

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

۱- روح‌اله 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 تاکید 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 خیزی 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 ۰/۵۶، ۰/۴۹، ۰/۴۰، ۰/۳۷ و ۰/۳۱ توانسته‌اند پیش‌بینی را انجام دهند. همچنین، نتایج، کارایی 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<sup>۱</sup> 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 (۰/۸۴)، اقلیم (۰/۱۰/۷)، موجودات زنده (۰/۳۸/۷)، مواد مادری (۰/۱۰/۷) و پستی و بلندی (۰/۲۹/۳) [۱۲]. 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

1. Digital Elevation Model

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 کارایی مدل پیش‌بینی 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

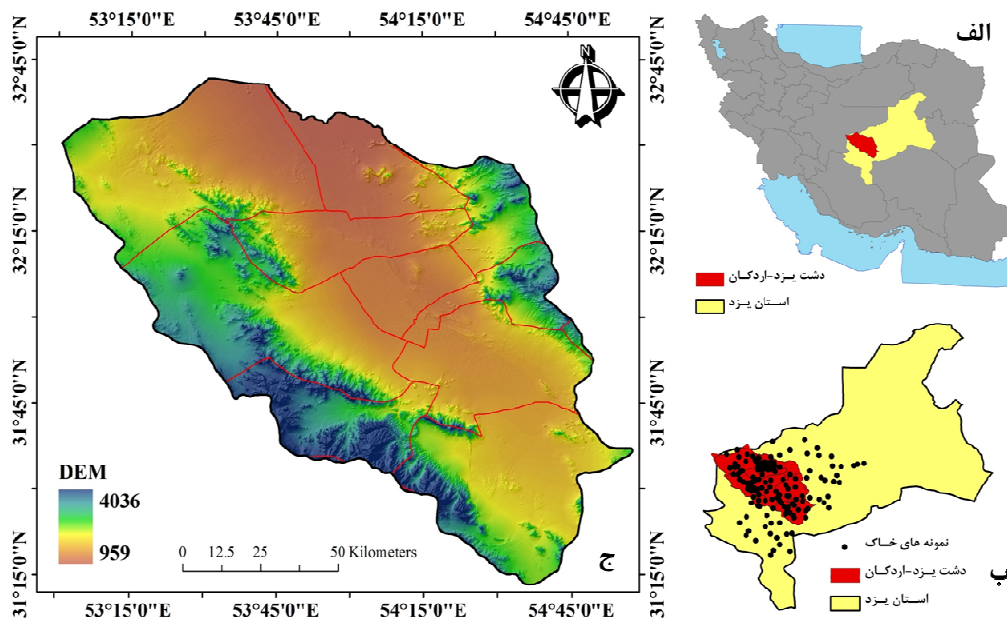
حوزه آبخیز دشت یزد- اردکان با مساحتی حدود ۱۵۹۵۰۰۰ هکتار، در محدوده عرض شمالی ۱۳° ۳۱' تا ۴۸° ۳۲' و طول شرقی ۵۷° ۵۲' تا ۵۹° ۵۴' در فلات مرکزی ایران واقع شده است (شکل ۱). این حوزه بوسیله رشته کوه‌های شیرکوه در جنوب، کوه آهنگران در غرب، کوه‌های هفت‌آدمین در شرق و کوه چک چک در شمال محصور و با شیب عمومی جنوب‌شرق- شمال‌غربی به چاله

در مطالعات زیادی از عامل پستی و بلندی برای پیش‌بینی خصوصیات خاک به تنهایی [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].

