

پنهانه‌بندی رقومی خاک با استفاده از مؤلفه‌های ژئومورفومتری در دشت یزد-اردکان

۱- روح الله تقی‌زاده مهرجردی، استادیار خاکشناسی دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان
Rh_taghizade@yahoo.com

دریافت: ۱۳۹۳/۰۲/۱۸

پذیرش: ۱۳۹۳/۰۶/۲۲

چکیده

نقشه‌های قدیمی خاک اغلب دارای واحدهای چندضلعی است که با فرض یکنواختی خصوصیات خاک جدا شده‌اند. با توجه به مشکلات این نوع نقشه‌ها، در سال‌های اخیر پژوهشگران برای به تصویر کشیدن تغییرات مکانی خاک‌ها با هزینه کمتر و در مدت زمان کوتاه‌تر، از روش‌های نقشه‌برداری رقومی خاک با تأکید بر منابع داده‌های قابل دسترس بهره گرفته‌اند. در این پژوهش، برای تهیه نقشه رقومی کلاس‌های خاک در دشت یزد-اردکان، از پنج روش نقشه‌برداری رقومی خاک استفاده شد. در ابتدا، کلاس طبقه‌بندی خاک آمریکا (گروه بزرگ) برای ۴۲۲ پروفیل در سطح استان یزد مشخص و کدگذاری شدند. سپس، مؤلفه‌های ژئومورفومتری به داده‌های خاک ارتباط داده شد. نتایج نشان داد که برای پیش‌بینی گروه‌های بزرگ خاک، متغیرهای ارتفاع، شاخص همواری دره با درجه تفکیک بالا و شاخص خیسی مهم هستند. نتایج مدل‌سازی نشان داد که مدل‌های درخت تصمیم، الگوریتم ژنتیک، رگرسیون لجستیک چندجمله‌ای، شبکه عصبی مصنوعی و آنالیز تشخیصی به ترتیب با دقت کلی ۶۰/۵٪، ۴۹٪، ۴۰٪، ۳۷٪ و ۳۱٪ توانسته‌اند پیش‌بینی را انجام دهند. همچنین، نتایج، کارآیی بالای مدل درخت تصمیم را نسبت به سایر مدل‌ها تایید می‌کند. این مدل توانسته است تا دقت پیش‌بینی را نسبت به روش آنالیز تشخیصی (ضعیفترین مدل) ۴۸٪ افزایش دهد. بنابراین، پیشنهاد می‌شود در مطالعات آینده جهت تهیه و به روز رسانی نقشه خاک از مدل‌های درختی و مؤلفه‌های ژئومورفومتری استفاده شود.

واژگان کلیدی : درخت تصمیم؛ شبکه عصبی مصنوعی؛ الگوریتم ژنتیک؛ رگرسیون لجستیک؛ آنالیز تشخیصی

مقدمه

راحتی می‌توان از مدل رقومی ارتفاع^۱ بدست آورد. در حقیقت استخراج اطلاعات از مدل‌های رقومی ارتفاعی بر پایه معادلات ریاضی و اشکال هندسی را ژئومورفومتری می‌نامند. ژئومورفومتری دانش کمی کردن عوارض سطح زمین بوده [۲۵ و ۲۶] و یک رویکرد نوین در زمینه تحلیل‌های کارتوگرافیکی عوارض سطح زمین برپایه محاسبات کامپیوتری و تغییرات ارتفاعی عوارض سطح زمین است. این دانش، به نوعی یک دانش تلفیقی در زمینه علوم مختلفی مانند ریاضیات، علوم زمین و کامپیوتر است [۳۳] و در سال‌های اخیر در نقشه‌برداری رقومی خاک کاربرد فراوانی داشته است [۲۲].

در نقشه‌برداری رقومی، پیش‌بینی خصوصیات و طبقات خاک براساس تشکیل رابطه آماری بین ویژگی‌های واقعی خاک و نمایندگان عوامل خاک‌سازی (مانند اقلیم، پستی و بلندی، مواد مادری، خصوصیات خاک، موجودات زنده، زمان و مکان) انجام می‌شود. در سال‌های اخیر پژوهشگران از عامل‌های هفتگانه مذکور در سطح وسیعی استفاده کرده‌اند: به عنوان مثال، از خصوصیات خاک (۴/۸۴)، اقلیم (۷/۱۰)، موجودات زنده (۷/۳۸)، مواد مادری (۷/۱۰)، و پستی و بلندی (۳/۲۹). در این راستا برخی پژوهشگران تنها از تعدادی عوامل خاک‌سازی بهره گرفته‌اند [۳۴ و ۴۶]؛ در حالی که برخی دیگر مجموعه بیشتری از عوامل را وارد مدل مکانی خود نمودند [۱۱]. از بین عوامل خاک‌سازی، عامل پستی و بلندی را به

چندجمله‌ای استفاده نمود [۵]. از رگرسیون لجستیک جهت نقشه‌برداری رقومی خاک در برزیل نیز استفاده شده است [۱۰]. همچنین چندین متغیر اراضی مشتق شده از مدل رقومی ارتفاع شامل شیب، انحنای شیب، جهت جریان، تجمع جریان، طول شیب، قدرت جریان رودخانه، شاخص خیسی و فاصله تا رودخانه به عنوان ورودی مدل در نظر گرفته شد. مدل مذکور توانست با دقت ۶۱٪ حضور کلاس‌های خاک را به درستی پیش‌بینی کند. جهت پیش‌بینی واحدهای خاک در کشور چک از شبکه عصبی- مصنوعی استفاده گردید و نتایج نشان داد که اگر ورودی‌های مدل از ۲۰ تا ۳۰ متغیر افزایش یابد، هیچ گونه تغییری در کارائی مدل پیش نمی‌آید [۲۷]. پژوهشگران استرالیایی جهت پیش‌بینی ظرفیت رطوبتی خاک و ماده آلی خاک از شبکه عصبی مصنوعی بهره گرفتند [۲۱]. در کشور ازبکستان نیز کارایی شبکه عصبی مصنوعی جهت تهیه نقشه شوری با استفاده از انواع داده‌های کمکی از جمله مشتقات مدل رقومی ارتفاع، تایید گردید [۲].

هدف از این پژوهش، تهیه نقشه رقومی کلاس‌های تاکسونومیک خاک تا سطح گروه بزرگ خاک در دشت یزد-اردکان است. جهت رسیدن به هدف، در ابتدا با استفاده از فنون‌های مختلف داده کاوی (شبکه عصبی مصنوعی، درخت تصمیم، الگوریتم ژنتیک، آنالیز تشخیصی و رگرسیون لجستیک)، ارتباط بین مؤلفه‌های ژئومورفومتری و داده‌های خاک تعیین می‌شود و در آخر پس از انتخاب مدل مناسب، نقشه رقومی در کل منطقه تهیه می‌گردد.

مواد و روش‌ها

تشریح محدوده مطالعاتی

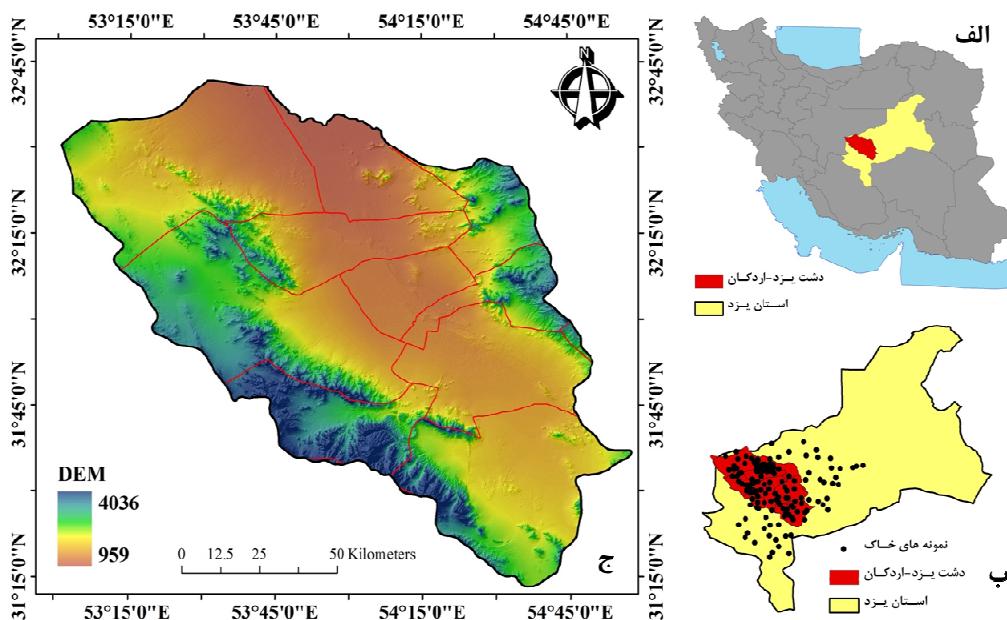
حوزه آبخیز دشت یزد- اردکان با مساحتی حدود ۱۵۹۵۰۰ هکتار، در محدوده عرض شمالی ۳۱° تا ۴۸° و طول شرقی ۵۷^{\prime} تا ۵۲^{\prime} در فلات مرکزی ایران واقع شده است (شکل ۱). این حوزه بوسیله رشته کوه‌های شیرکوه در جنوب، کوه آهنگران در غرب، کوه‌های هفت‌آدمین در شرق و کوه چک در شمال محصور و با شیب عمومی جنوب‌شرق- شمال‌غربی به چاله

