمین، تصویر ماهواره و نقشه ژئومورفولوژی جهت پیش بینی کلاس بافت خاک استفاده می‌شود. لازم به ذکر می‌باشد که در این تحقیق پیش‌بینی کلاس بافت خاک به‌طور غیر مستقیم مطرح می‌باشد. بدین صورت که در ابتدا، نقشه‌های رقومی رس، شن و سیلت به صورت رقومی تهیه می‌شود و در نهایت نقشه‌ها با هم ترکیب شده تا تغییرات مکانی کلاس بافت خاک در منطقه بیجار کردستان بدست بیاید.

مواد و روش‌ها

تشریح محدوده مطالعاتی

به منظور پهنه‌بندی کلاس بافت خاک در منطقه‌ای با وسعت ۲۰۰۰۰ هکتار شمال شرقی استان کردستان در نظر گرفته شد (شکل ۱). منطقه از لحاظ سنگ‌شناسی شامل تراورتن، مارن، کنگلومرا، سنگ آهک رسی، شیل، سنگ‌های حاوی آهن زیاد، گل سنگ، سنگ آهک حاوی فسفیل، تراس‌های قدیمی، رسوبات آبرفتی و گابرو بوده و دارای دو کاربری کشاورزی دیم و مرتع می‌باشد. رژیم رطوبتی و حرارتی خاک در منطقه به ترتیب زیریک و مزیک بوده و میانگین بارندگی سالانه ۳۳۳/۴ میلی‌متر و میانگین دمای سالیانه ۱۰/۴۸ می‌باشد.

عملیات میدانی و آنالیزهای آزمایشگاهی

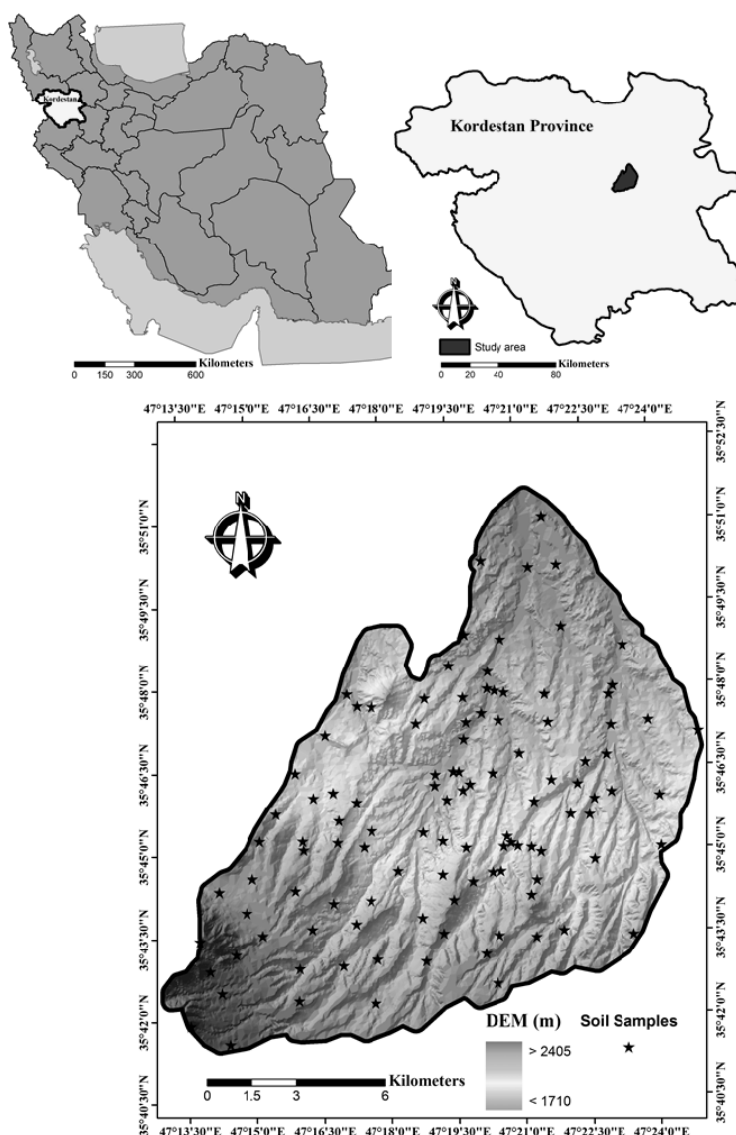
در منطقه مورد مطالعه بر اساس تغییرات واحدهای ژئومورفیک، مکان هندسی ۱۰۳ پروفیل شناسایی و سپس نمونه‌برداری از افق سطحی A انجام گرفت. به این شکل که برای هر نقطه مطالعاتی اطلاعات لازم اعم از محل پروفیل در زمین نما، نوع واحد ژئومورفیک و نوع مواد مادری یادداشت برداری و از افق‌های هر پروفیل نمونه-برداری شد. در کلیه نمونه‌های خاک پس از هوا خشک شدن و عبور از الک ۲ میلیمتری بافت خاک به روش هیدرومتری (۱۰)، اندازه‌گیری شد.

داده‌های کمکی

بر اساس مدل اسکورپین در نقشه‌برداری رقومی خاک، علاوه بر داده‌های خاک نیاز به داده‌های کمکی می‌باشد. در مطالعه حاضر، از دو سری داده کمی و کیفی به عنوان داده‌های کمکی استفاده گردید. **داده کمی:** از مدل رقومی ارتفاع سازمان زمین‌شناسی آمریکا (رزولیشن ۹۰ متر) استفاده گردید. بعد از آماده کردن مدل رقومی ارتفاع، از آن برای استخراج کردن اطلاعات کمکی یا تصاویر تخمین-زنده متغیرهای ژنتیکی خاک استفاده گردید.

صحت درون‌یابی توسعه داده شد (۲۱). اگر چه این روش‌ها هنوز نیازمند یکسری داده‌های واقعی از منطقه هستند. لذا ترکیب داده‌های کمکی و یا ترکیب دیگر روش‌ها با کریجینگ برای غلبه بر این مشکل مورد استفاده قرار گرفت. اما این روش‌های اصلاح شده هم نیاز به داده‌های مزرعه‌ای به عنوان ورودی داشتند. و دقت نقشه‌های به دست آمده باز هم بستگی به تراکم و توزیع داده‌های نقطه‌ای اصلی دارد (۲۰ و ۳۳). اگرچه صحت نقشه‌های خاک ممکن است با افزایش داده‌های نقطه‌ای بیشتر شود اما باید اذعان داشت که مطالعات صحرایی شناسی خاک پر هزینه و زمان بر است. به علت تغییرات مکانی زیاد خصوصیات خاک برای تولید نقشه‌های خاک با صحت زیاد تعداد نقاط نمونه‌برداری زیاد لازم است. علاوه بر این صحت نقشه متأثر از کیفیت داده‌های جمع‌آوری شده هم می‌باشد، مثلاً تجربه صحرایی فردی که شناسایی خاک را انجام می‌دهد می‌تواند موثر باشد (۲ و ۳۷). لذا ایجاد روش‌های کارآمدتر برای تولید نقشه بافت خاک با صحت بالا منطقی و به صرفه است.

