

## بررسی تاثیر شاخص خیسی و داده های طیفی در برآورد درصد ذرات خاک با استفاده از مدل های نروفازی، شبکه عصبی مصنوعی و رگرسیون درختی

الهام مهربابی گوهری<sup>۱</sup>، حمیدرضا متین فر<sup>۲\*</sup>، روح الله تقی زاده مهرجردی<sup>۳</sup>، اعظم جعفری<sup>۴</sup>

مقاله پژوهشی

تاریخ ارسال: ۱۳۹۷/۰۸/۱۲

تاریخ پذیرش: ۱۳۹۷/۱۰/۰۱

چکیده

برآورد مستقیم برخی از ویژگی های خاک وقت گیر، پرهزینه و گاهی امکان پذیر نیست، در سال های اخیر از روش های غیر مستقیم برای برآورد این خصوصیات استفاده می شود. در مطالعه حاضر بر اساس تکنیک هایپیرکیوب، محل ۱۱۵ پروفیل شنا سایی و سپس نمونه برداری از افق ها انجام گرفت و در صد شن و رس و سیلت نمونه های خاک اندازه گیری شد. متغیرهای محیطی یا فاکتورهای خاکسازی که در این پژوهش استفاده شد شامل: اجزاء سرزمین، داده های تصویر لندست ۸، نقشه سطوح ژئومورفولوژی و شاخص های منتج از آن و داده های طیف سنجی انعکاسی می باشد. همچنین، جهت ارتباط دادن بین داده های خاک (رس، شن و سیلت) و متغیرهای کمکی از مدل های شبکه عصبی مصنوعی، رگرسیون درختی و نروفازی بهره گرفته شد. نتایج این تحقیق نشان داد که مدل نروفازی دارای دقت بیشتری نسبت به شبکه عصبی مصنوعی و رگرسیون درختی به منظور پیش بینی هر سه پارامتر رس، شن و سیلت می باشد. مقدار متوسط خطا در روش نروفازی با روش رگرسیون درختی مقایسه شد و نتایج نشان داد که مقدار متوسط مربعات خطا در مدل نروفازی برای متغیر رس ۱.۴۳ و برای شن ۱.۹۸ و برای سیلت ۲.۱ بوده که برای رس ۶/۷۱، برای شن ۸/۴۹ و برای سیلت ۵/۴۲ واحد نسبت به رگرسیون درختی کاهش داشت. نتایج همچنین نشان داد که برای پیش بینی رس، شن و سیلت پارامترهای داده های طیفی، شاخص خیسی، شاخص همواری با درجه تفکیک بالا بیشترین سهم را در برآورد دارند.

واژه های کلیدی: شاخص خیسی، داده های طیفی، شبکه عصبی مصنوعی، رگرسیون درختی، نروفازی

۱ - مربی، گروه کشاورزی، دانشگاه پیام نور و دانشجوی دکتری، گروه علوم خاک، دانشکده کشاورزی، دانشگاه لرستان  
Elham.mehrabi1@yahoo.com

۲ - دانشیار، گروه علوم خاک، دانشکده کشاورزی، دانشگاه لرستان، نویسنده مسئول Matinfar.h@lu.ac.ir

۳. استادیار، گروه علوم خاک، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان. rtaghizadeh@ardakan.ac.ir

۴. استادیار، گروه علوم خاک، دانشکده کشاورزی، دانشگاه باهنر. a.gafari@ut.ac.ir



## مقدمه

یا کلاس‌ها در نقاط نمونه‌برداری نشده تخمین زده می‌شود (McBratney et al., 2003).