در مطالعات زیادی از عامل پستی و بلندی برای پیش‌بینی خصوصیات خاک به تهابی [۴۵] یا به همراه سایر عوامل [۱۵] و [۲۰] استفاده شده است. جهت پهنه‌بندی رقومی شوری خاک مشتقات اولیه و ثانویه مدل رقومی ارتفاع استفاده شده است [۳۶]. همچنین مشتقات مدل رقومی ارتفاع، به عبارت دیگر، مؤلفه‌های ژئومورفومتری مانند شاخص خیسی، شیب، انحنا و شاخص همواری دره با درجه تفکیک بالا از جمله متغیرهای پیش‌بینی کننده مؤثر در فنون نقشه‌برداری رقومی خاک معرفی شده‌اند [۱۷]. هرچند این قانون کلی برای عامل پستی و بلندی نیست و مشخص شده که عامل پستی و بلندی می‌تواند حتی کمترین اثر را در مدل پیش‌بینی کننده داشته باشد [۳۱]. این امر، بهویژه در مناطق صاف و دشت اتفاق می‌افتد و در چنین مناطقی انتظار می‌رود که داده‌های کمکی (مشتقات سرزمین) رابطه چندان معنی‌داری با داده‌های شوری نداشته باشد [۲ و ۳].

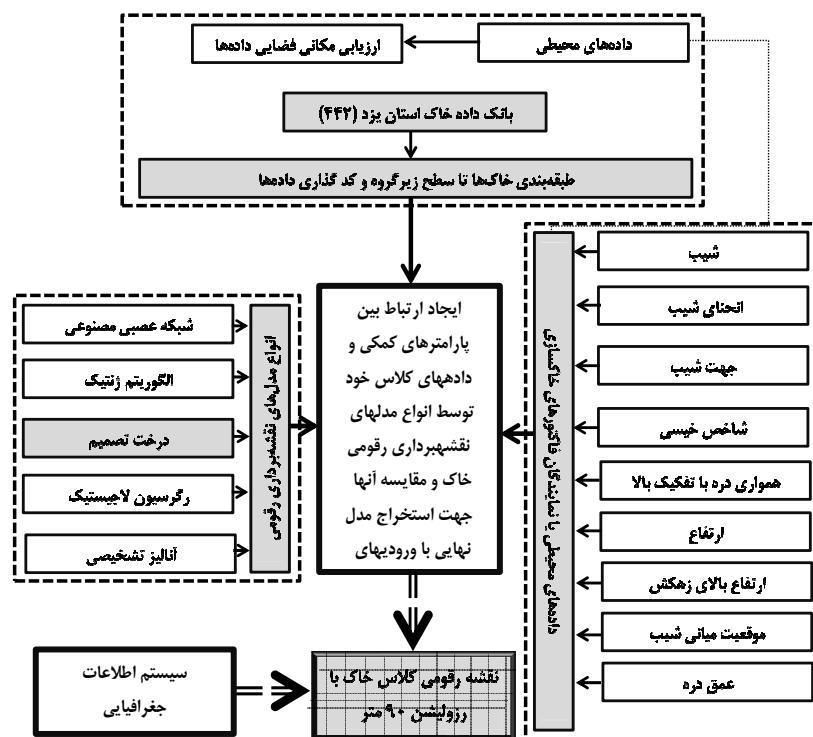
در روش شناسایی رقومی خاک، مؤلفه‌های ژئومورفومتری (عامل مستقل) با استفاده از یک مدل آماری به داده‌های خاک (عامل وابسته) ارتباط داده می‌شوند. مدل‌های آماری مختلفی، در سال‌های اخیر، توسعه پیدا کرده‌اند. پژوهشگران استرالیایی از مدل‌های درختی جهت پیش‌بینی کلاس‌های خاک استفاده نموده‌اند [۱۳ و ۱۷]. در جنوب شرق نزدیک از رگرسیون لجستیک چندجمله‌ای جهت پهنه‌بندی کلاس خاک استفاده شد [۹]. نتایج نشان داد از بین متغیرهای سرزمین، ارتفاع، شیب، جهت و مدت زمان تابش خورشیدی، در پراکنش مکانی کلاس‌های خاک نقش تعیین‌کننده‌ای دارند. موقفيت رگرسیون لجستیک چندجمله‌ای در پیش‌بینی گروه‌های خاک WRB به شدت به همبستگی کلاس‌های خاک با پیش‌بینی کننده‌ها بستگی دارد [۱۵]. به طور مشابه، در جنوب فرانسه نیز از رگرسیون لجستیک برای تعیین حضور و نبود افق لومی رسی غیرآهکی با استفاده از اجزاء سرزمین استفاده شده است [۱۸]. همچنین جهت تعیین روابط بین سری‌های خاک یک منطقه و تعدادی از متغیرهای همان منطقه (از جمله شیب، جهت شیب و ارتفاع نسبی) می‌توان از رگرسیون لاجیستیک

گام تهیه داده‌های خاک؛ تهیه است. همانطور که ملاحظه می‌شود می‌توان مراحل داده‌های محیطی؛ و در آخر مدل‌سازی، یعنی ارتباط دادن داده‌های محیطی و خاک تقسیم نمود. پس از تعیین مدل و ورودی‌های مناسب، اقدام به تهیه نقشه کلاس خاک تا سطح گروه بزرگ گردید.

کویر اردکان (حوزه آبریز سیاه‌کوه) تخلیه می‌شود. اقلیم منطقه به روش دومارتن اصلاح شده فراخشک سرد است. میانگین بارندگی منطقه حدود ۶۲/۱ میلیمتر و تبخیر و تعرق پتانسیل ۳۴۸۳ میلیمتر است. روند انجام این تحقیق به طور خلاصه در شکل ۲ نشان داده شده است. همان‌طور که ملاحظه می‌شود می‌توان مراحل تحقیق را به سه



شکل ۱. موقعیت منطقه مورد مطالعه در (الف) کشور، (ب) استان یزد و (ج) دشت برد-اردکان استان یزد (بر روی نقشه مدل رقومی ارتفاع مرزهای سیاسی شهرستان‌های واقع در دشت برد-اردکان مشخص شده است)



شکل ۲. روند انجام تحقیق جهت تهیه نقشه رقومی کلاس خاک

مشتقات لازم برای محاسبه بعضی از شاخص‌های پستی و بلندی به شرح ذیل است [۲۵].

$$G = \frac{df}{dx} = \frac{Z3 + Z6 + Z9 - Z1 - Z4 - Z7}{6.p} \quad (1)$$

$$H = \frac{df}{dy} = \frac{Z1 + Z2 + Z3 - Z4 - Z8 - Z9}{6.p} \quad (2)$$

$$D = \frac{d^2f}{dx^2} = \frac{Z1 + Z3 + Z4 + Z6 + Z7 + Z9 - 2(Z2 + Z5 + Z8)}{3.p^2} \quad (3)$$

$$E = \frac{d^2f}{dx^2} = \frac{Z1 + Z2 + Z3 + Z7 + Z8 + Z9 - 2(Z4 + Z5 + Z6)}{3.p^2} \quad (4)$$

$$F = \frac{d^2f}{dx^2 dy} = \frac{Z3 + Z7 + Z1 + Z9}{4.p^2} \quad (5)$$

$$Z5^+ = s. \frac{Z1 + Z2 + Z3 + Z4 + Z6 + Z7 + Z8 + Z9}{9} \quad (6)$$

پارامترهای Z1 الی Z9 مقادیر ارتفاع در شبکه سلولی ۳×۳ می‌باشد (شکل ۳). با استفاده از این مقادیر و روابط یک الی شش، شاخص‌های G الی Z5* محاسبه می‌شود. سپس پارامترهای ژئومورفومتری از قبیل شیب (SLOPE)، جهت شیب (ASPECT) و میانگین انحنای سطح زمین (MEANC) بدست می‌آید [۲۵ و ۴۳]:

$$SLOPE = \sqrt{H^2 + G^2} \quad (7)$$

$$MEANC = -\left(\frac{(1+H^2).D - 2.G.H.F. + (1+G^2).E}{2.(1+G^2+H^2)^{1.5}} \right) \quad (8)$$

$$ASPECT = \arctan \left(\frac{H}{G} \right) \quad (9)$$

شاخص رطوبتی (WETIN) به عنوان شاخصی از پراکنش مکانی رطوبت خاک در طول زمین نما است که به وسیله رابطه زیر محاسبه می‌شود:

$$WETIN = In \left(\frac{A_s}{\tan \beta} \right) \quad (10)$$

در آن: معادله مقدار As سطح ویژه حوزه و β درجه شیب است [۴۴].