بعضی محققین از روش‌های آماری برای این کار استفاده کرده‌اند، مثلاً از روش‌های آماری برای تولید نقشه رطوبتی خاک در مقیاس‌های مختلف استفاده شده است (۶ و ۸). در روشی مشابه نقشه‌های کربن خاک (۷)، زهکشی خاک، و ساختمان خاک (۱) ترسیم شده است. خصوصیات خاک در ارتباط نزدیک با تشکیلات زمین شناسی، موقعیت‌های داخل زمین نما می‌باشند. مدل‌های رگرسیونی چندگانه برای ایجاد ارتباط بین خصوصیات خاک و پارامترهای مشتق شده از نقشه رقومی ارتفاع مورد استفاده قرار گرفتند و در سطح بالایی هم موفق بودند (۱۵). در سال‌های اخیر، استفاده از تکنیک‌های داده‌کاوی از جمله شبکه عصبی مصنوعی و رگرسیون درختی در فرآیند نقشه‌برداری رقومی خاک رواج گسترده‌ای یافته است. به عنوان مثال ژاو و همکاران (۳۹) از مدل شبکه عصبی مصنوعی برای تولید نقشه بافت خاک استفاده کردند. مدل درختی طبقه‌بندی و رگرسیون برای اولین بار توسط بریمن و همکاران (۳) گسترش داده شد. خیر و همکاران (۱۷) از مدل رگرسیون درختی برای پهنه‌بندی نوزیع مقدار روی با استفاده از داده‌های کمکی پارامترهای سرزمین در لبنان استفاده کردند. جعفری و همکاران (۱۴) نیز در منطقه خشک اقدام به پیش‌بینی کلاس‌های خاک کرده‌اند و شاخص خیسی و همواری دره با درجه تفکیک بالا را به عنوان پارامتر مهم برای مدل خود معرفی کردند. همچنین بیان داشتند که سطح ژئومورفولوژی نیز یک پارامتر بسیار مهم می‌باشد که این مسئله می‌تواند به دلیل این باشد که سطوح ژئومورفولوژی اخیراً تشکیل شده است و بنابراین، ارتباط خوبی را با فرآیندهای خاک‌سازی در مناطق خشک نشان می‌دهد. خیر و همکاران (۱۶) از مدل رگرسیون درختی برای نقشه برداری خاک نیز استفاده کردند. همچنین تقی‌زاده و همکاران (۳۲) در منطقه اردکان اقدام به تهیه نقشه سه بعدی شوری



شکل ۱- موقعیت منطقه مورد مطالعاتی و نحوه پراکنش مکانی داده‌های خاک

۰/۶۰ میکرومتر، باند ۳: ۰/۶۳-۰/۶۹ میکرومتر، باند ۴: ۰/۷۶-۰/۹۰ میکرومتر، باند ۵: ۱/۵۵-۱/۷۵ میکرومتر، باند ۷: ۲/۰۸-۲/۳۵ میکرومتر) تشکیل شده است.

داده کیفی: علاوه بر این، در منطقه مورد مطالعاتی نقشه ژئومورفولوژی نیز تهیه گردید به این ترتیب که بر روی عکس‌های هوایی ۱/۵۵۰۰۰ منطقه روکش شفاف قرار داده شد تا خطوط سطوح ژئومورفیک روی آن‌ها ترسیم شود. برای تفکیک ژئومورفیک از سیستم استریوسکوپ برای تشخیص تفاوت‌ها استفاده شد. سپس عکس‌های هوایی و روکش مربوطه اسکن شده و وارد محیط سامانه جغرافیایی پی‌سی‌آی ژئوماتیک^۱ شد. در مراحل بعد، عکس‌ها و

پارامترهای زمین‌نما از قبیل شیب، ارتفاع، ارتفاع بالای شبکه زهکشی، مساحت حوزه‌های اصلاح شده، موقعیت میانی شیب، عمق دره، شاخص خیسی، شاخص همواری دره با درجه تفکیک بالا، شاخص بالای پشته با درجه تفکیک بالا و شیب حوزه در محیط سامانه جغرافیایی ساگا^۲ محاسبه و استخراج گردید. روش استخراج تمام پارامترهای مزبور در روش ارائه شده توسط هنگل و همکاران (۱۳) تشریح گردیده است.

همچنین در این مطالعه از تصاویر ماهواره‌ای سنجنده ETM⁺ استفاده گردید. تصاویر این سنجنده مربوط به تابستان ۱۳۹۲ می‌باشد. این تصویر از ۶ باند (باند ۱: ۰/۴۵-۰/۵۲ میکرومتر، باند ۲: ۰/۵۲-