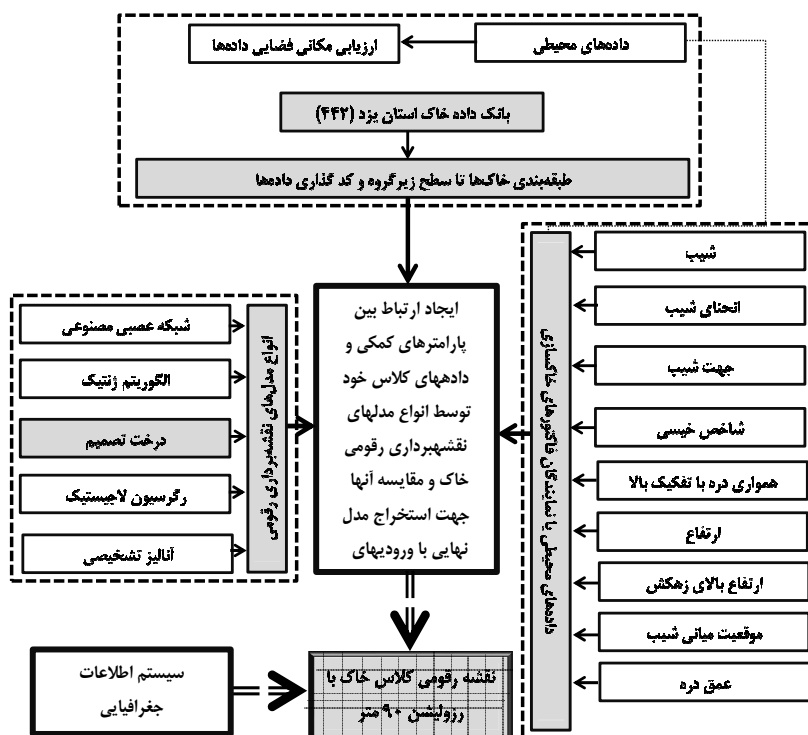
در روش شناسایی رقومی خاک، مؤلفه‌های ژئومورفومتری (عامل مستقل) با استفاده از یک مدل آماری به داده‌های خاک (عامل وابسته) ارتباط داده می‌شوند. مدل‌های آماری مختلفی، در سال‌های اخیر، توسعه پیدا کرده‌اند. پژوهشگران استرالیایی از مدل‌های درختی جهت پیش‌بینی کلاس‌های خاک استفاده نموده‌اند [۷، ۸ و ۱۳]. در جنوب شرقی نروژ، 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. موفقیت رگرسیون لجستیک چندجمله‌ای در پیش‌بینی گروه‌های خاک WRB به شدت به همبستگی کلاس‌های خاک با پیش‌بینی‌کننده‌ها 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 یزد-اردکان استان یزد (بر روی نقشه مدل رقومی ارتفاع مرزهای سیاسی شهرستان‌های واقع در دشت یزد-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].

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

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

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

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

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

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

پارامترهای  $Z1$  الی  $Z9$  مقادیر ارتفاع در شبکه سلولی  $3 \times 3$  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 زمین‌نما است که به وسیله رابطه زیر محاسبه می‌شود:

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

در آن: معادله مقدار  $A_s$  سطح ویژه حوزه و  $\beta$  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، به طوری که خاک‌هایی که در نواحی مرتفع‌تر هستند دارای بافت درشت‌تر و هر چه به سمت انتهایی 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: توری‌فلوننتز (۵ مشاهده)، هاپلو‌سالدیز (۹۵ مشاهده)، هاپلوژیپسیدز (۱۰۵ مشاهده)، اکویی‌سالدیز (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 خیزی، 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  $3 \times 3$  بر روی تصویر است (شکل ۳).

Z <sub>1</sub>	Z <sub>2</sub>	Z <sub>3</sub>
Z <sub>4</sub>	Z <sub>5</sub>	Z <sub>6</sub>
Z <sub>7</sub>	Z <sub>8</sub>	Z <sub>9</sub>

شکل ۳. ساختار شبکه DEM، با یک آرایه  $3 \times 3$  متحرک

## مدل مکانی

در این تحقیق از پنج روش داده کاوی (شامل شبکه عصبی مصنوعی، الگوریتم ژنتیک، درخت تصمیم، آنالیز تشخیصی و رگرسیون لجستیک) بهره گرفته شده است. روش اول یا الگوریتم ژنتیک یک فن برنامه‌نویسی است [۱]. در این روش ابتدا برای مجموعه‌ای از داده‌ها که جمعیت نامیده می‌شود، متغیرهای هدف به‌صورت 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. در این تحقیق، تقریباً 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)، مجموعه‌ای از شرط‌های منطقی به صورت یک الگوریتم با ساختار درختی برای طبقه‌بندی یا پیش‌بینی کمی یک متغیر به کار می‌رود. در این تحقیق، از نرم‌افزار سی ۵ [۲۹] برای ساختن درخت تصمیم و در آخر پیش‌بینی کلاس‌های خاک استفاده شد. آنالیز تشخیصی، راهکار سوم جهت مدل‌سازی است. در واقع، آنالیز تشخیصی، اعضای جامعه مورد تحقیق را در قالب گروه‌های جدا از هم طبقه‌بندی می‌کند، افزون بر این، تابع تشخیص معادله‌ای است که با داشتن مشخصات هر فرد از جامعه، می‌توان پیش‌بینی کرد که وی به کدام گروه تعلق دارد [۱۶]. برای انجام این آنالیز، کلاس‌های خاک به عنوان متغیر مستقل و اطلاعات محیطی وارد نرم‌افزار آماری گردید.