با توجه به قابلیت نقشه‌برداری رقومی در استفاده از داده‌های قدیمی [۳۷، ۳۸، ۳۹ و ۴۰]، در مطالعه حاضر نیز از اطلاعات ۴۴۲ پروفیل موجود در سطح استان یزد بهره گرفته شد. خاک‌های منطقه بسیار شور، دارای گچ و آهک زیاد و ماده‌آلی بسیار کم است، که همگی از خصوصیات خاک‌های مناطق خشک است. کلاس بافتی خاک بسیار متغیر بوده، به‌طوری‌که خاک‌هایی که در نواحی مرتفع‌تر هستند دارای بافت درشت‌تر و هر چه به سمت انتهای حوزه و نواحی با ارتفاع کمتر پیش می‌رویم، بافت خاک سنگین‌تر می‌شود. خاک‌های استان یزد بر اساس سیستم طبقه‌بندی خاک آمریکا در هشت گروه بزرگ قرار می‌گیرند: توری‌فلوئنتز (۵ مشاهده)، هاپلوسالیدز (۹۵ مشاهده)، هاپلوژیپسیدز (۱۰۵ مشاهده)، اکویی‌سالیدز (۷ مشاهده)، توری‌ارتنتز (۱۲۰ مشاهده)، هاپلوکلسیدز (۴۰ مشاهده)، پتروژیپسیدز (۲۲ مشاهده) و کلسی‌ژیپسیدز (۲۵ مشاهده).

پارامترهای ژئومورفومتری

در این تحقیق، از مدل رقومی با قدرت تفکیک مکانی ۹۰ متر بر اساس پروژه جهانی نقشه خاک استفاده شد [۲۲]. بعد از آماده کردن مدل ارتفاعی رقومی، از آن برای استخراج کردن اطلاعات کمکی یا تصاویر تخمین‌زننده متغیرهای ژنتیکی خاک استفاده شد. متغیرهای زمین‌نما از قبیل شیب، ارتفاع، ارتفاع بالای شبکه زهکشی، مساحت حوزه‌های اصلاح شده، میانگین انحنای سطح زمین، موقعیت میانی شیب، عمق دره، شاخص خیسی، شاخص صافی قسمت میانی دره با درجه تفکیک بالا، شاخص بالای پشته با درجه تفکیک بالا و شیب حوزه در محیط سامانه جغرافیایی ساگا محاسبه و استخراج شد [۱۴]. مبنای محاسبه شاخص‌های فوق، ایجاد یک شبکه سلولی ۳×۳ بر روی تصویر است (شکل ۳).

Z ₁	Z ₂	Z ₃
Z ₄	Z ₅	Z ₆
Z ₇	Z ₈	Z ₉

شکل ۳. ساختار شبکه DEM، با یک آرایه ۳×۳ متحرك

ارزیابی خطأ و برآورد دقت طبقه بندي، به طور معمول، بر اساس متغيرهای آماری است که از ماترييس ابهام استخراج می شوند. ماترييس ابهام نتيجه مقاييسه پيكسل به پيكسل، پيكسل های معلوم (در واقعیت زمینی) با پيكسل های منتظر در نتایج طبقه بندي است. اعداد روی قطر اصلی ماترييس، تعداد پيكسل هایي را مشخص می کنند که درست هستند. دقت کلی، ميانگيني از دقت طبقه بندي است که نسبت پيكسل های صحيح طبقه بندي شده به جمع پيكسل های معلوم را نشان می دهد (رابطه ۱۱):

$$OA = \sum_{i=1}^C E_{ii} / N \quad (11)$$

که در آن:

E_{ii} تعداد کلاس ها، N تعداد کل پيكسل های معلوم، C اعضای اصلی ماترييس خطأ و OA دقت کلی طبقه بندي است. دقت کلی يكی از ساده ترین شاخص های دقت است که نياز به عمليات پيچيده برای محاسبه ندارد. دقت کلی يك برآورد کلی از دقت طبقه بندي و يا به صورت دقیق تر، ميانگيني از دقت طبقه بندي است. هر چه مقدار عددی دقت کلی بيشتر باشد، نشان دهنده اين است که مدل پيش بيني کننده تعداد پيكسل های بيشتری را به صورت صحيح طبقه بندي كرده و از دقت بالاتر برخوردار می باشد. لازم به توضیح است که داده ها به دو دسته آموزش (۸۰ درصد از داده های نمونه برداری شده) و آزمون (۲۰ درصد از داده های نمونه برداری شده) به طور تصادفي تقسیم شدند.

نتایج و بحث

طراحی الگوی نمونه برداری

در نقشه برداری رقومی خاک، نمونه های خاک برای برقراری ارتباط کمی بین اجزاء خاک و متغيرهای محیطی استفاده می شوند [۸]. از آنجایی که روابط براساس مشاهدات خاک است، کیفیت نقشه خاک تولیدی به کمیت و کیفیت مشاهدات خاک بستگی دارد. توزیع هیستوگرامی روش کارآمد برای ارزیابی توزیع فضایی نمونه ها در جامعه هدف است [۲۳]. همچنان، شباهت توزیع فراوانی روش مربع لاتین به متغيرهای جامعه، به عنوان دلیل برتری نسبت به سایر روش های نمونه برداری

مدل مکانی

در اين تحقیق از پنج روش داده کاوی (شامل شبکه عصبی مصنوعی، الگوریتم ژنتیک، درخت تصمیم، آنالیز تشخیصی و رگرسیون لاجیستیک) بهره گرفته شده است. روش اول یا الگوریتم ژنتیک يك فن برنامه نویسي است [۱]. در اين روش ابتدا برای مجموعه ای از داده ها که جمعیت نامیده می شود، متغيرهای هدف به صورت اتفاقی تولید و افراد در برابر اين مجموعه از داده ها، مورد آزمایش قرار گرفته و مناسب ترین نسل جدید را شکل می دهند. اين فرآيند برای نسل های بعدی تا رسیدن به معیار همگرایی تکرار می شود. در اين تحقیق، تقریبا مشابه پیش فرض برنامه، تعداد جمعیت اولیه ۵۰، حداکثر نسل ۱۰۰ و تعداد گردش برابر با ۱۰۰ دور، در نظر گرفته شد.

در روش دوم (درخت تصمیم)، مجموعه ای از شرط های منطقی به صورت يك الگوریتم با ساختار درختی برای طبقه بندي یا پيش بيني کمی يك متغير به کار می رود. در اين تحقیق، از نرم افزار سی ۵ [۲۹] برای ساختن درخت تصمیم و در آخر پيش بيني کلاس های خاک استفاده شد. آنالیز تشخیصی، راهکار سوم جهت مدل سازی است. در واقع، آنالیز تشخیصی، اعضای جامعه مورد تحقیق را در قالب گروه های جدا از هم طبقه بندي می کند، افزون بر اين، تابع تشخیص معادله ای است که با داشتن مشخصات هر فرد از جامعه، می توان پيش بيني کرد که وی به کدام گروه تعلق دارد [۱۶]. برای انجام اين آنالیز، کلاس های خاک به عنوان متغير مستقل و اطلاعات محیطی وارد نرم افزار آماری گردید.

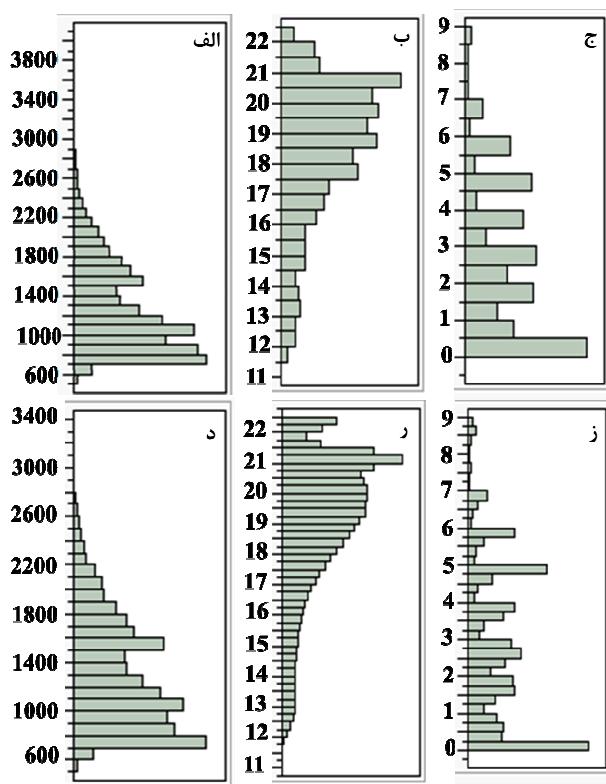
روش چهارم استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه با يك لایه مخفی است. اين شبکه دارای تابع فعال سازی سیگموئید در لایه مخفی، و تابع فعال سازی خطی در لایه خروجی بوده و تعداد نرون های آن از دو تا ۱۰ نرون متغير است. بهترین تعداد نرون آن به صورت آزمون و خطأ تعیین و مورد بررسی قرار گرفت. همچنان به علت کارایی، سادگی و سرعت بالا در اين تحقیق، الگوریتم آموزشی لونبرگ مارکوارت استفاده شد [۴]. مدل لجستیک، آخرین روش مورد استفاده در اين تحقیق است. در مدل لجستیک چند جمله ای، متغير وابسته دارای چند طبقه است (مثالاً کلاس های خاک در يك منطقه).