2- PCI Geomatica

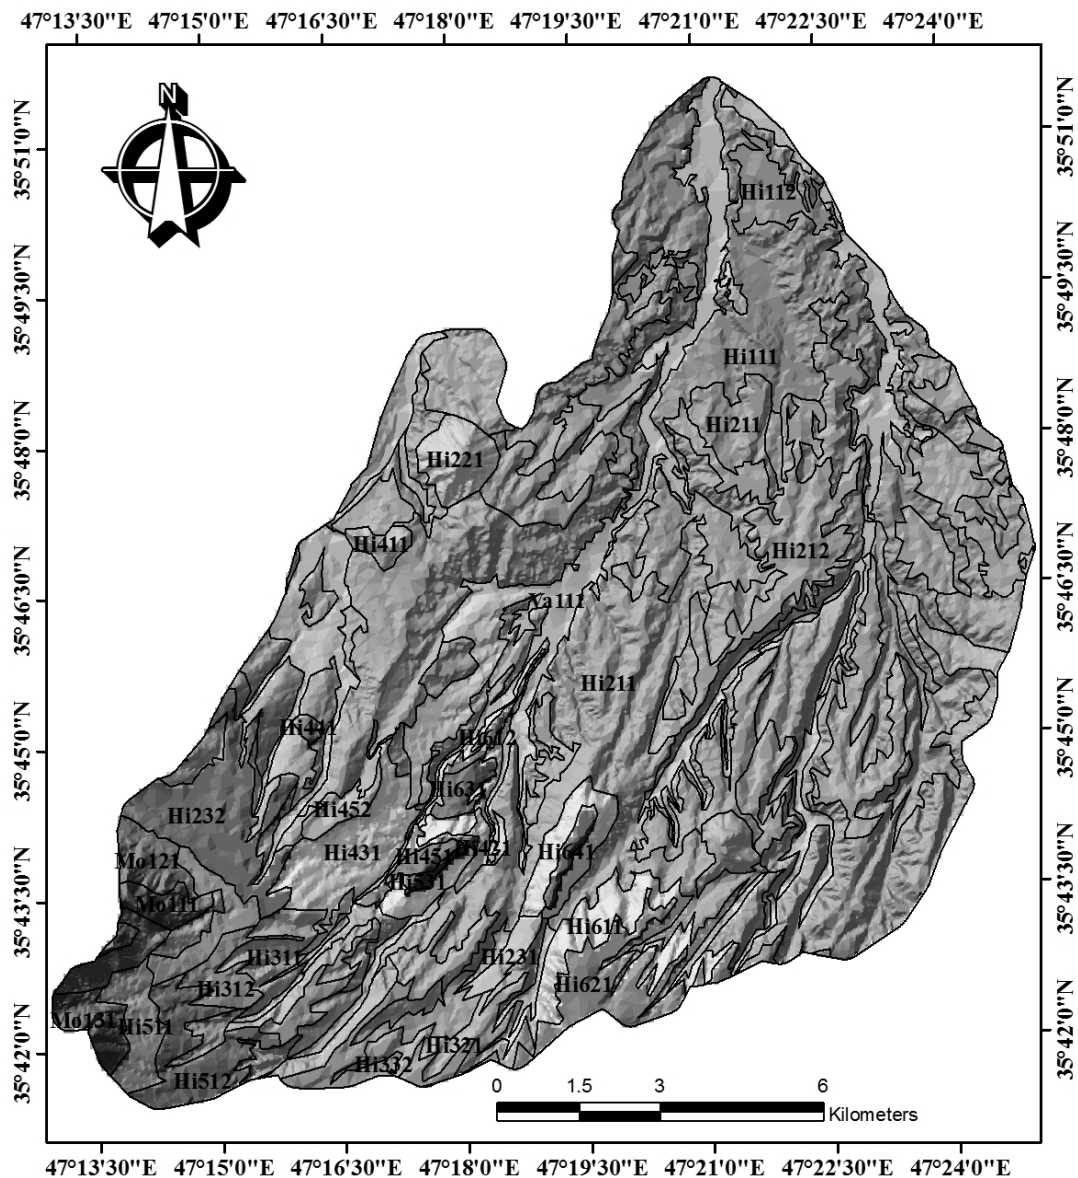
1- SAGA

در افق سطحی A به عنوان متغیر وابسته در نظر گرفته شدند و در فرآیند نقشه برداری رقومی خاک قرار گرفتند. در نهایت با ترکیب نقشه های بدست آمده (رس، شن و سیلت)، تغییرات مکانی کلاس های بافتی خاک مدل سازی شد. همچنین، تمام لایه های اطلاعاتی یا کمکی به فرمت رستری با اندازه سلولی ۳۰ متری تهیه شد. این اطلاعات به عنوان متغیرهای وابسته در مدل اسکورپن شناخته می شوند. تمامی اطلاعات (داده های خاک و متغیرهای محیطی) به فرمت نهایی txt تبدیل شده و برای انجام فرآیند مدل سازی در نرم افزارهای مربوطه آماده شدند.

روکش های وارد شده به سامانه جغرافیایی با استفاده از تصاویر ماهواره ای به روش ارتوفوتوژئورفرنسینگ (۲۹) زمین مرجع شدند. با رقومی کردن مرزهای ترسیم شده بر روکش عکس ها، نقشه ژئومرفولوژی تهیه شد (شکل ۲ و جدول ۱). همچنین از نقشه کاربری اراضی نیز در فرآیند مدل سازی استفاده گردید. در مطالعه حاضر، در کل از ۳۲ لایه اطلاعاتی کمکی بهره گرفته شد.

آماده سازی داده ها برای مدل سازی

برای پهنه بندی کلاس های بافت خاک در سطح منطقه، در این مطالعه ابتدا هر یک از داده های ذرات نسبی خاک (رس، شن و سیلت)



شکل ۲- نقشه واحدهای ژئومورفولوژی

جدول ۱- راهنمای کدهای واحدهای ژئومورفولوژیکی

زمین نما	پستی بلندی - قالب	سنگ شناسی	لندفرم
	تپه‌های رسوبی کم ارتفاع (Hi1) (اختلاف ارتفاع کمتر از ۱۰۰ متر)	کنگلوما و مارن (Hi11)	دامنه شیب (Hi111) قله شیب (Hi112)
	تپه‌های رسوبی با ارتفاع متوسط (Hi2) (اختلاف ارتفاع ۱۰۰-۲۰۰ متر)	کنگلوما و مارن (Hi21) کنگلوما و سنگ آهک رسی (Hi22) تراس‌های قدیمی (Hi23) تراس‌های قدیمی (Hi23)	دامنه شیب (Hi211) قله شیب (Hi212) دامنه شیب (Hi221) دامنه شیب (Hi231) قله شیب (Hi232)
	تپه‌های رسوبی با ارتفاع زیاد (Hi3) (اختلاف ارتفاع ۲۰۰-۳۰۰ متر)	کنگلوما و مارن (Hi31) تراس‌های قدیمی (Hi32)	دامنه شیب (Hi311) قله شیب (Hi312) دامنه شیب (Hi321) قله شیب (Hi322)
تپه (Hi)		تراورتن (Hi41) گابرو (Hi42) سنگ‌های آذرین غنی از آهن (Hi43) گل سنگ (Hi44) سنگ آهک فسیلی (Hi45) سنگ آهک فسیلی (Hi45)	دامنه شیب (Hi411) دامنه شیب (Hi421) دامنه شیب (Hi431) دامنه شیب (Hi441) دامنه شیب (Hi451) قله شیب (Hi452)
	تپه‌های فرسایش با ارتفاع متوسط (Hi4) (اختلاف ارتفاع ۱۰۰-۲۰۰ متر)	سنگ‌های آذرین غنی از آهن (Hi43) گل سنگ (Hi44) سنگ آهک فسیلی (Hi45) سنگ آهک فسیلی (Hi45)	دامنه شیب (Hi431) دامنه شیب (Hi441) دامنه شیب (Hi451) قله شیب (Hi452)
	تپه‌های فرسایش با ارتفاع زیاد (Hi5) (اختلاف ارتفاع ۲۰۰-۳۰۰ متر)	گابرو (Hi51)	دامنه شیب (Hi511) قله شیب (Hi512)
		کنگلوما و مارن (Hi61)	پرتگاه (Hi611) قله (Hi612)
	مسا (Hi6)	سنگ آهک رسی (Hi62) سنگ‌های آذرین غنی از آهن (Hi63) گل سنگ (Hi64)	قله (Hi621) قله (Hi631) قله (Hi641)
دره (Va) کوه (Mo)	تراس‌های آبرفتی (Va1) کوه‌های فرسایشی (Mo1)	آبرفت (Va11) شیل (Mo11) سنگ آهک (Mo12) گابرو (Mo13)	تراس‌های مسطح آبرفتی ریز بافت (Va11) دامنه کوه (Mo111) دامنه کوه (Mo121) دامنه کوه (Mo131)

(۴۴)

استفاده شد.