$$Sc=f(s, c, o, r, p, a, n) \quad (1)$$

در این معادله SC: کلاس خاک، S: اطلاعات خاک که از نقشه خاک یا پایگاه داده یا دانش کارشناس به دست می‌آید. C: اقلیم، O: موجودات زنده از جمله فعالیت انسانی، r: پستی و بلندی یا توپوگرافی، P: مواد مادری، a: زمان و N: موقعیت مکانی می‌باشد. تابع f، یک طبقه بندی نظارت شده یا برنامه یادگیری نظارت شده را نشان می‌دهد. تابع f برای پیش بینی بافت خاک می‌تواند شبکه عصبی مصنوعی، یا طبقه بندی درختی یا تصمیم گیری درختی یا نروفازی باشد. در سال‌های اخیر، استفاده از تکنیکهای داده کاوی از جمله شبکه عصبی مصنوعی، رگرسیون درختی و نروفازی در فرآیند نقشه برداری رقومی خاک رواج گسترده ای یافته است. به عنوان مثال Zhao و همکاران (۲۰۰۹) از مدل شبکه عصبی مصنوعی برای تولید نقشه بافت خاک استفاده کردند. مدل درختی طبقه بندی و رگرسیون برای اولین بار توسط Breiman و همکاران (۱۹۸۴) گسترش داده شد. Kheir و همکاران (۲۰۱۰) از مدل رگرسیون درختی برای پهنه بندی توزیع مقدار روی با استفاده از داده های کمی پارامترهای سرزمین در لبنان استفاده کردند. جعفری و همکاران (۲۰۱۲) نیز در منطقه خشک اقدام به پیش بینی کلاسهای خاک کرده اند و شاخص خیزی 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 اخیرا تشکیل شده است و بنابراین، ارتباط خوبی را با فرآیندهای خاکسازی در مناطق خشک نشان میدهد. Kheir و همکاران (۲۰۱۰) از مدل رگرسیون درختی برای نقشه برداری خاک نیز استفاده کردند. همچنین تقی زاده و همکاران (۲۰۱۴) در منطقه اردکان اقدام به تهیه نقشه سه

بافت خاک یکی از مهم‌ترین ویژگی‌های خاک است که مقدار نگهداری آب و عناصر غذایی، نفوذپذیری، زهکشی، تهویه، مقدار کربن آلی، ظرفیت بافری، تخلخل و بسیاری از خواص مکانیکی خاک را تحت تاثیر قرار می‌دهد (Akpa et al., 2014). داده های مربوط به توزیع اندازه ذرات نهایی سازنده خاک، جزو اطلاعات ورودی به اغلب مدل‌های هیدرولوژیکی، اکولوژیکی، اقلیمی و زیست محیطی هستند (Lie et al., 2012). افزون بر این، در برخی از توابع انتقالی<sup>۱</sup> مورد استفاده برای تخمین خواص از خاک مثل جرم مخصوص ظاهری، قابلیت هدایت آبی و ظرفیت نگهداری آب خاک، از بافت خاک و مقدار برخی از ذرات نهایی سازنده خاک نظیر سیلت و شن استفاده می‌شود (Minasny & Hartemink, 2011). هم چنین بافت خاک در تعیین تناسب خاک برای برخی از استفاده‌های خاص و مهم مثل دفن زباله و مدیریت آب نقش اساسی دارد (Thompson et al., 2012).

با وجود اهمیت زیاد بافت خاک، در مقیاس‌های مورد نیاز برای مدل‌سازی‌های زیست محیطی با کمبود داده‌های آن مواجه هستیم. برای بررسی تغییرات جانبی متغیر مورد نظر در فواصل بین نقاط نمونه‌برداری شده و در نتیجه تهیه نقشه پیوسته پیش‌بینی آن، نیاز به تخمین آن متغیر با استفاده از روش‌های مختلف است. از نقشه‌برداری رقومی خاک که طی چند سال اخیر جنبه کاربردی آن بیشتر شده است می‌توان برای تهیه این نقشه‌های پیوسته استفاده نمود. پایه نقشه‌برداری رقومی خاک مدل اسکورپان (scorpan) است (McBratney et al., 2003). بر اساس این مدل مجموعه‌ای از خواص خاک یا کلاس‌های خاک (مثل کلاس بافت خاک) به عنوان تابعی از متغیرهای کمی به دست از منابع دیگر از جمله نقشه‌های مرسوم خاک‌شناسی، مدل رقومی ارتفاع، سنجش از دور، سنجش از نزدیک و دانش کارشناسان در نظر گرفته می‌شوند (رابطه 1) و با استفاده از روش‌های پیش‌بینی مناسب، این خواص