مواد شور را نشان می‌دهد. قسمت‌های صاف و کم‌شیب واقع در مرکز و شمال دشت یزد-اردکان مواد با قابلیت حلالت بالا را دریافت می‌کنند که این پدیده منجر به شور شدن خاک‌های این واحد شده است. بین شاخص خیسی و شوری خاک ارتباط زیادی وجود دارد که این نتایج با یافته‌های محققین دیگر نیز مطابقت دارد [۱۷ و ۲۶]. شاخص MrVBF، قسمت‌های هموار پایین دره را مشخص می‌کند. همان‌طور که در شکل ۵ مشخص است، تغییرات مکانی این شاخص شباهت زیادی با تغییرات مکانی شاخص خیسی دارد. برای نمونه کمترین مقدار این شاخص با قسمت‌های مرتفع منطقه همپوشانی دارد. بیشترین مقادیر شاخص همواری دره با درجه تفکیک بالا در قسمت‌های میانی و شمالی قرار دارد که می‌توان این ناحیه را به عنوان ناحیه با ظرفیت بالا برای دریافت رسوبات در نظر گرفت.

مدل‌سازی مکانی

شبکه عصبی مصنوعی: توپولوژی شبکه یک عامل اساسی در طراحی شبکه عصبی مصنوعی بوده و تاثیر زیادی بر روی سرعت یادگیری و صحت طبقه‌بندی نهایی می‌گذارد. تعداد لایه‌های مخفی و تعداد نرون‌ها جزو اجزای اصلی شبکه‌های پرسپترون چندلایه هستند. به جز توپولوژی شبکه عصبی مصنوعی که ذکر گردید، تعداد اپوک در مرحله یادگیری دارای اهمیت زیادی است. تعداد نرون‌ها در لایه‌های ورودی و خروجی ثابت بوده و بسته به تعداد ورودی (متغیرهای مستقل) و خروجی (کلاس‌های خاک) مدل به کار گرفته شده، دارد. لایه ورودی شبکه شامل ۲۰ ورودی و لایه خروجی شامل هشت نرون است. تعداد نرون‌ها و لایه‌های مخفی بستگی به پیچیدگی مسئله مورد نظر دارد. در اینجا یک لایه مخفی برای ایجاد شبکه پرسپترون چندلایه استفاده شد. تعداد نرون‌های لایه مخفی و همچنین تعداد اپوک در فرآیند آموزش و به صورت آزمون و خطا به دست آمد. به طور اختصاصی در این مسئله مورد نظر، تعداد نرون ۲ تا ۱۰ و تعداد اپوک ۱۰۰ تا ۱۰۰۰ مورد آزمایش قرار گرفت. برای تعیین بهترین ترکیب از شاخص صحت کلی استفاده شد. نتایج نشان داد که تعداد نرون ۵ و تعداد اپوک ۷۰۰ دارای

گزارش شده [۳۲]. و چنین روش ارزیابی نمونه‌برداری کاربرد فراوانی دارد [۴۵]. در این تحقیق نیز برای بررسی دقیق روش نمونه‌برداری، توزیع هیستوگرامی متغیرهای استفاده شده مدل در محل‌های منتخب رسم شد (شکل ۴). به نظر می‌رسد که توزیع متغیرهای ژئومورفومتری در محل پروفیل‌های خاک (نمونه)، تبعیت از توزیع جامعه را نشان می‌دهد. در حقیقت، نقاط نمونه در جاهایی انتخاب شده که دارای هیستوگرام یکنواخت است.



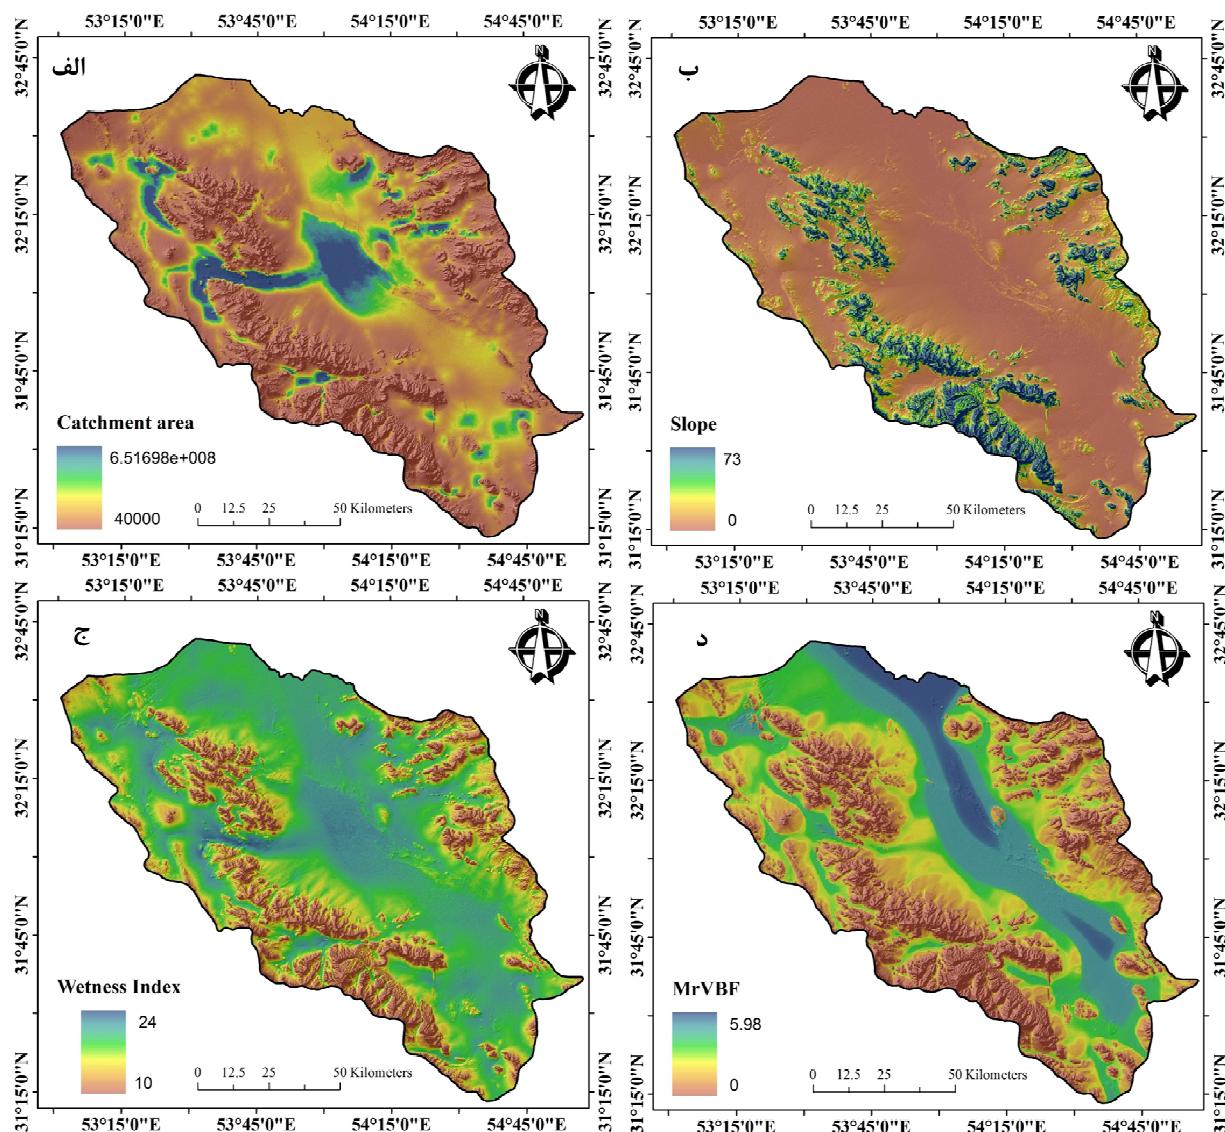
شکل ۴. هیستوگرام متغیرهای ژئومورفومتری در داده‌های نمونه‌برداری شده (الف، ب، ج) و داده‌های اصلی (د، ر، ز). متغیرهای مختلف ژئومورفومتری از قبیل: (الف، د): ارتفاع؛ (ب، ر): شاخص خیسی و (ج، ز): شاخص صافی قسمت میانی دره با درجه تفکیک بالا

متغیرهای محیطی

عامل محیطی مورد استفاده در این پژوهش، از تحلیل مدل رقومی ارتفاع به دست آمد. شکل ۴ تغییرات مکانی شاخص خیسی را نشان می‌دهد. مقادیر کم شاخص خیسی (<10) عموماً در مناطق کوهستانی واقع شده‌اند. مقادیر حد میانه که در حدود ۱۴ است، قسمت‌هایی از شکل اراضی باهada را پوشش می‌دهد و بالاترین مقادیر این شاخص با واحد پلایا (در قسمت‌های میانی منطقه) همخوانی دارد. در حقیقت، این ناحیه ظرفیت بالای تجمع

نتایج همچنین نشان داد برای برآورد مکانی انتی‌سول‌ها، متغیر ارتفاع بیشترین اثر را دارد. پژوهشگران مختلفی از شبکه‌های عصبی مصنوعی جهت پیش‌بینی کلاس خاک و همچنین پیش‌بینی مکانی واحدهای خاک استفاده نموده‌اند. نتایج نشان داد که اجزاء سرزمین مانند شیب، انحنای شیب، ارتفاع، جهت شیب و تابش خورشیدی یکی از متغیرهای کمکی مؤثر در مدل‌سازی هستند [۶]. در کشور چین نیز از شبکه عصبی مصنوعی در پیش‌بینی کلاس بافت خاک استفاده شده است [۴۶].