روش چهارم استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه با یک لایه مخفی است. این شبکه 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 است. بهترین تعداد نرون آن به صورت آزمون و خطا تعیین و مورد بررسی قرار گرفت. همچنین به علت کارایی، سادگی و سرعت بالا در این تحقیق، الگوریتم آموزشی لونیبرگ مارکوارت استفاده شد [۴]. مدل لجستیک، آخرین روش مورد استفاده در این تحقیق است. در مدل لجستیک چند جمله‌ای، متغیر وابسته دارای چند طبقه است (مثلاً کلاس‌های خاک در یک منطقه).

ارزیابی خطا و برآورد دقت طبقه‌بندی، به طور معمول، بر اساس متغیرهای آماری است که از ماتریس ابهام استخراج می‌شوند. ماتریس ابهام نتیجه مقایسه پیکسل به پیکسل، پیکسل‌های معلوم (در واقعیت زمینی) با پیکسل‌های متناظر در نتایج طبقه‌بندی است. اعداد روی قطر اصلی ماتریس، تعداد پیکسل‌هایی را مشخص می‌کنند که درست طبقه‌بندی شده‌اند. عناصر غیرقطری مجموعه خطاها هستند. دقت کلی، میانگینی از دقت طبقه‌بندی است که نسبت پیکسل‌های صحیح طبقه‌بندی شده به جمع پیکسل‌های معلوم را نشان می‌دهد (رابطه ۱۱):

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

که در آن:

C تعداد کلاس‌ها، N تعداد کل پیکسل‌های معلوم،  $E_{ii}$  اعضای اصلی ماتریس خطا و OA دقت کلی طبقه‌بندی است. دقت کلی یکی از ساده‌ترین شاخص‌های دقت است که نیاز به عملیات پیچیده برای محاسبه ندارد. دقت کلی یک برآورد کلی از دقت طبقه‌بندی و یا به صورت دقیق‌تر، میانگینی از دقت طبقه‌بندی است. هر چه مقدار عددی دقت کلی بیشتر باشد، نشان دهنده این است که مدل پیش‌بینی کننده تعداد پیکسل‌های بیشتری را به صورت صحیح طبقه‌بندی کرده و از دقت بالاتر برخوردار می‌باشد. لازم به توضیح است که داده‌ها 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

## طراحی الگوی نمونه‌برداری

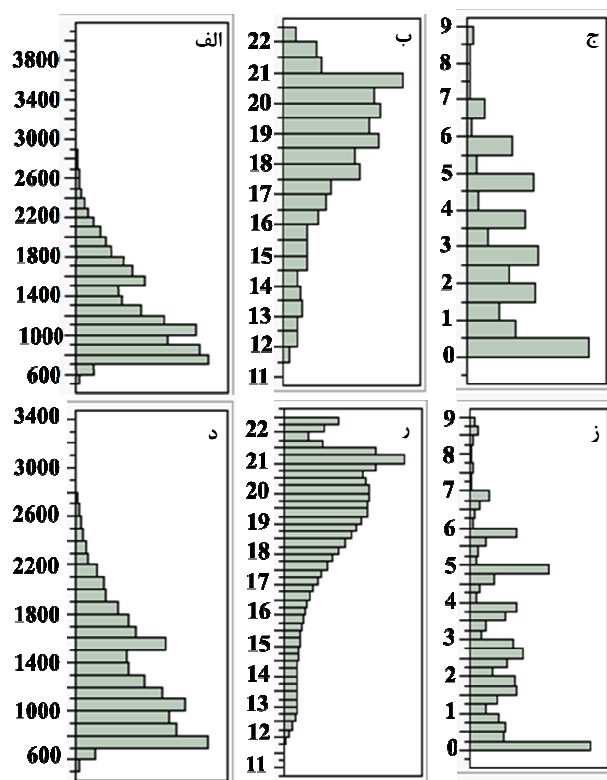
در نقشه‌برداری رقومی خاک، نمونه‌های خاک برای برقراری ارتباط کمی بین اجزاء خاک و متغیرهای محیطی استفاده می‌شوند [۸]. از آنجایی که روابط براساس مشاهدات خاک است، کیفیت نقشه خاک تولیدی به کمیت و کیفیت مشاهدات خاک بستگی دارد. توزیع هیستوگرامی روش کارآمد برای ارزیابی توزیع فضایی نمونه‌ها در جامعه هدف است [۲۳]. همچنین، شباهت توزیع فراوانی روش مربع لاتین به متغیرهای جامعه، به عنوان دلیل برتری نسبت به سایر روش‌های نمونه‌برداری