<sup>1</sup> Pedotransfer function

رگرسیون درخت، شبکه عصبی مصنوعی و عصبی-فازی، و (۲) بررسی تاثیر داده های کمکی مانند پارامترهای سرزمین، تصویر ماهواره ای، نقشه ژئومورفولوژی و نتایج طیف سنجی زمینی جهت پیش بینی درصد رس و شن و سیلت خاک می باشد .

### مواد و روش ها

#### تشریح محدوده مطالعاتی

منطقه مورد مطالعه در جنوب شرق ایران، تقریباً در فاصله ۷۰ کیلومتری شهر کرمان بین عرض جغرافیایی ۴۰' تا ۳۰'۰ تا ۳۱'۰ درجه شمالی و طول جغرافیایی ۵۶'۰ تا ۵۰'۰ درجه شرقی قرار گرفته است. این منطقه مساحتی حدود ۱۰۰۰۰۰ هکتار را می پوشاند و شهرستان زرنند را نیز در بر می گیرد. شهرستان زرنند در شمال غرب استان کرمان قرار دارد و از شمال و شمال غرب با استان یزد (شهرستان بافق)، از شمال شرق و شرق با شهرستان راور، از جنوب شرق با شهرستان کرمان و از جنوب غرب و غرب با شهرستان رفسنجان هم مرز است. ارتفاعات این شهرستان در دو راستا با روند کلی شمال غرب به جنوب-شرق کشیده شده است که دشت زرنند را با همین روند احاطه کرده اند. لندفرم های اصلی این منطقه شامل مخروط افکنه های قدیمی و جدید، سطوح رسی (دق) و تپه های شنی می باشد. متوسط سالانه بارندگی، درجه حرارت و تبخیر و تعرق به ترتیب ۶۱ میلی متر، ۱۷ درجه سانتی گراد و ۱۷۵۰ میلی متر می باشد (آمار هواشناسی شهرستان زرنند، استان کرمان، ۱۳۹۴). در منطقه مورد مطالعه بر اساس تکنیک های پیرکیوب، محل ۱۱۵ پروفیل شناسایی و سپس نمونه برداری از افق ها 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 نمونه های خاک پس از هوا خشک

بعدی شوری خاک با استفاده از مدل رگرسیون درختی کردند. از دیگر روش های مناسب در پیش بینی خصوصیات خاک استفاده از سیستم های فازی عصبی است. مدل نروفازی<sup>۱</sup>، که ترکیب شبکه عصبی با منطق فازی است، با استفاده از الگوریتم آموزش شبکه عصبی، پارامترهای سیستم فازی را تعیین می کند. این سیستم ترکیبی بر اساس سیستم فازی، که بیانگر عدم قطعیت ها است، پایه گذاری شده است. از انواع مدلهای نروفازی می توان به نروفازی همزمان<sup>۲</sup>، نروفازی تعاونی<sup>۳</sup> و نروفازی دورگه<sup>۴</sup> اشاره کرد. در مدل های نروفازی دورگه تغییرات انجام شده در روند یادگیری را می توان از هر دو منظر شبکه عصبی و منطق فازی تفسیر کرد. از این شبکه ها می توان به سیستم فازی تطبیق پذیر مبتنی بر شبکه عصبی<sup>۵</sup> اشاره کرد که نخستین بار توسط Jang (۱۹۹۷) معرفی شد. این مدل یک سیستم فازی را در ساختاری عصبی اجرا می کند و برای فرایند آموزش از ترکیبی از روشهای آموزش شامل شیب نزولی<sup>۶</sup> و حداقل مربعات خطا<sup>۷</sup> استفاده میکند (Kisi, 2005 & Drake, 2000). مطالعات اخیر، کارایی بیشتر مدلهای نروفازی را، در مقایسه با دیگر توابع انتقالی، نشان می دهد. (Mohammadi & Taheri, 2005) برای ایجاد توابع انتقالی خاک، دو روش رگرسیون آماری و فازی را مقایسه کردند. نتایج نشان داد روش رگرسیون فازی در شرایطی که روابط بین متغیرها دارای ابهام است و، به طور کلی، در مواردی که با خطاهای ناشی از ابهام در ساختار معادلات رگرسیونی روبه روست، مکمل و یا جایگزین مناسبی برای روش رگرسیون آماری است. Odeh McBratney & (۱۹۹۷) قابلیت منطق فازی را در علوم خاک، مانند نقشه برداری، ارزیابی، و مدل کردن فرایندهای فیزیکی، به خوبی نشان دادند .