بهترین ترکیب برای پیش‌بینی گروه بزرگ خاک است. در نتیجه ساختار ۲۰-۵-۸ برای پیش‌بینی کلاس گروه خاک پیشنهاد می‌گردد. همچنین نتایج ماتریس ابهام برای مرحله آموزش با ۱۵۸ داده نشان داد که کلاس هاپلوسالید (٪۷۶) دارای بالاترین صحت طبقه‌بندی است. دقت کلی این شبکه در مرحله آزمون ۳۷٪ است. همچنین نتایج آنالیز حساسیت شبکه عصبی مصنوعی نشان داد که متغیر شاخص خیسی دارای بالاترین اثر برای پیش‌بینی کلاس هاپلوسالید است. بعد از شاخص خیسی، همواری دره با درجه تفکیک بالا دارای اهمیت است (شکل ۶).

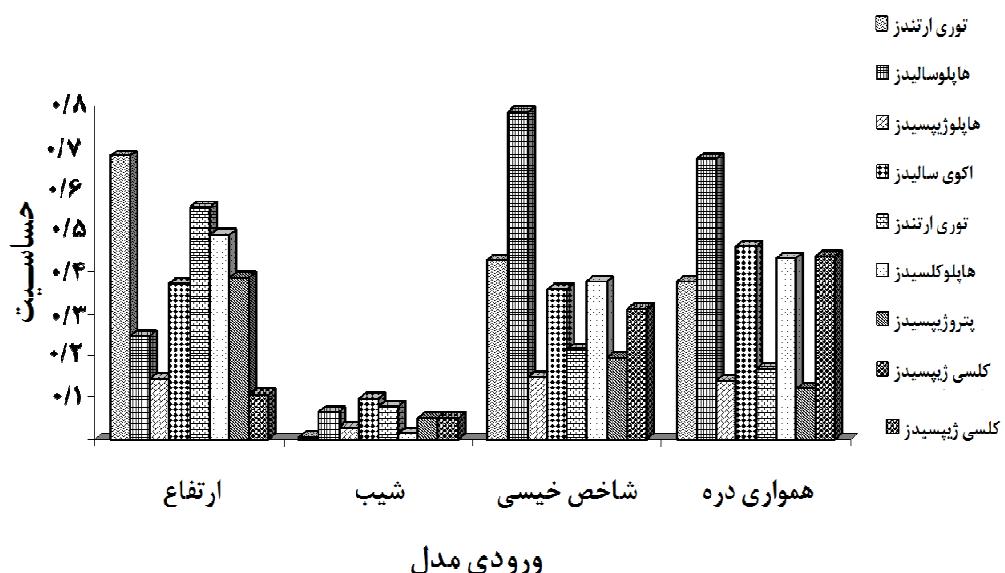


شکل ۵. نقشه مساحت حوزه (الف)، شیب (ب)، شاخص صافی (ج) و شاخص خیسی (د)، شاخص میانی دره با درجه تفکیک بالا (د) که از مدل رقومی ارتفاع بدست آمده است

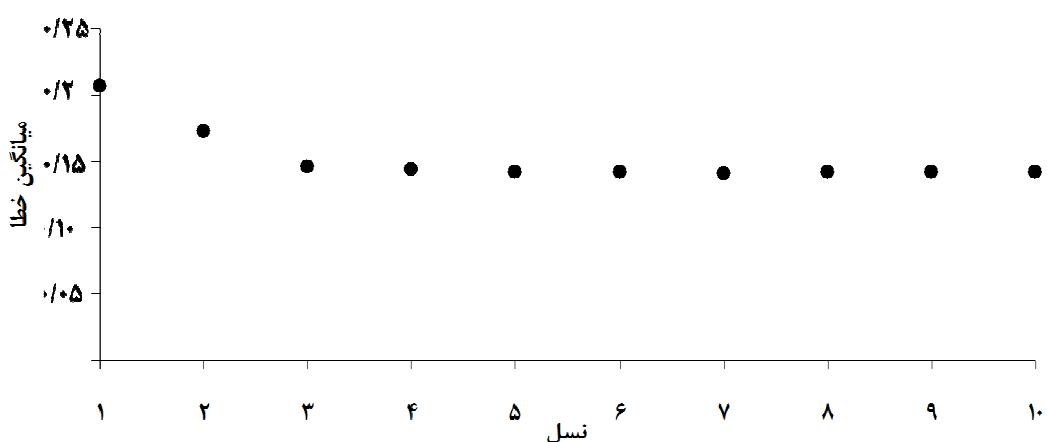
شبکه عصبی مصنوعی-الگوریتم ژنتیک

نسل سوم، شبکه عصبی مصنوعی به عملکرد بهینه دست یافته است. دقت کلی مدل برای مرحله آزمون ۴۹٪ (۰/۸۵/۱۸) بهترین عملکرد مربوط به طبقه توری ارتنز است. نتایج نشان داد که ترکیب دو فن فوق، توانست دقت طبقه‌بندی در مورد کلاس‌های گروه بزرگ خاک را نسبت به روش شبکه عصبی مصنوعی افزایش دهد. همچنانی نتایج آنالیز حساسیت این مدل نشان داد که مهم‌ترین متغیر ورودی مؤلفه‌های اراضی از جمله شاخص همواری دره با درجه تفکیک بالا است.

در این روش از الگوریتم ژنتیک به عنوان روش بهینه‌سازی وزن‌های شبکه عصبی مصنوعی استفاده می‌شود. در این روش، ابتدا برای مجموعه‌ای از داده‌ها که جمعیت نامیده می‌شود، متغیرهای هدف به صورت اتفاقی تولید و افراد در برابر این مجموعه از داده‌ها، مورد آزمایش قرار گرفته و مناسب‌ترین نسل جدید را شکل می‌دهند. این فرآیند برای نسل‌های بعدی تا رسیدن به معیار همگرایی تکرار می‌شود. شکل ۷، تغییرات عملکرد شبکه عصبی مصنوعی در نسل‌های مختلف از ۱ تا ۱۰ را نشان می‌دهد. همان‌طور که از شکل مذکور مشخص است، در



شکل ۶. آنالیز حساسیت ورودی‌های مدل با استفاده از شبکه عصبی مصنوعی

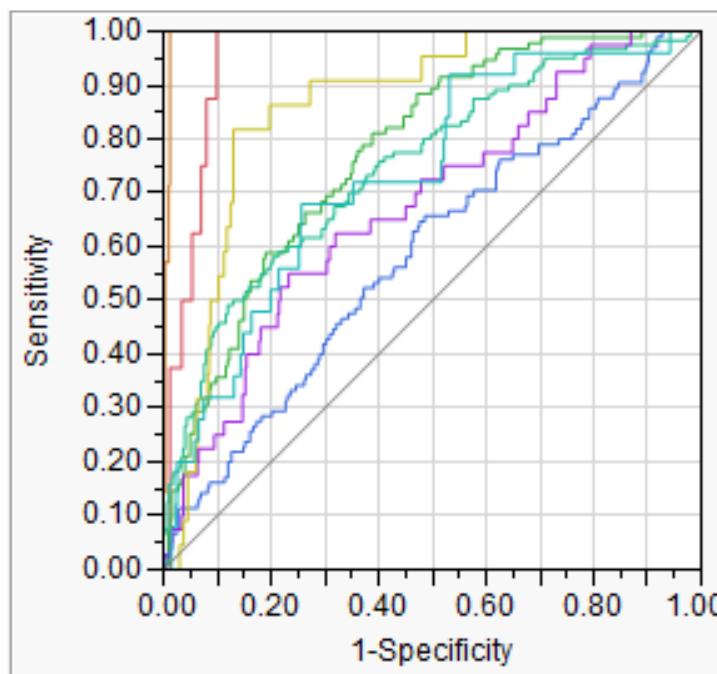


شکل ۷. تغییرات میانگین مربعات خطأ در مقابل تعداد نسل‌های مختلف

رگرسیون لجستیک

همان‌طور که در شکل ۸ مشخص است، مدل توانسته است گروه‌های بزرگ خاک را به خوبی از هم جدا نماید و سطح زیر منحنی نزدیک به یک آن نشان‌دهنده دقیق مدل رگرسیونی است. همچنین نتایج نشان داد که این مدل از نقشه‌های شاخص همواری دره با قدرت تفکیک بالا و شاخص خیسی به عنوان مهم‌ترین متغیرهای پیش‌بینی کننده استفاده کرده است. پژوهشگران مختلفی نیز از مدل‌های رگرسیون لجستیکی (دوتایی و چندتایی) برای پیش‌بینی کلاس‌های خاک استفاده کردند [۹، ۱۰، ۱۵ و ۱۷]. مهم‌ترین عامل در بالا بردن دقیق مدل، همبستگی و ارتباط خوب بین متغیرهای محیطی و هدف اعلام شده است. البته یکی از حسن‌های روش رگرسیون لجستیک، تولید نقشه‌های احتمال است. در حقیقت نقشه خروجی، احتمال حضور یک کلاس از خاک یا افق مشخصه را نشان می‌دهد که برای بررسی عدم قطعیت مدل و همچنین بررسی دقیق‌تر ارتباط بین متغیرهای محیطی و کلاس خاک، به کار می‌رود.