مواد شور را نشان می‌دهد. قسمت‌های صاف و کم‌شیب واقع در مرکز و شمال دشت یزد-اردکان مواد با قابلیت حلالیت 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 جزء 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، 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 به‌صورت 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 دقت 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.



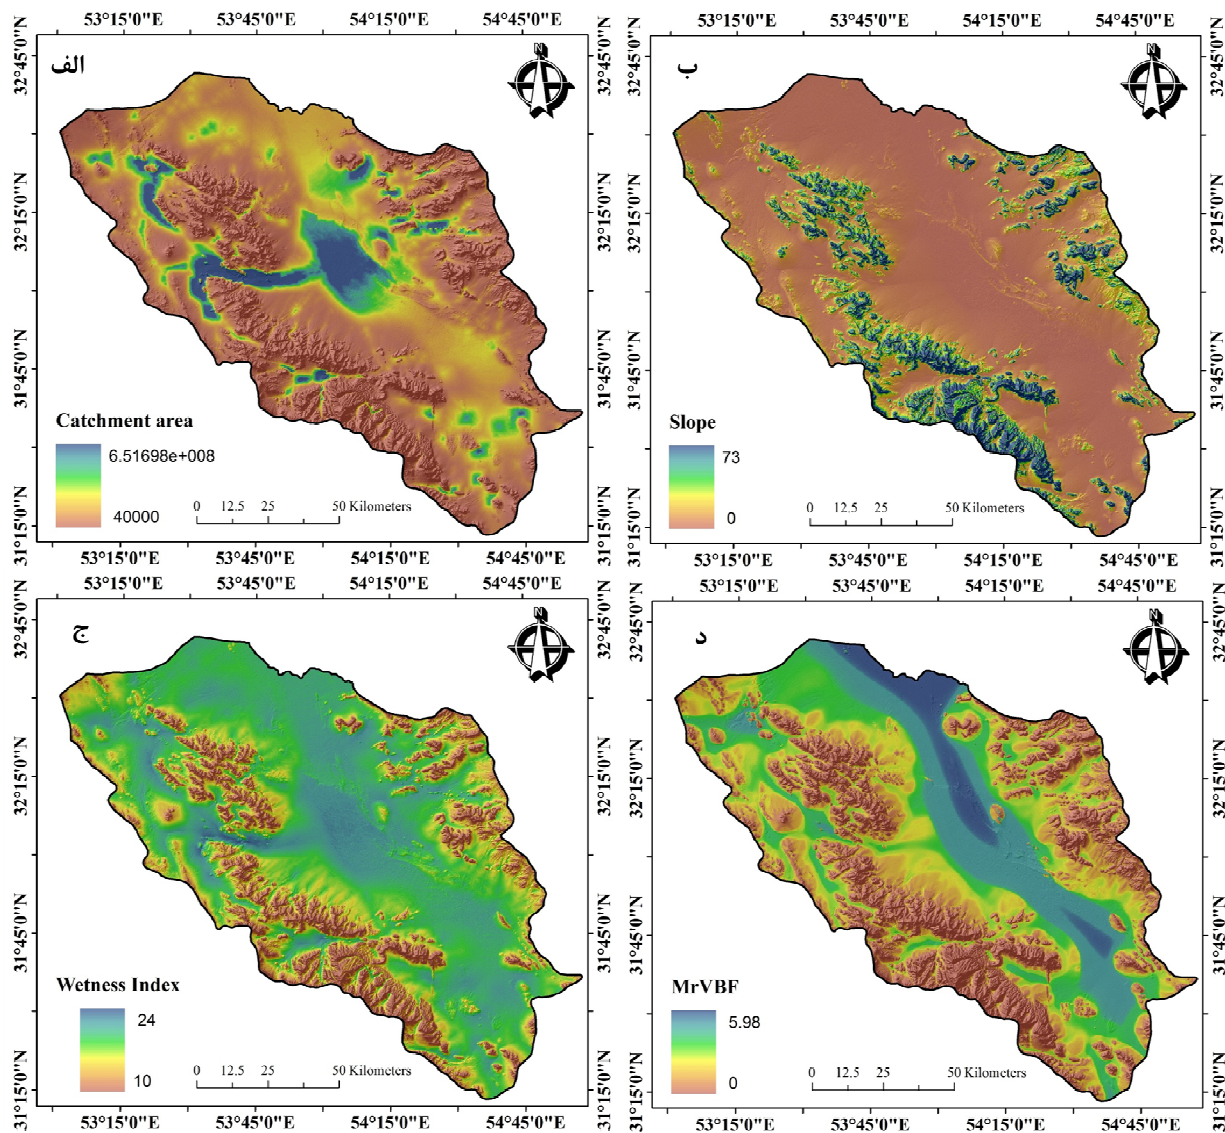
شکل ۴. هیستوگرام متغیرهای ژئومورفومتری در داده‌های نمونه‌برداری شده (الف، ب، ج) و داده‌های اصلی (د، ر، ز). متغیرهای مختلف ژئومورفومتری از قبیل: (الف، د): ارتفاع؛ (ب، ر): شاخص خیسی و (ج، ز): شاخص صافی قسمت میانی دره با درجه تفکیک بالا