مدل سازی خاک

شبکه عصبی مصنوعی: در این تحقیق شبکه عصبی مصنوعی پرسپترون چند لایه با یک لایه مخفی که دارای تابع فعال‌سازی سیگموئید در لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی بوده و تعداد نرون‌های آن از دو تا ۱۰ نرون متغیر بوده و بهترین تعداد نرون به صورت سعی و خطا تعیین شد، مورد بررسی قرار گرفت. همچنین به علت کارایی، سادگی و سرعت بالا در این تحقیق الگوریتم آموزش لونیگ مارکواریت استفاده شد. در تحقیق حاضر از نرم‌افزار نروسولوشن^۱ برای ساختن شبکه عصبی مصنوعی و پیش‌بینی ذرات نسبی خاک (رس، شن و سیلت) استفاده شد. در نهایت نقشه‌های رقمی شن، سیلت و رس تهیه شده توسط تکنیک‌های

درخت تصمیم: مدل درختی طبقه‌بندی و رگرسین، یک روش ناپارامتری الگوریتمی است که قادر به پیش‌بینی متغیرهای کمی یا متغیرهای طبقه‌بندی شده بر اساس مجموعه‌ای از متغیرهای پیش-بینی کننده کمی و کیفی است. در این روش، مجموعه‌ای از شرط‌های منطقی (if-then) به صورت یک الگوریتم با ساختار درختی برای طبقه‌بندی یا پیش‌بینی کمی یک متغیر به کار می‌رود. ایجاد درخت تصمیم شامل دو مرحله است. مرحله اول ایجاد و رشد درخت است. این مرحله شامل پیوند و انشعاب می‌باشد. مرحله دوم، مرحله توقف و هرس است. هدف از این مرحله به حداقل رساندن خطای پیش‌بینی است. در تحقیق حاضر از نرم‌افزار کیوبیست برای ساختن رگرسین درختی و در نهایت پیش‌بینی ذرات نسبی خاک (رس، شن و سیلت)

1- Neurosolutions

اصلی شبکه پرسپترون می‌باشد. بجز توپولوژی شبکه عصبی مصنوعی که ذکر شد تعداد اپوک در مرحله یادگیری بسیار حائز اهمیت می‌باشد. تعداد نرون‌ها در لایه‌های ورودی و خروجی ثابت بوده و بسته به تعداد ورودی (متغیرهای کمکی) و خروجی (رس، شن و سیلت) مدل به کار گرفته شده دارد. لایه ورودی شبکه شامل ۳۲ ورودی می‌باشد. لایه خروجی شامل یک نرون می‌باشد. تعداد نرون‌ها و لایه‌های مخفی بستگی به پیچیدگی مسئله مورد نظر دارد. در اینجا یک لایه مخفی برای ایجاد شبکه پرسپترون مورد استفاده قرار گرفت. تعداد نرون‌های لایه مخفی و همچنین تعداد اپوک در فرآیند آموزش و به صورت سعی و خطا به دست آمدند. در این پژوهش، تعداد نرون ۲ تا ۱۰ و تعداد تکرار ۱۰۰ تا ۱۰۰۰ مورد آزمایش قرار گرفت. برای تعیین بهترین ترکیب از شاخص ریشه مربعات خطا و ضریب تبیین استفاده شد. نتایج نشان داد که تعداد نرون ۹، ۷، ۹ و تعداد تکرار ۲۲۰، ۴۸۰، ۳۲۸ دارای بهترین ترکیب برای پیش‌بینی رس، شن و سیلت خاک می‌باشد. در نتیجه، ساختار ۱-۹-۳۲، ۱-۷-۳۲ و ۱-۹-۳۲ برای پیش‌بینی ذرات خاک پیشنهاد می‌شود. نتایج ریشه مربعات خطا برای جزء رس، شن و سیلت ۱۳/۴، ۷/۷ و ۱۱/۳ بدست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰/۷۷، ۰/۸۸ و ۰/۸۱ بدست آمد. بعد از بدست آوردن ساختار بهینه در مرحله آموزش شبکه عصبی مصنوعی که در بالا توضیح داده شد، شبکه آموزش دیده را بر روی داده‌های آزمون آزمایش کرده تا دقت این مدل برای پیش‌بینی رس، شن و سیلت خاک سطحی مشخص شود. نتایج ریشه مربعات خطا برای جزء رس، شن و سیلت ۱۷/۱، ۹/۷ و ۱۴/۹ بدست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰/۴۶، ۰/۵۶ و ۰/۵۳ بدست آمد.

نتایج مدل سازی مکانی به کمک تکنیک رگرسیون درختی:

در روش رگرسیون درختی، مجموعه‌ای از شرط‌های منطقی به صورت یک الگوریتم یا ساختار درختی برای پیش‌بینی ذرات خاک به کار می‌رود. نتایج پیش‌بینی در مرحله آموزش نشان داد که ریشه مربعات خطا برای جزء رس، شن و سیلت ۱۰/۱، ۴/۲ و ۷/۷ بدست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰/۸۷، ۰/۹۴ و ۰/۸۹ بدست آمد. بعد از بدست آوردن قوانین مرتبط که در بالا توضیح داده شد، این مدل درختی را بر روی داده‌های آزمون (۲۰ درصد از داده‌ها) آزمایش کرده تا دقت این مدل برای پیش‌بینی مشخص شود. نتایج ریشه مربعات خطا برای جزء رس، شن و سیلت ۱۲/۵، ۶/۹ و ۹/۸ بدست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰/۸۱، ۰/۷۶ و ۰/۷۹ بدست آمد. به نظر می‌رسد که مدل رگرسیون درختی انتخاب شده به خوبی توانسته است که ذرات رس، شن و سیلت خاک را شبیه‌سازی کند. مقادیر ضریب تبیین دامنه‌ای در حدود ۰/۷۶ الی ۰/۸۱ دارند که در مقایسه با نتایج سایر محققین دامنه‌ای قابل قبول می‌باشد. رایان و همکاران (۳۰)، فلورنسکی و همکاران (۹) و مالون و همکاران (۱۹) نتایج مشابه‌ای از ضریب تبیین را گزارش داده‌اند.

شبکه عصبی مصنوعی و رگرسیون درختی، به صورت پیکسل-پیکسل تلفیق شدند. سپس داده‌های تلفیق شده مربوط به هر پیکسل با مثلث بافت خاک مقایسه شدند و در نهایت کلاس بافتی خاک برای هر پیکسل تعیین گردید.