اهداف مطالعه حاضر عبارتند از: ۱- پیش بینی بافت خاک سطحی با استفاده از روشهای داده کاوی شامل مدل

۵ . Adaptive Neuro-Fuzzy Inference System, ANFIS

۶ . Gradient descent

۷ . Least square error

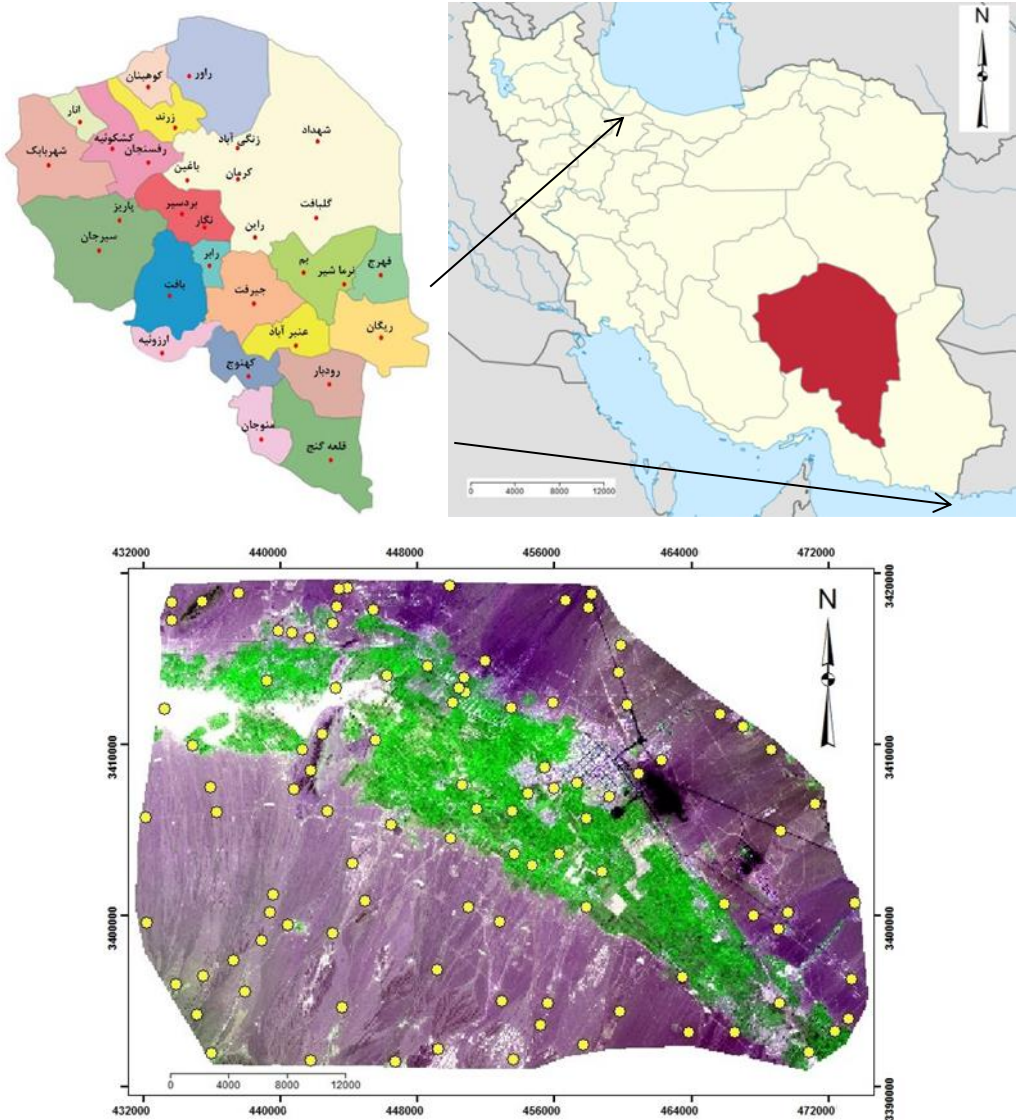
1. Neuro-Fuzzy model

2. Concurrent

3. Cooperative

4. Hybrid

شدن و عبور از الک 2 میلیمتری بافت خاک به روش  
هیدرومتری، اندازه گیری شد.



شکل (۱): موقعیت منطقه مورد مطالعاتی و نحوه پراکنش مکانی داده های خاک

در مطالعه حاضر، از دو سری داده کمی و کیفی به عنوان  
داده های کمی استفاده گردید.

### داده های کمی

داده کمی: از مدل رقومی ارتفاع سازمان زمین شناسی  
آمریکا (قدرت تفکیک ۹۰ متر) استفاده گردید. بعد از آماده  
کردن مدل رقومی ارتفاع، از آن برای استخراج کردن  
اطلاعات کمی یا تصاویر تخمین زننده متغیرهای ژنتیکی

بر اساس مدل اسکورپن در نقشه برداری رقومی خاک،  
علاوه بر داده های خاک نیاز به داده های کمی میباشد .