#### 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 (< ۱۰) عموماً در مناطق کوهستانی واقع شده‌اند. مقادیر حد میانه که در حدود ۱۴ است، قسمت‌هایی از شکل اراضی باهادا 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 ۸-۵-۲۰ برای پیش‌بینی کلاس گروه خاک پیشنهاد می‌گردد. همچنین نتایج ماتریس ابهام برای مرحله آموزش با ۱۵۸ داده نشان داد که کلاس هاپلوسالید (۰.۷۶٪) دارای بالاترین صحت طبقه‌بندی است. دقت کلی این شبکه در مرحله آزمون ۰.۳۷٪ است. همچنین نتایج آنالیز حساسیت شبکه عصبی مصنوعی نشان داد که متغیر شاخص خیزی دارای بالاترین اثر برای پیش‌بینی کلاس هاپلوسالید است. بعد از شاخص خیزی، همواری درجه تفکیک بالا دارای اهمیت است (شکل ۶).




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

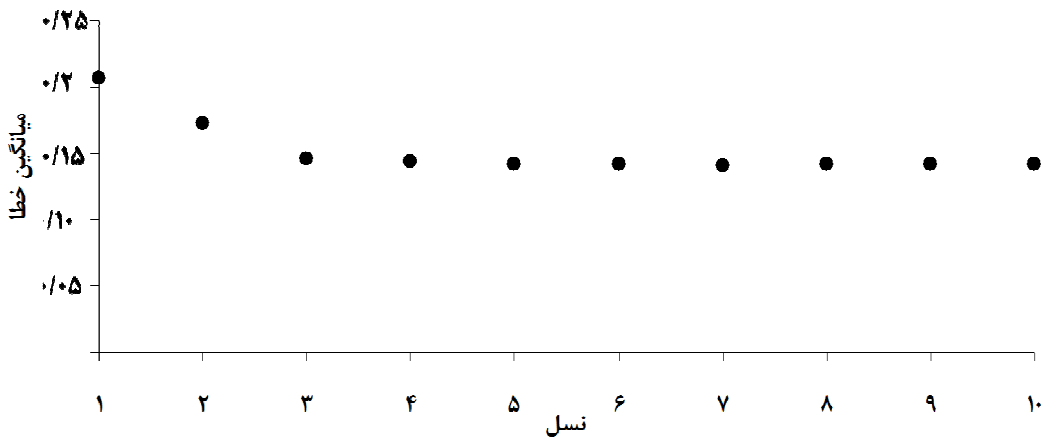
شبکه عصبی مصنوعی - الگوریتم ژنتیک

نسل سوم، شبکه عصبی مصنوعی به عملکرد بهینه دست یافته است. دقت کلی مدل برای مرحله آزمون ۴۹٪ و بهترین عملکرد مربوط به طبقه توری ارتنتز (۸۵/۱۸٪) 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. همچنین 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