در اجرای مدل لجستیک چند جمله‌ای، گروه بزرگ خاک به عنوان متغیر هدف و متغیرهای کمکی (مؤلفه‌های سرزمین) به عنوان متغیرهای پیش‌بینی کننده در نظر گرفته می‌شوند. نتایج آماری نشان داد که مدل رگرسیونی برآذش داده شده در سطح ۰/۱٪ معنی‌دار بوده و توانسته است در مرحله آزمون با دقیق کلی ۴۰٪ گروه‌های بزرگ خاک را پیش‌بینی نماید. در این مرحله علاوه بر شاخص کلی مدل، مشخصه عامل گیرنده^۱ نیز محاسبه گردید. این منحنی، امکان تعیین بهترین ترکیب حساسیت و ویژگی^۲ در تشخیص حضور یا عدم حضور را فراهم می‌کند [۳۰]. سپس، سطح زیر منحنی^۳ [۲۸] به عنوان شاخصی از کیفیت کلی نقشه تخمین زده شد. سطح زیر منحنی مساوی یک، نشان‌دهنده قدرت بالای روش در تشخیص حضور و عدم حضور و سطح زیر منحنی مساوی ۰/۵، نشان می‌دهد که روش مورد استفاده هیچ قدرت تمایزی در تشخیص حضور و عدم حضور ندارد و در واقع تشخیص به صورت تصادفی است.



شکل ۸. نتایج منحنی مشخصه عامل گیرنده و سطح زیر منحنی مرتبط با مدل رگرسیون لاجیستیک

1. Receiver Operating Characteristic (ROC)

2. Sensitivity and Specificity

3. Area Under Curve (AUC)

آنالیز تشخیصی

تجمع رطوبت در خاک و یا آب در سطح زمین نما را نشان می‌دهد. این مؤلفه با متغیرهای وابسته‌ای که با رطوبت ارتباط و تحت تأثیر رطوبت قرار دارند، همبستگی بیشتری نشان می‌دهد. به طوری که در این پژوهش، شاخص خیسی به عنوان یک متغیر پیش‌بینی‌کننده معنی‌دار در مدل‌های افق مشخصه سالیک وارد شد. شاخص خیسی و شاخص صافی قسمت میانی دره با درجه تفکیک بالا، مناطق مستعد برای دریافت رسوبات (نواحی میانی) را نشان می‌دهند و این قسمت از مناطق بیشتر از خاک‌های شور تشکیل شده است. در حقیقت، این شاخص‌ها به شناسایی گروه بزرگ هاپلوسالیدز کمک می‌کنند. ارتباط معنی‌دار بین خاک‌های شور و شاخص خیسی را تایید شده است [۲۵]. در منطقه خشک شاخص خیسی و همواری دره با درجه تفکیک بالا، به عنوان مؤلفه‌های مهم برای پیش‌بینی کلاس‌های خاک، معرفی شده است [۳۵]. نتایج همچنین نشان داد که سایر متغیرهای کمکی تأثیر چندانی بر روی مدل برای پیش‌بینی گروه‌های بزرگ خاک ندارند.

بعد از به دست آوردن متغیرهای محیطی فوق، مدل درختی با الگوریتم حداقل کردن خطای جهت مشخص کردن دقیق مدل برای پیش‌بینی کلاس خاک برای سطح گروه بزرگ بر روی داده‌های آزمون (۲۰ درصد از داده‌ها) آزمایش شد. نتایج ماتریس خطای برای نتایج مرحله آزمون با ۱۵۸ داده نشان داد که بالاترین دقیق متعلق به گروه هاپلوسالیدز (۸۱ درصد) می‌باشد. دقیق کلی مدل ۶۰/۵ درصد برای پیش‌بینی کلاس خاک برای سطح گروه بزرگ است. محققین مختلفی کارآیی درخت تصمیم را در پیش‌بینی کلاس‌های خاک تایید کردند [۱۳، ۸ و ۷].

ارزیابی مدل‌ها

برای انتخاب بهترین مدل، اقدام به مقایسه مدل‌های استفاده شده (شبکه عصبی مصنوعی، شبکه عصبی مصنوعی-الگوریتم ژنتیک، رگرسیون لجستیک، آنالیز تشخیصی و درخت تصمیم) بر اساس دقیق کلی نقشه گردید. نتایج مقایسه مدل‌ها برای پیش‌بینی گروه بزرگ خاک نشان داد که مدل درخت تصمیم دارای بهترین عملکرد برای پیش‌بینی گروه بزرگ است. بعد از درخت

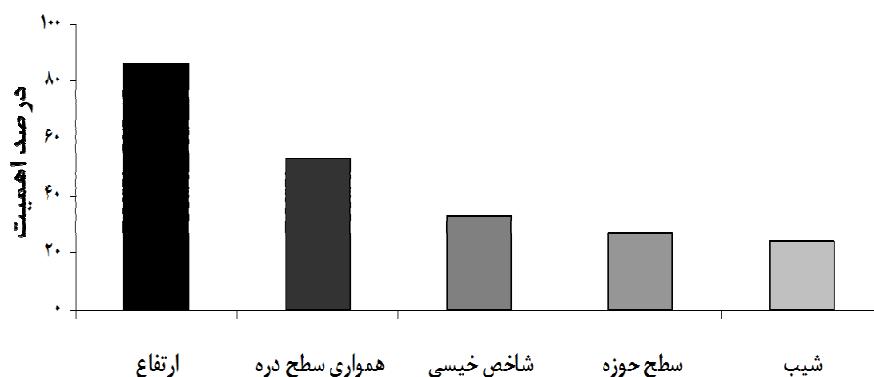
در این روش متغیرهای کمکی در قالب گروه‌های مجزا از هم جدا می‌شود، به صورتی که هر گروه با وجود این که با گروه دیگر شباهت و همبستگی دارد، از انسجام لازم نیز برخوردار باشد. علاوه بر این می‌توان با وارد کردن مشخصات متغیرهای محیطی در قسمت‌های مختلف منطقه در تابع تشخیص، پیش‌بینی کرد که هر پیکسل به کدام طبقه از خاک تعلق دارد. نتایج آنالیز تشخیصی ثابت کرد که تابع تشخیص، متغیرها را در گروه‌های مختلف قرار داده است. همچنین نتایج پیش‌بینی در مرحله آزمون نشان داد که دقیق کلی مدل آنالیز تشخیصی ۳۱٪ است. همچنین بر اساس روش گام به گام، متغیرهایی که به عنوان پیش‌بینی کننده انتخاب شدند عبارتند از: شاخص همواری دره با درجه تفکیک بالا، و ارتفاع و مساحت حوزه اصلاح شده.