مقایسه تکنیک‌های نقشه‌برداری رقومی

برای بررسی عملکرد مدل‌های مختلف در برآورد متغیرهای وابسته (رس، شن و سیلت) از ضریب همبستگی و ریشه مربعات خطا استفاده شد. لازم به توضیح است که برای بررسی دقت مدل‌ها برای پیش‌بینی، به دو دسته آموزش (۸۰ درصد از داده‌های نمونه‌برداری شده) و آزمون (۲۰ درصد از داده‌های نمونه‌برداری شده) به طور تصادفی تقسیم شدند.

نتایج و بحث

خلاصه آماری داده‌ها

شرایط ژئومورفولوژیک منطقه مطالعاتی بر روی بسیاری از خصوصیات خاک از جمله عمق خاک، بافت خاک، ماده آلی، زهکشی، مقدار سنگریزه موجود در سطح و نیمرخ خاک، مقدار آهک تجمع یافته در مقاطع خاک بیشترین تأثیر را داشته است. سطوح مختلف ژئومورفیک و سطح آب زیرزمینی توسعه و تکوین خاک‌ها را نیز تحت تأثیر قرار داده است. مجموعه این عوامل باعث تمایز و تفکیک خاک‌ها گردیده است که آن‌ها را می‌توان در سه رده طبقه بندی کرد که عبارتند از: آنتی‌سولز، اینسپتی‌سولز و مالی‌سولز. گروه‌های بزرگ موجود در خاک‌های منطقه مورد مطالعه شامل هاپلوزرپت، اندواکوالز، هاپلوزرولز، کلسیزرولز، زروارتنتز^۵ و کلسیزرپت^۶ می‌باشند. در جدول ۲ خلاصه آماری رس، سیلت و شن آمده است. کلاس‌های مختلف بافت خاک در منطقه مورد مطالعه از لومی شنی تا رسی مشاهده گردید (شکل ۳).

مدل سازی مکانی

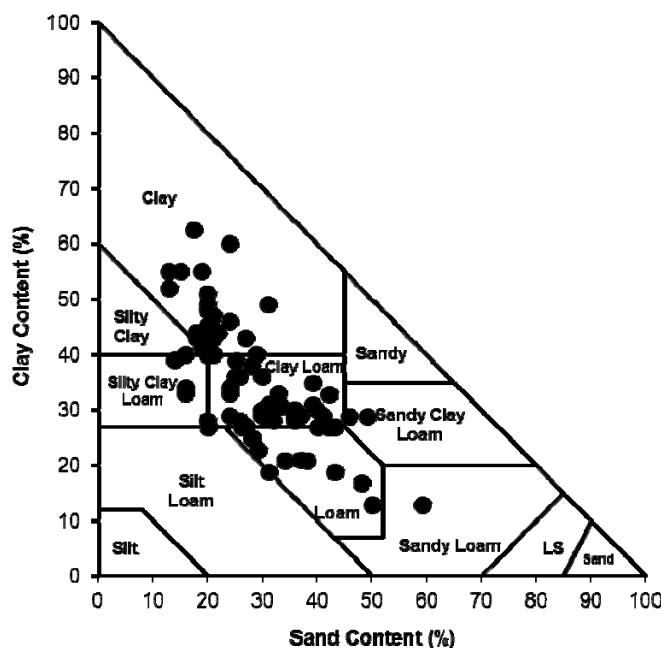
نتایج مدل سازی مکانی به کمک تکنیک شبکه عصبی

مصنوعی: شبکه عصبی مصنوعی: توپولوژی شبکه یک فاکتور اساسی در طراحی شبکه عصبی مصنوعی می‌باشد به علت اینکه این ساختار اثر تأثیرگذار بر روی سرعت یادگیری و صحت طبقه‌بندی نهایی می‌گذارد. تعداد لایه‌های مخفی و تعداد نرون‌ها جزء اجزای

- 1- Haploxerepts
- 2- Endoaquolls
- 3- Haploxerolls
- 4- Calcixerolls
- 5- Xerorthents
- 6- Calcixerepts

جدول ۲- پارامترهای آماری مربوط به خصوصیات شن، رس و سیلت

خصوصیت (درصد)	حداقل	حداکثر	میانگین	انحراف معیار	ضریب تغییرات	چارک اول	چارک دوم	چارک سوم
رس	۱۲/۸۰	۶۲/۵۰	۳۴/۳۴	۱۰/۳۹	۳۰/۲۷	۲۸/۰۰	۳۱/۰۰	۴۱/۰۰
شن	۱۳/۰۰	۵۹/۲۰	۲۹/۱۸	۹/۹۴	۳۴/۰۷	۲۰/۰۰	۲۸/۲۰	۳۶/۰۰
سیلت	۱۶/۰۰	۵۳/۰۰	۳۶/۴۳	۷/۴۴	۲۰/۴۳	۳۱/۰۰	۳۶/۰۰	۴۰/۸۰



شکل ۳- کلاس‌های بافتی خاک در خاک‌های مورد مطالعه

پیش‌بینی ذرات خاک را دارند (شکل ۴). این شکل تاثیر هر متغیر کمکی به صورت درصد بر روی مدل درختی بیشتر نشان می‌دهد.

جدول ۳- نتایج مقایسه انواع مدل‌ها برای پیش‌بینی رس، شن و سیلت بر اساس داده‌های آزمون

مدل	ریشه مربعات خطا			ضریب تبیین		
	رس	شن	سیلت	رس	شن	سیلت
شبه عصبی مصنوعی	۱۷/۱	۹/۷	۱۴/۹	۰/۴۶	۰/۵۶	۰/۵۳
رگرسیون درختی	۱۲/۵	۶/۹	۹/۸	۰/۸۱	۰/۷۶	۰/۷۹

با توجه به این شکل، اینگونه استنباط می‌شود که سطوح ژئومورفولوژی موثرترین متغیر کمکی در هر سه مدل می‌باشد و این شاخص ۴۶، ۵۰ و ۴۹ درصد در مدل‌ها جهت پیش‌بینی رس، شن و سیلت استفاده شده است. سطح ژئومورفولوژی یک پارامتر بسیار مهم می‌باشد که این مسئله می‌تواند به دلیل این باشد که سطوح ژئومورفولوژی اخیراً تشکیل شده است و بنابراین، ارتباط خوبی را با فرآیندهای خاک‌سازی نشان می‌دهد. این نتایج در راستای نتایج


برای بحث نقشه‌برداری رقمی این نتایج قابل قبول می‌باشد، به طوری که ضریب تبیین بالاتر ۰/۷۰ کمتر و ضریب تبیین پایین‌تر از ۰/۵۰ بیشتر معمول می‌باشد (۱۹). محققین مختلف دیگری نیز کارایی درختان تصمیم را در نقشه‌برداری رقمی خاک تایید کرده‌اند (۴، ۲۶، ۵، ۱۲، ۲۲، ۲۳ و ۳۲). با دقت بیشتر به نتایج هر دو معیار ارزیابی متوجه می‌شویم که مدل رگرسیون درختی دارای بهترین عملکرد برای پیش‌بینی رس، شن و سیلت نسبت به شبکه عصبی مصنوعی را دارا می‌باشد (جدول ۳). به‌طورمشابه لوتو و جورت (۱۸) کارایی بالاتر رگرسیون درختی را در مقایسه با شبکه عصبی مصنوعی نشان دادند. همچنین خیر و همکاران (۱۶) نتیجه گرفتند که درخت تصمیم مناطق با ماده آلی بالا را بهتر طبقه‌بندی کرده است. با این وجود مونجان و همکاران (۲۴) اقدام به مقایسه تکنیک شبکه عصبی مصنوعی و درخت تصمیم برای پیش‌بینی واحدهای خاک نموده و نشان دادند که تفاوت معنی‌داری بین دو تکنیک برای پیش‌بینی وجود ندارد.