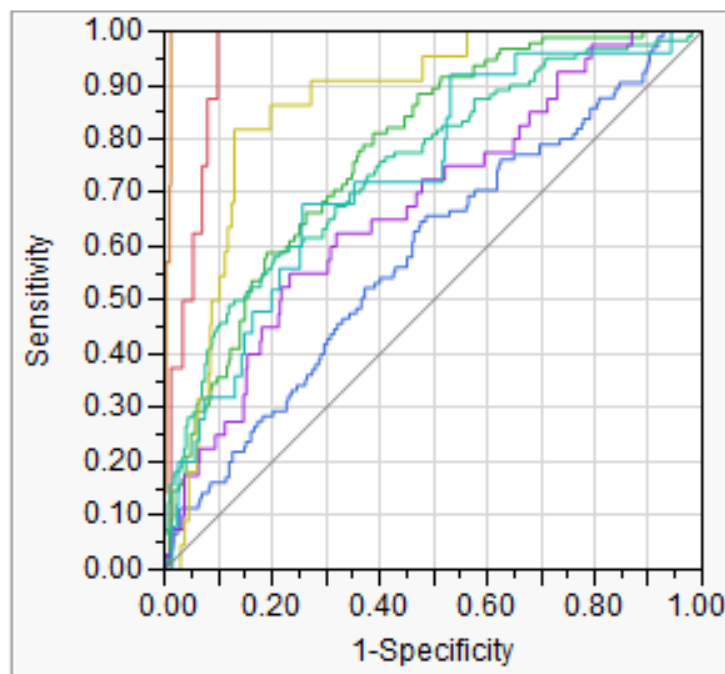
شکل ۷. تغییرات میانگین مربعات خطا در مقابل تعداد نسل‌های مختلف



## رگرسیون لجستیک

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 برازش داده شده در سطح ۰.۱٪ معنی‌دار بوده و توانسته است در مرحله آزمون با دقت کلی ۰.۴۰٪ گروه‌های بزرگ خاک را پیش‌بینی نماید. در این مرحله علاوه بر شاخص کلی مدل، مشخصه عامل گیرنده<sup>۲</sup> نیز محاسبه گردید. این منحنی، امکان تعیین بهترین ترکیب حساسیت و ویژگی<sup>۳</sup> در تشخیص حضور یا عدم حضور را فراهم می‌کند [۳۰]. سپس، سطح زیر منحنی<sup>۴</sup> [۲۸] به عنوان شاخصی از کیفیت کلی نقشه تخمین زده شد. سطح زیر منحنی مساوی یک، نشان دهنده 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.

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 دقت مدل رگرسیونی است. همچنین نتایج نشان داد که این مدل از نقشه‌های شاخص همواری دره با قدرت تفکیک بالا و شاخص خیزی 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 دقت 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.



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

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 زمین‌نما 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 خیزی به عنوان یک متغیر پیش‌بینی کننده معنی‌دار در مدل‌های افق مشخصه سالیکی وارد شد. شاخص خیزی 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 خیزی را تایید شده است [۲۵]. در منطقه خشک شاخص خیزی 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 خطا جهت مشخص کردن دقت مدل برای پیش‌بینی کلاس خاک برای سطح گروه بزرگ بر روی داده‌های آزمون (۲۰ درصد از داده‌ها) آزمایش شد. نتایج ماتریس خطا برای نتایج مرحله آزمون با ۱۵۸ داده نشان داد که بالاترین دقت متعلق به گروه هاپلوسالیدز (۸۱ درصد) می‌باشد. دقت 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 کرده‌اند [۷، ۸ و ۱۳].