و منحنی های طیفی آن‌ها در دامنه مرئی، مادون قرمز نزدیک و مادون قرمز میانی (۲۵۰۰-۳۵۰ نانومتر) در تاریکخانه اندازه‌گیری شد (جدول ۲). برای کالیبراسیون اسپکترومتر صفحه سفید (White panel Spectralon) استفاده شد. به منظور کاهش خطا (افزایش نسبت سیگنال به نویز) از هر نمونه خاک ۵۰ طیف گرفته شد. منحنی های به دست آمده با استفاده از نرم افزار RS3 میانگین گیری شده و به صورت یک منحنی طیفی به نمایش در آمد. برای هر نمونه ۳ تکرار ثبت گردید. طیف انعکاسی محدوده مرئی - مادون قرمز نزدیک به دست . ویژگی جذبی آب در ۱۴۰۰ و ۱۹۰۰ نانومتر به علت فرکانس ارتعاشات پایه مولکول آب شامل کشش متقارن و نامتقارن پیوند O-H و خمش O-H مشاهده می شود. ویژگی جذبی رس در ۲۲۰۰ نانومتر می باشد. کانی های خاک نور را در ناحیه های مرئی - مادون قرمز نزدیک و میانی جذب می کنند. پاسخ طیفی کانی های رسی در نتیجه ارتعاش مولکول های آب ساختمانی، گروه های هیدروکسیل، چارچوب سیلیکات و کاتیون های اکتاهدرال، تتراهدرال و بین لایه ای است. اکسید های آهن در محدوده مرئی و کربنات ها در ۲۳۰۰ نانومتر قابل مشاهده هستند. مقادیر انعکاس از طریق رابطه زیر به جذب تبدیل شد. نمودارهای جذب طیف مرئی - مادون قرمز ده نمونه خاک را نشان می دهد. در رابطه (2)، A و R به ترتیب مقادیر جذب و انعکاس بر حسب درصد را نشان می دهند.