آنالیز درخت تصمیم نشان داد که بعضی از متغیرهای کمکی مانند سطوح ژئومورفولوژی، شاخص خیزی، شاخص همواری دره با درجه تفکیک بالا، ارتفاع، طول شیب و باند ۳ بالاترین تاثیر را بر روی

گرفته است. و در مقابل کمترین میزان رس خاک در مناطق جنوبی قرار دارد. در نهایت نقشه‌های رقومی شن، سیلت و رس تهیه شده توسط تکنیک رگرسیون درختی، به صورت پیکسل-پیکسل تلفیق شدند. سپس داده‌های تلفیق شده مربوط به هر پیکسل با مثلث بافت خاک مقایسه شدند و در نهایت کلاس بافتی خاک برای هر پیکسل تعیین گردید. به عنوان مثال اگر مقادیر استخراج شده پیکسل مشخصی دارای درصد رس ۳۵، سیلت ۳۰ و شن ۳۵ درصد باشد، با مثلث بافت خاک مقایسه شده و کلاس بافت لومی رسی بدست می‌آید. در شکل ۶ کلاس‌های مختلف بافت خاک نشان داده شده است. همان طور که در این شکل ملاحظه می‌شود میزان درصد رس در لندفرم‌های Hi431، Hi441، Hi641 و Hi631 غالب بوده و دارای کلاس بافت خاک رسی هستند. این لندفرمها مسا (اراضی بالا افتاده‌ای نسبت به اراضی اطراف خود هستند که از لحاظ فرایند تشکیل با این اراضی اطراف متفاوت هستند) و تپه‌های ژئولوژیکی هستند که دارای مواد مادری درجا با سنگ‌های آذرین غنی از آهن بازالت و گل سنگ می‌باشند که منجر به ایجاد چنین خاک‌های ریز بافت شده‌اند. همچنین در لندفرم‌های پست‌تر که شامل تپه‌های رسوبی با مواد مادری انتقالی (کنگولومرا و مارن) و تراس‌های آبرفتی (شامل Hi421، Hi411 و بعضی از Hi211، Hi212، Hi611، Hi612 و Va111) که در قسمت‌های پایین دست منطقه واقع شده‌اند میزان درصد رس زیاد می‌باشد. این لندفرم‌های پست‌تر عمدتاً دارای مواد مادری انتقالی و کلاس بافتی ریز می‌باشند که چون در پایین دست منطقه قرار گرفته‌اند، متاثر از رسوبات لندفرم‌های بالا دست بوده که در اثر فرایندهای هوازدگی و فرسایش آزاد شده و لذا درصد رس در آنها افزایش یافته و بافت این خاک‌ها رسی تا لوم رسی است.

محققین دیگر می‌باشد. به عنوان مثال اسکال و همکاران (۳۱)؛ جعفری و همکاران (۱۴) و تقی‌زاده و همکاران (۳۲) تاکید کردند که سطوح ژئومورفولوژی مهم‌ترین متغیر کمکی برای شناسایی رقومی خاک‌ها می‌باشد. یکی از اجزاء سرزمین، شاخص خیزی یا رطوبتی است که برای تعیین توزیع مکانی نفوذ و جریان آب سطحی بکار می‌رود. در واقع تأثیر توپوگرافی بر مکان و میزان تجمع رطوبت در خاک و یا آب در سطح زمین‌نما را نشان می‌دهد. این پارامتر با متغیرهای وابسته‌ای که با رطوبت ارتباط دارند و تحت تأثیر رطوبت قرار دارند، همبستگی بیشتری نشان می‌دهد. به طوری که در مطالعه حاضر، شاخص خیزی به عنوان یک متغیر پیش‌بینی کننده معنی‌دار در مدل ذرات سیلت وارد شده است. شاخص خیزی مناطق مستعد برای دریافت رسوبات را نشان می‌دهند. با توجه به اینکه حساس‌ترین جزء خاک به فرسایش سیلت می‌باشد، بنابراین انتظار می‌رود که رسوبات عمدتاً حاوی سیلت باشند. در نتیجه همبستگی بالایی بین شاخص خیزی و سیلت وجود دارد. این موضوع می‌تواند مؤید این مطلب باشد که در این منطقه، پستی و بلندی از مهمترین فاکتورهای خاکساز می‌باشد. اجزاء سرزمین در توزیع مکانی خاک و خصوصیاتش بسیار مؤثر هستند، چرا که توزیع مکانی تابش خورشیدی، درجه حرارت، رطوبت و جریان مواد را تحت تأثیر قرار می‌دهند. به طور مشابه مور و همکاران (۲۵) اهمیت شاخص خیزی را در نقشه‌برداری رقومی خاک در منطقه خود تایید کرده‌اند. جعفری و همکاران (۱۴) نیز در منطقه خشک اقدام به پیش‌بینی رقومی خاک کرده‌اند و شاخص خیزی را به عنوان پارامتر مهم برای مدل خود معرفی کردند.