## 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 دقت 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 دقت 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

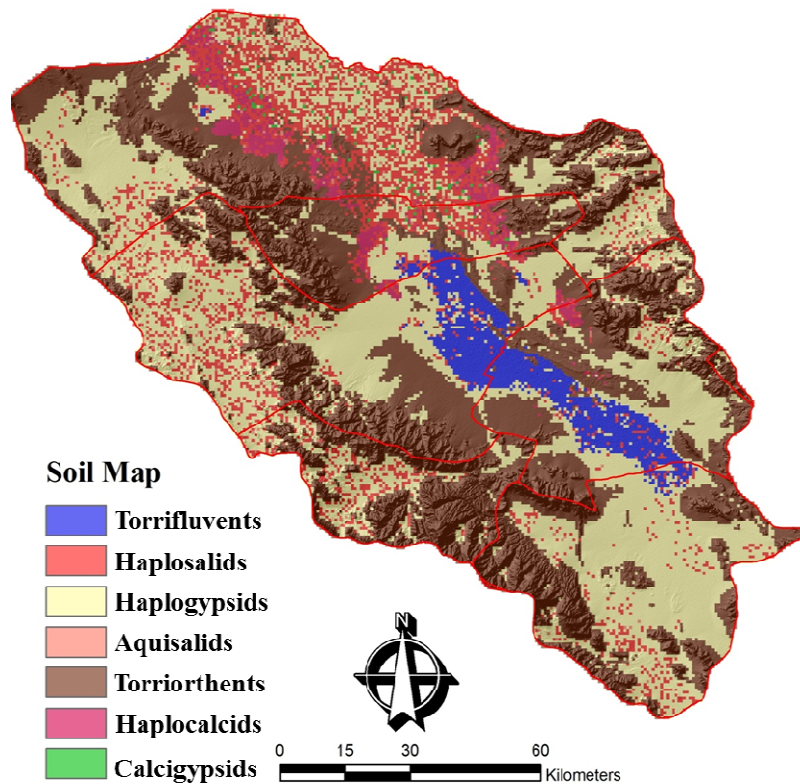
تجزیه و تحلیل درخت تصمیم نشان داد که بعضی از متغیرهای کمکی مانند ارتفاع، شاخص صافی قسمت میانی دره با درجه تفکیک بالا، شاخص خیزی، سطح حوزه و شیب بالاترین تأثیر را بر روی پیش‌بینی گروه‌های بزرگ خاک دارند شکل ۹ تأثیر هر متغیر کمکی به صورت درصد را بر روی مدل درختی نشان می‌دهد. با توجه به شکل، چنین استنباط 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 خیزی و شاخص صافی قسمت میانی دره با درجه تفکیک بالا بوده که ۸۰ و ۳۸ درصد در مدل وارد شده است. این موضوع می‌تواند تأییدکننده 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 خیزی 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 پیش بینی واحدهای خاک نموده و نشان دادند که تفاوت معنی داری بین دو شیوه مذکور برای پیش بینی وجود ندارد [۲۴]. در پایان، با استفاده از مدل درختی اقدام به تهیه نقشه رقومی کلاس های 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 می گیرد. از بین مدل های استفاده شده برای طبقه بندی خاک، آنالیز تشخیصی دارای کمترین دقت کلی (۰/۳۱) است. کارایی 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 پیش بینی گروه های 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 رقوم، 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 خیزی و شاخص همواری دره با درجه تفکیک بالا را در مدل‌سازی تایید می‌نماید. نتایج کلی این تحقیق نشان داد که اجرای فنون نقشه‌برداری رقوم 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 مراکز 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 رقوم کلاس و خصوصیات خاک برای کل کشور تهیه گردد.

## 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

همانطور که در شکل مذکور دید می‌شود خاک‌های توری‌ارتنز بیشتر در نواحی با ارتفاع و شیب 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 نودول و پندانت دیده می‌شود. خاک‌های بعدی، کلسی‌ژپسیدز هستند که دارای یک افق کلسیک در عمق ۵۰-۱۵ سانتی‌متری و یک افق مشخصه ژپسیدز در عمق ۱۰۰-۵۰ 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 پندانت و نودول رسوب کرده‌اند. این گروه خاک را می‌توان در قسمت‌های شمالی منطقه مشاهده کرد. هاپلو-سالیڈز تنها یک افق مشخصه سالیک دارند و دارای بافت سنگین و ریزدانه بوده و در بیشتر قسمت‌های دشت یزد-اردکان قابل مشاهده است. تجمعات گچ در این خاک‌ها بیشتر به صورت پندانت دیده می‌شود.

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., Figueiredo, 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 witan 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., & Ibañez, 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-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, Niyeestan, 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., Grealish, 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-Mehrzardi, 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