درخت تصمیم

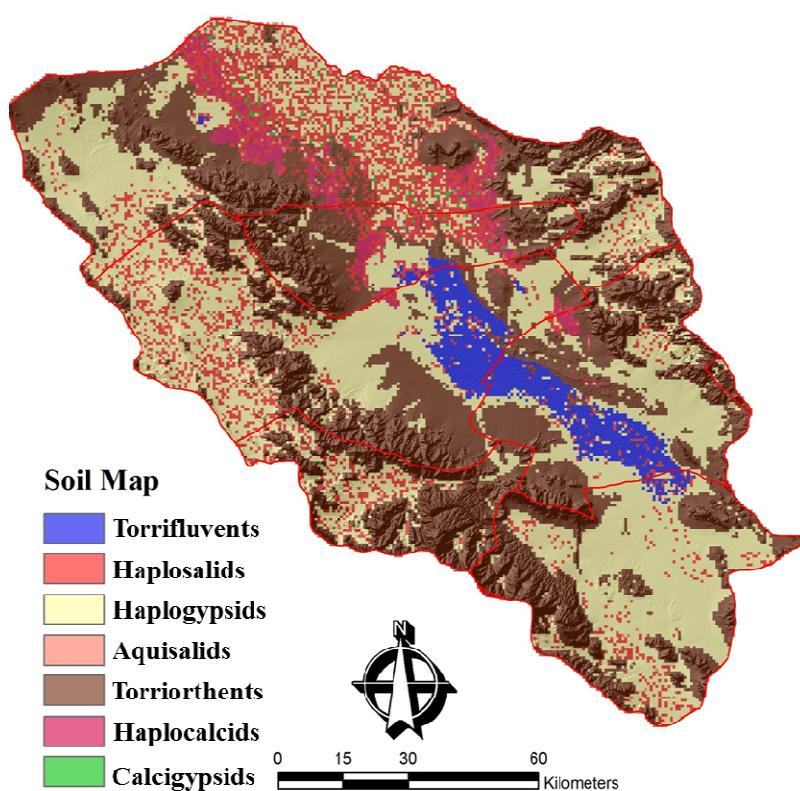
تجزیه و تحلیل درخت تصمیم نشان داد که بعضی از متغیرهای کمکی مانند ارتفاع، شاخص صافی قسمت میانی دره با درجه تفکیک بالا، شاخص خیسی، سطح حوزه و شبیب بالاترین تأثیر را بر روی پیش‌بینی گروه‌های بزرگ خاک دارند شکل ۹ تأثیر هر متغیر کمکی به صورت درصد را بر روی مدل درختی نشان می‌دهد. با توجه به شکل، چنین استنباط می‌شود که ارتفاع مؤثرترین متغیر کمکی در مدل بوده و این شاخص ۸۰ درصد در مدل استفاده شده است. همچنین، متغیر کمکی مهم دیگر شاخص خیسی و شاخص صافی قسمت میانی دره با درجه تفکیک بالا بوده که ۸۰ و ۳۸ درصد در مدل وارد شده است. این موضوع می‌تواند تأیید کننده این مطلب باشد که در این منطقه، پستی و بلندی از مهم‌ترین عوامل خاک‌سازی است. اجزاء سرزمین در توزیع مکانی خاک و خصوصیات آن بسیار مؤثر هستند، چرا که توزیع مکانی تابش خورشیدی، درجه حرارت، رطوبت و جریان مواد را تحت تأثیر قرار می‌دهد. یکی از اجزاء سرزمین، شاخص خیسی یا رطوبتی است که برای تعیین توزیع مکانی نفوذ و جریان آب سطحی به کار می‌رود. در واقع، تأثیر پستی و بلندی بر مکان و میزان

مقایسه فن شبکه عصبی مصنوعی و درخت تصمیم برای پیش‌بینی واحدهای خاک نموده و نشان دادند که تفاوت معنی‌داری بین دو شیوه مذکور برای پیش‌بینی وجود ندارد [۲۴]. در پایان، با استفاده از مدل درختی اقدام به تهیه نقشه رقومی کلاس‌های خاک تاکسونومی در سطح گروه بزرگ گردید (شکل ۱۰).

تصمیم، الگوریتم ژنتیک با دقت کلی ۴۹٪ در مرتبه دوم و رگرسیون لاجیستیک (۴۰٪) در رتبه بعدی قرار می‌گیرد. از بین مدل‌های استفاده شده برای طبقه‌بندی خاک، آنالیز تشخیصی دارای کمترین دقت کلی (۳۱٪) است. کارائی بالاتر درخت تصمیم در مقایسه با شبکه عصبی تایید شده است [۱۹]. با این وجود، برخی پژوهشگران اقدام به



شکل ۹. نتایج اهمیت متغیرهای محیطی در پیش‌بینی گروههای بزرگ خاک بر حسب درصد



شکل ۱۰. نقشه رقومی خاک در سطح بزرگ خاک بر اساس مدل درخت تصمیم

نتیجه‌گیری کلی

نتایج مقایسه انواع مدل‌ها برای پیش‌بینی کلاس خاک در سطح گروه بزرگ نشان داد که در فرآیند نقشه‌برداری رقومی، مدل درخت تصمیم به خوبی می‌تواند ارتباط بین داده‌های خاک و مؤلفه‌های ژئومورفومتری را مدل‌سازی کند. البته سایر مدل‌های استفاده شده شامل الگوریتم ژنتیک و رگرسیون لجستیک نیز به دقت‌های قابل قبولی جهت پیش‌بینی کلاس خاک دست یافتند. همچنین نتایج اهمیت مؤلفه‌های ژئومورفومتری مانند ارتفاع، شاخص خیسی و شاخص همواری دره با درجه تفکیک بالا را در مدل‌سازی تایید می‌نماید. نتایج کلی این تحقیق نشان داد که اجرای فنون نقشه‌برداری رقومی منجر به ایجاد داده و اطلاعات پیوسته در تمام نقاط منطقه مورد مطالعه شده و جواب‌گوی نیاز شاخه‌های دیگر علمی درگیر با محیط است. بنابراین، پیشنهاد می‌گردد مراکزی به منظور جمع‌آوری داده‌های خاک‌رخ‌های سراسر کشور ایجاد گردد و داده‌های گردآوری شده جهت ایجاد بانک داده خاک استفاده شوند. در آخر با استفاده از داده‌های موجود نقشه رقومی کلاس و خصوصیات خاک برای کل کشور تهیه گردد.

همانطور که در شکل مذکور دید می‌شود خاک‌های توری ارنتز بیشتر در نواحی با ارتفاع و شبیه زیاد و اراضی فرسایشی دیده می‌شود، یعنی در مناطقی که امکان و زمان کافی برای تشکیل افق مشخصه زیرسطحی وجود ندارد. خاک‌های با افق کلسیک بیشتر در قسمت‌های شمالی و غربی منطقه مورد مطالعاتی مشاهده گردید. تجمعات آهک در این زیرگروه بیشتر در عمق ۱۵-۷۵ سانتی‌متری به صورت ندول و پندانست دیده می‌شود. خاک‌های بعدی، کلسی‌ژیپسیدز هستند که دارای یک افق کلسیک در عمق ۱۵-۵۰ سانتی‌متری هستند. این ژیپسیک در عمق ۵۰-۱۰۰ سانتی‌متری هستند. این حالت قرارگیری افق‌های یاد شده نشان‌دهنده شستشوی از بالا به پائین است. به طوری که ذرات آهک که دارای حلالیت کمتر نسبت به گچ هستند در بالای پروفیل به صورت پندانست و ندول رسوب کرده‌اند. این گروه خاک را می‌توان در قسمت‌های شمالی منطقه مشاهده کرد. هاپلو-سالیدز تنها یک افق مشخصه سالیک دارند و دارای بافت اردکان قابل مشاهده است. تجمعات گچ در این خاک‌ها بیشتر به صورت پندانست دیده می‌شود.