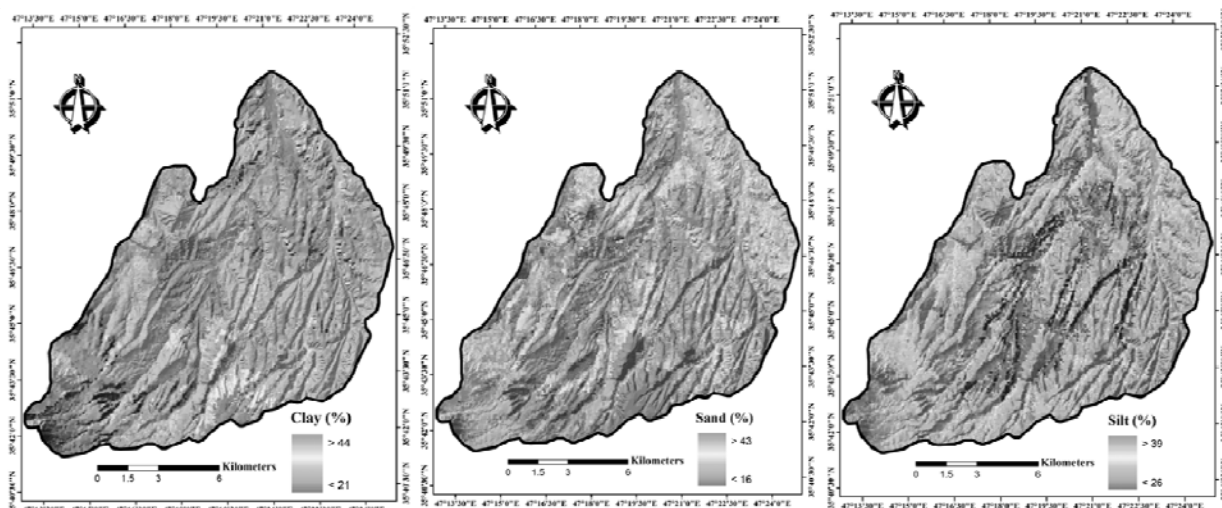
با توجه به قوانینی که از مدل رگرسیون درختی به دست آمد، اقدام به پیش‌بینی مکانی ذرات رس، شن و سیلت در کل منطقه مورد مطالعه گردید (شکل ۵). همان طور که در این اشکال مشخص است به عنوان مثال بیشترین مقدار رس خاک در مناطق مرکزی حوضه قرار




شکل ۴- نتایج اهمیت متغیرهای محیطی در پیش‌بینی ذرات رس، شن و سیلت بر حسب درصد

زمین نما، سیستم زمین نما و واحد زمین نما بود تقسیم بندی صورت گرفته بود. آن‌ها نشان دادند که در واحد زمین نما دشتهای پست دارای خاکهای ریز بافت تری در مقایسه با سایر قسمت‌ها بود. که نشان دهنده ارتباط قوی بین نوع خاک و اشکال زمین نما می باشد.

آنکارو و همکاران (۳۴) در مطالعه ارزیابی منطقه برنتا در ارتباط با آلودگی آرسنیک در ایتالیای شمالی از نقشه خاک در مقیاس ۱/۵۰۰۰۰ به عنوان مبنای کار استفاده نمودند که بر اساس موقعیت‌های داخل هر زمین نما و جنس مواد مادری دارای سه سطح



شکل ۵- نقشه‌های رقومی ذرات رس، شن و سیلت با استفاده از رگسیون درختی



شکل ۶- نقشه رقومی کلاس بافتی خاک

نتیجه گیری

تاثیرگذار برروی دقت مدل می‌باشد. به‌طور کلی نتایج نشان داد که تکنیک‌های پدومتری بخصوص رگرسیون درختی می‌توانند فرآیند نقشه‌برداری خاک‌ها را درگستره‌ای وسیع و متشکل از هر گونه عوارض طبیعی به یک‌باره انجام داده، روش سنتی را ارتقاء بخشیده، سرعت عمل و کارآمدی نقشه‌ها را درانتقال داده‌ها و اطلاعات افزایش داده و قابلیت استفاده آن‌ها را برای قشر وسیعی از شاخه‌های علمی امکان‌پذیر نماید. لذا پیشنهاد می‌گردد که جهت تهیه نقشه رقومی خاک از مدل‌های درختی در مطالعات آینده استفاده شود.

نتایج مقایسه مدل‌های شبکه عصبی مصنوعی و رگرسیون درختی برای پیش‌بینی بافت خاک نشان داد که مدل رگرسیون درختی دارای کارایی بالاتری در پیش‌بینی هر یک از ذرات رس، شن و سیلت می‌باشد. بنابراین از این مدل جهت پهنه‌بندی بافت خاک استفاده گردید. نتایج همچنین نشان داد که مهم‌ترین متغیر کمکی سطوح ژئومورفولوژی، شاخص خیزی می‌باشند. همچنین وجود ارتباط قوی بین داده خاک و پارامترهای محیطی نیز یکی از فاکتورهای

منابع

- Bell J.C., Cunningham R.L., and Havens M.W. 1992. Calibration and validation of a soil- landscape model for predicting soil drainage class. *SSSJA*, 56: 1860-1866.
- Bie S.W., and Beckett P.H.T. 1971. Quality control in soil survey. II: The cost of soil survey. *J. Soil Sci*, 22: 453-465.
- Breiman L., Friedman J.H., Olshen R.A., and Stone C.J. 1984. Classification and regression. Tress. Wadsworth, Belmont, CA.
- Bui E.N., Loughhead A., and Corner R. 1999. Extracting soil-landscape rules from soil previous surveys. *Aus. J. Soil Res*, 37: 495-508.
- Bui E.N., and Moran C.J. 2001. Disaggregation of polygons of surficial geology and soil maps using spatial modelling and legacy data. *Geoderma*. 103, 79- 94.
- Cassel D.K., Wendroth O., and Nielsen D.R., 2000. Assessing spatial variability in an agricultural experiment station field, opportunities arising from spatial dependence. *Agron. J*, 92: 706-714.
- Cerri C.E.P., Coleman K., Jenkinson D.S., Bernoux M., Victoria R., and Cerri C.C. 2003. Modeling soil carbon from forest and pasture ecosystems of Amazon, Brazil. *SSSJA*, 67: 1879-1887.
- Fernandez-Glvez J., Simmonds L.P., and Barahona E. 2005. Estimating detailed soil water profile records from point measurements. *E. J. Soil Sci*, 57: 23-45.
- Florinsky I.V., Eilers R.G., Manning G.R., and Fuller L.G. 2002. Prediction of soil properties by digital terrain modeling. *Env. Model. Soft*, 17: 295- 311.
- Gee G.W., and Bauder J.W. 1986. Particle size analysis. p. 383-411. In: A. Klute. (ed). *Methods of Soil Analysis*. Part 1. A. Soc. Ag. Madison, WI.
- Hassink J. 1992. Effects of soil texture and structure on carbon and nitrogen mineralization in grass-land soils. *Biol. Fertil. Soils*, 14: 126-134.
- Henderson B.L., Bui E.N., Moran C.J., and Simon D.A.P. 2005. Australia-wide predictions of soil properties using decision trees. *Geoderma*. 124, 383-398.
- Hengl T., Rossiter D.G., and Stein A. 2003. Soil sampling strategies for spatial prediction by correlation with auxiliary maps. *Geoderma*, 120: 75-93.
- Jafari A., Finke P.A., de Wauw J.V., Ayoubi S., and Khademi H. 2012. Spatial prediction of USDA- great soil groups in the arid Zard region, Iran: comparing logistic regression approaches to predict diagnostic horizons and soil types. *E. J. Soil Sci*, 63: 284-298.
- Jain M.K., Kothiyari U.C., and Raju K.G.R. 2005. GIS based distributed model for soil erosion and rate of sediment outflow from Catchments. *J. Hydraulic Eng*, 13:755-769.
- Kheir B., Greve M.H., Bocher P.K., Greve M.B., Larsen R., and McCloy K. 2010. Predictive mapping of soil organic carbon in wet cultivated lands using classification-tree based models: The case study of Denmark. *J. Env. Man*, 91: 1150-1160.
- Kheir R.B., Greve M.H., Abdallah C., and Dalgaard T. 2010. Spatial soil zinc content distribution from terrain parameters: A GIS-based decision-tree model in Lebanon. *Environ. Poll*, 158: 520-528.
- Luoto M., and Hjort J. 2005. Evaluation of current statistical approaches for predictive geomorphological mapping. *Geomorph*, 67, 299-315.
- Malone B.P., McBratney A.B., Minasny B., and Laslett G.M. 2009. Mapping continuous depth functions of soil carbon storage and available water capacity. *Geoderma*, 154: 138- 152.
- McBratney A.B., Odeh I.O.A., Bishop T.F.A., Dunbar M.S., and Shatar T.M. 2000. An overview of pedometric techniques for use in soil survey. *Geoderma*, 97: 293-327.
- McBratney A.B., Santos M.L.M., and Minasny B. 2003. On digital soil mapping. *Geoderma*, 117: 3-52.

- 22- Mendonça-Santos M.L., McBratney A.B., and Minasny B. 2006. Soil prediction with spatially decomposed environmental factors. *Digital Soil Mapping — An Introductory Perspective*, 31: 269–278.
- 23- Minasny B., and McBratney A.B. 2007. Incorporating taxonomic distance into spatial prediction and digital mapping of soil classes. *Geoderma*, 142: 285–293.
- 24- Moonjun R., Farshad A., Shrestha D.P., and Vaiphasa C. 2010. Artificial Neural Network and Decision Tree in Predictive Soil Mapping of Hoi NumRin Sub-Watershed, Thailand. *Digital Soil Mapping. Pro. Soil Sci*, 2, pp 151-164.
- 25- Moore I.D., Grayson R.B., and Ladson A.R. 1991. Digital terrain modeling: review of hydrological, geomorphological and biological applications. *Hyd. Proc*, 5: 3-30.
- 26- Moran C.J., and Bui E.N. 2002. Spatial data mining for enhanced soil map modelling. *I. J. Geog. Info. Sci*, 16: 533-549.
- 27- Oberthur T., Dobermann A., and Neue H.U. 1996. How good is a reconnaissance soil map for agronomic purposes? *Soil Use Manage*, 12: 33–43.
- 28- Quinlan J.R. 2001. *Cubist: An Informal Tutorial*. Available at <http://www.rulequest.com>.
- 29- Rossiter D.G., and Hengl T. 2001. Technical note: Creating geometrically-correct photo- interpretation, photo-mosaics, and base maps for a projects GIS. Available at <http://www.itc.nl/rossiter>.
- 30- Ryan P.J., McKenzie N.J., O'Connell D., Loughhead A.N., Leppert P.M., Jacquier D., and Ashton L. 2000. Integrating forest soils information across scales: spatial prediction of soil properties under Australian forests. *For. Eco. Manag*, 138:139–157.
- 31- Scull P., Franklin J., and Chadwick O.A. 2005. The application of classification of tree analysis to soil type prediction in a desert landscape. *Eco. Model*, 181: 1-15.
- 32- Taghizadeh-Mehrjardi R., Minasny B., Sarmadian F., and Malone, P.B. 2013. Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma*, 213: 15-28.
- 33- Thattai D., and Islam S. 2000. Spatial analysis of remotely sensed soil moisture data. *J. Hydrol. Eng*, 5: 386–392.
- 34- Ungaro F., Ragazzi F., Cappellin R., and Giandon P. 2008. Arsenic concentration in the soils of the Brenta Plain (Northern Italy): Mapping the probability of exceeding contamination thresholds. *J. Geo. Explo*, 96: 117-131.
- 35- Voltz M., and Webster R. 1990. A comparison of kriging, cubic-splines and classification for predicting soil properties from sample information. *J. Soil Sci*, 41: 473–490.
- 36- Voltz M., Lagacherie P., and Louchart X. 1997. Predicting soil properties over a region using sample information from a mapped reference area. *Eur. J. Soil Sci*, 48: 19–30.
- 37- Webster R. 1968. Fundamental objection to the 7th approximation. *J. Soil Sci*, 19: 354–365.
- 38- Wischmeier W.H., and Smith D.D. 1978. *Predicting Rainfall Erosion Losses, a Guide to Conservation Planning, Agriculture Handbook No. 537*. U.S. Department of Agriculture, Washington, DC.
- 39- Zhao Z., Chow T.L., Rees H.W., Yang Q., Xing Z., and Meng F. 2009. Predict soil texture distributions using an artificial neural network model. *Com. Elec. Agr*, 65: 36-48.
- 40- Zinck J.A. 1989. *Physiography and soils*. Lecture notes for K6 course. Soils Division, pp. 156, ITC, Enschede, The Netherlands.



Digital Mapping of Soil Texture Using Regression Tree and Artificial Neural Network in Bijar, Kurdistan

K. Nabiollahi^{1*} - A. Haidari² - R. Taghizadeh - Mehrjerdi³

Received: 26-11-2013

Accepted: 26-7-2014

Abstract

Soil texture is an important soil physical property that governs most physical, chemical, biological, and hydrological processes in soils. Detailed information on soil texture variability is crucial for proper crop and land management and environmental studies. Therefore, at present research, 103 soil profiles were dogged and then sampled in order to prepare digital map of soil texture in Bijar, Kurdistan. Auxiliary data used in this study to represent predictive soil forming factors were terrain attributes, Landsat 7 ETM+ data and a geomorphologic surfaces map. To make a relationship between the soil data set (i.e. Clay, sand and silt) and auxiliary data, regression tree (RT) and artificial neural network (ANN) were applied. Results showed that the RT had the higher accuracy than ANN for spatial prediction of three parameters. For the clay fraction, determination of coefficient (R²) and root mean square root (RMSE) calculated for two models were 0.46, 0.81 and 17.10, 12.50, based on validation data set (20%). Our results showed some auxiliary variables had more influence on predictive soil class model which included: geomorphology map, wetness index, multi-resolution index of valley bottom flatness, elevation, slope length, and B3. In general, results showed that decision tree models had higher accuracy than ANN models and also their results are more convenient for interpretation. Therefore, it is suggested using of decision tree models for spatial prediction of soil properties in future studies.

Keywords: Auxiliary data, Spatial variation, Digital soil mapping

1- Assistant Professor, Department of Soil Science, Faculty of Agriculture, University of Kurdistan, Sanandaj
(*- Corresponding Author Email: nabiollahy_k@Yahoo.com)

2- Associate Professor, Department of Soil Science, College of Agriculture and Natural Resources, University of Tehran, Tehran

3- Assistant Professor, Faculty of Agriculture and Natural Resources, University of Ardakan