References

- [1] Ahmed, S., & Simonovic, S. P. (2005). An artificial neural network model for generating hydrograph from hydro meteorological parameters. *Journal of Hydrology*, 315, 236-251.
- [2] Akramkhanov, A., & Vlek, P. L. G. (2012). The assessment of spatial distribution of soil salinity risk using neural network. *Environmental Monitoring and Assessment*, 184, 2475-2485.
- [3] Akramkhanov, A., Martius, C., Park, S. J., & Hendrickx, J. M. (2011). Environmental factors of spatial distribution of soil salinity on flat irrigated terrain. *Geoderma*, 163, 55-62.
- [4] Amini, M., Abbaspour, K. C., Khademi, H., Fathianpour, N., Afyuni, M., & Schulin, R. (2005). Neural network models to predict cation exchange capacity in arid regions of Iran. *European Journal of Soil Science*, 53, 748-757.
- [5] Bailey, N., Clements, T., Lee J.T., & Thompson, S. (2003). Modeling soil series data to facilitate targeted habitat restoration: a polytomous logistic regression approach. *Journal of Environment Management*, 67, 395-407.
- [6] Behrens, T., & Scholten, T. (2007). A comparison of data-mining techniques in predictive soil mapping. In: Lagacherie, P., & McBratney, A.B., Voltz, M. (Eds.), *Developments in Soil Science*, 31, 353- 364.
- [7] Bui, E. N., & Moran, C. J. (2001). Disaggregation of polygons of surficial geology and soil maps using spatial modelling and legacy data. *Geoderma*, 103, 79-94.
- [8] Bui, E. N., Loughhead, A., & Corner, R. (1999). Extracting soil-landscape rules from previous soil surveys. *Australian Journal of Soil Research*, 37, 495- 508.
- [9] Debella-Gilo, M., & 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.
- [10] Giasson, E., Figueiedo, S. R., Tornquist, C. G., & Clarke, R. T. (2008). Digital soil mapping using logistic regression on terrain parameters for several ecological regions in Southern Brazil. In: Hartemink, A.E., McBratney, A.B., & Mendonca-Santos, M.L. (Eds.), *Digital Soil Mapping with Limited Data*. (Volume 32, pp. 3–14): Springer.
- [11] Grinand, C., Arrouays, D., Laroche, B., & 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.
- [12] Grunwald, S. (2009). Multi-criteria characterization of recent digital soil mapping and modeling approaches. *Geoderma*, 152, 195–207.
- [13] Henderson, B. L., Bui, E. N., Moran, C. J., & Simon, D. A. P. (2005). Australia-wide predictions of soil properties using decision trees. *Geoderma*, 124, 383–398.
- [14] Hengl, T., Huvelink, G. B. M., & Stein, A. (2004). A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma*, 120, 75–93.
- [15] Hengl, T., Toomanian, N., Reuter, H., & Malakouti M. J. (2007). Methods to interpolate soil categorical variables from profile observations: Lessons from Iran. *Geoderma*, 140, 417–427.
- [16] Hole, F. D., & Hironaka, M. (1960). An experiment in ordination of some soil profiles. *Soil Science Society of American Journal*, 24, 309–312.
- [17] Jafari, A., Finke, P. A., de Wauw, J. V., Ayoubi, S., & Khademi, H. (2012). Spatial prediction of USDA- great soil groups in the arid Zarand region, Iran: comparing logistic regression approaches to predict diagnostic horizons and soil types. *European Journal of Soil Science*, 63, 284–298.
- [18] King, G. J., Acton, D. F., & Arnaud, R. J. (1983). Soil-landscape analysis in relation to soil distribution and mapping at site with the Weyburn association. *Canadian Journal of Soil Science*, 63, 657–670.
- [19] Luoto, M., & Hjort, J. (2005). Evaluation of current statistical approaches for predictive geomorphological mapping. *Geomorphology*, 67, 299–315.
- [20] MacMillan, R. A., Moon, D. E., & Coupé, R. A. (2007). Automated predictive ecological mapping in a forest region of B.C., Canada. *Geoderma*, 140, 353–373.
- [21] Malone, B. P., McBratney, A. B., Minasny, B., & Laslett G. M. (2009). Mapping continuous depth functions of soil carbon storage and available water capacity. *Geoderma*, 154, 138–152.
- [22] McBratney, A. B., Mendonça-Santos, M. L., & Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117, 3–52.
- [23] Minasny B., & McBratney, A. B. (2006). A conditioned Latin hypercube method for sampling in the presence of ancillary information. *Geology*, 32, 1378–1388.
- [24] Moonjun, R., Farshad, A., Shrestha, D. P., & Vaiphasa, C. (2010). Artificial Neural Network and Decision Tree in Predictive Soil Mapping of Hoi Num Rin Sub-Watershed, Thailand. *Progress in Soil Science* (Volume 33, pp. 151–164): Taylor and Francis Group.
- [25] Moore, I. D., Grayson, R. B. & Ladson, A. R. (1991). Digital terrain modeling: review of hydrological, geomorphological and biological applications, *Hydrology Processing*, 5, 3–30.
- [26] Moore, I. D., Turner, A. K., Wilson, J. P., Jenson, S. K., & Band, L. E. (1993). GIS and landsurface-subsurface process modelling. In: Goodehild, M.F., Parks, B., & L. T. Steyaert, (Eds.), *Environmental Modeling with GIS* (Volume 20, pp. 196–230): Oxford University Press.
- [27] Penížek, V., & Borůvka, L. (2006). Soil depth prediction supported by primary terrain attributes: a comparison of methods. *Plant, Soil and Environment*, 52, 424–430.
- [28] Peterson, W. W., Birdsall, T. G., & Fox, W. C. (1954). The theory of signal detectability. *Transactions of the IRE Professional Group in Information Theory*, 4, 171–212.
- [29] Quinlan, J. R. (2001). See5: An Informal Tutorial, Retrieved January 15, 2014, from <http://www.rulequest.com>.
- [30] Richardson, A. J., & Wiegand, C. L. (1977). Distinguishing vegetation from soil background information. *Remote Sensing*, 43, 1541–1552.
- [31] Rivero, R. G., Grunwald, S., & Bruland,

- G. L. (2007). Incorporation of spectral data into multivariate geostatistical models to map soil phosphorus variability in a Florida wetland. *Geoderma*, 140, 428– 443.
- [32] Roudier, P., Hewitt, A. E., & Beaudette, D. E. (2012). A conditioned Latin hypercube sampling algorithm incorporating operational constraints. *Digital Soil Assessments and Beyond* (Volume 36, pp. 227-231): Taylor and Francis Group.
- [33] Saldadna, A., & Ibaanez, J. J. (2004). Pedodiversity analysis of three fluvial terraces of the Henares River (central Spain). *Geomorphology*, 62, 123– 138.
- [34] Santra, P., & Das, B. S. (2008). Pedotransfer functions for soil hydraulic properties developed from a hilly watershed of Eastern India. *Geoderma*, 146, 439–448.
- [35] Scull, P., Franklin, J., & Chadwick, O. A. (2005). The application of classification of tree analysis to soil type prediction in a desert landscape. *Ecological Modelling*, 181, 1-15.
- [36] Sheng, J., Ma, L., Jiang, P., Li, B., Huang, F., & Wu, H. (2010). Digital soil mapping to enable classification of salt-affected soils in desert agro-ecological zones. *Agricultural water Management*, 97, 1944- 1951.
- [37] Soil and Water Research Department, Agricultural and Natural Resources Research Center of Yazd Province.
- [38] Taghizadeh-Mehrjardi, R. (2008). Soil physico-chemical, mineralogical, and micromorphological changes due to desertification processes in Yazd region, Iran. MSc thesis, Department of Soil Science, Tehran University, (in Farsi).
- [39] Taghizadeh-Mehrjardi, R. (2012). Comparison of artificial neural network and decision tree methods for mapping soil sub-great groups and soil salinity in Ardakan region. PhD thesis, Department of Soil Science, Tehran University, (in Farsi).
- [40] Taghizadeh-Mehrjardi, R. (2014). Semi-detailed soil surveys of Banadak-Sadat, Kohh-Pahlak, Niyestan, Kazab, and Fakhr-Aaad regions. BS thesis, Faculty of Agriculture and Natural Resources, Ardakan University, (in Farsi).
- [41] Thomas, M., Odgers, N. P., Ringrose-Voase, A., Greathouse, G., Glover, M., & Dowling, T. (2012). Soil survey design for management-scale digital soil mapping in a mountainous southern Philippine catchment. *Digital Soil Assessments and Beyond* (Volume 36, pp. 233-238): Taylor and Francis Group.
- [42] West, T. O., Wilson, B. S., Hellwinckel, C. M., Tyler, D. D., Marland, G., De La Torre Ugarte, D., Larson, J. A., & Nelson, R. G. (2008). Estimating regional changes in soil carbon with high spatial resolution. *Soil Science society of American Journal*, 72, 285–294.
- [43] Wilson, J. P., & Gallant, J. C. (2000). Terrain analysis. New York: Wiley & Sons.
- [44] Zevebergen, L. W., & Thorne, C. R. (1987). Quantitative analysis of land surface topography. *Earth Surface Processes Landforms*, 12, 47-56.
- [45] Zhang, Y., Zhao, Y. C., Shi, X. Z., Lu, X. X., Yu, D. S., Wang, H. J., Sun, W. X., & Darilek, J. L. (2008). Variation of soil organic carbon estimates in mountain regions: a case study from Southwest China. *Geoderma*, 146, 449–456.
- [46] Zhao, Z., Chow, T. L., Rees, H. W., Yang, Q., Xing, Z., & Meng, F. (2009). Predict soil texture distributions using an artificial neural network model. *Computers and Electronics in Agriculture*, 65, 36–48.

Digital Soil Mapping Using Geo-morphometric Parameters in the Yazd-Ardakan Plain

1- R. Taghizadeh-Mehrjardi, Faculty of Agriculture and Natural Resources University of Ardakan

Rh_taghizade@yahoo.com

Received: 08 May 2014

Accepted: 13 Sep 2014

Abstract

Traditional soil maps generally consist of some polygon units delineated on the basis of soil variation uniformity. Regarding the difficulties of this kind of maps, researchers have recently tried to use digital soil mapping (DSM) techniques in order to present spatial distribution of soil properties with less cost and time. In this research, Five DSM techniques were applied to predict soil classes in the Yazd-Ardakan plain. Firstly, the USDA soil classification of 422 soil profiles across the Yazd Province were determined and coded. Then, geomorphometric parameters were related to soil data. Results showed that elevation, MrVBF, and wetness index have the most influence on prediction of soil classes up to great group level. Moreover, results indicated that decision tree, genetic algorithm, logistic regression, artificial neural network and discriminant analysis predict soil classes with overall accuracy of 60.5%, 49%, 40%, 37% and 31%, respectively. Results also confirmed the capability of decision tree. Later technique could increase the accuracy of prediction up to 48% compared to discriminant analysis technique. Therefore, using of decision tree model with geomorphometric parameters for soil mapping and updating soil maps is suggested in future studies.

Keyword: Decision tree; Artificial Neural Network; Genetic algorithm; Logistic regression; Discriminant analysis