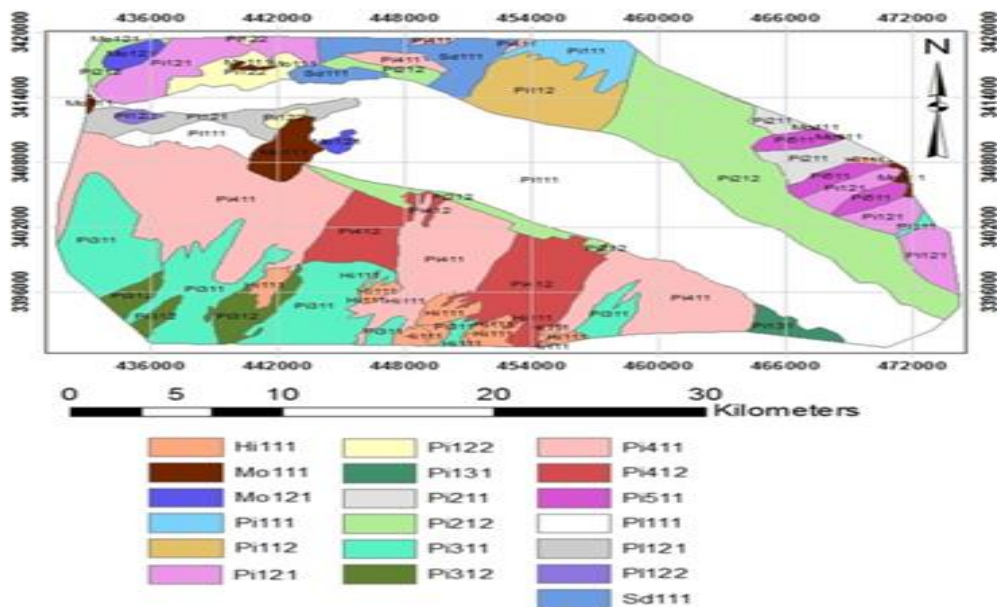
$A = \log(1/R)$  (2) به دلیل این که هنگام اندازه گیری های طیفی این اندازه گیری ها تحت تأثیر عوامل ناخواسته قرار می گیرند، پیش پردازش داده های طیفی نقش مؤثری در بهبود کالیبراسیون دارد. به منظور انجام پیش پردازش طیف ها، ابتدا دو بخش نویزی ابتدا و انتهای طیف ها در محدوده ۳۵۰-۴۵۰ و ۲۴۵۰-۲۵۰۰ نانومتر حذف گردید. به علاوه دو وقفه حاصل از تغییر دکتور در محدوده ۱۰۰۰ و ۱۷۰۰ نانومتر نیز حذف شد. انواع روش های پیش پردازش شامل فیلتر میانه، فیلتر ساویتزکی و

خاک استفاده گردید. پارامترهای زمین نما از قبیل شیب، ارتفاع، ارتفاع بالای شبکه زهکشی، مساحت حوزه های اصلاح شده، عمق دره، شاخص خیسی، شاخص همواری دره ۱ شاخص بالای پشته (MRrtf) و شیب حوزه در محیط سامانه جغرافیایی ساگا 2 محاسبه و استخراج گردید همچنین تصاویر ماهواره ای لندست 8 گرفته شده در سال ۲۰۱۵ در این مطالعه مورد استفاده قرار گرفت. لندست 8 دارای ۱۱ باند است. ۹ باند آن از جمله: باند ۲ (۰.۴۵۰-۰.۵۱۵ میلی متر)، باند ۳ (۰.۵۲۵-۰.۶۰۰ میلی متر)، باند ۴ (۰.۶۳۰-۰.۶۸۰ میلی متر)، باند ۵ (۰.۸۴۵-۰.۸۸۵ میلی متر)، باند ۶ (۱.۵۶۰-۱.۶۶۰ میلی متر)، باند ۷ (۲.۱۰۰-۲.۳۰۰ میلی متر)، باند ۸ (۰.۵۰۰-۰.۶۸۰ میلی متر) با وضوح ۱۵ متر، باند ۱۰ (۱۰-۱۱.۲ میلی متر) با وضوح ۱۰۰ متر) و باند ۱۱ (۵.۳-۵.۱۵ میلی متر) با وضوح ۱۰۰ متر) مورد استفاده قرار گرفت. به منظور کنترل کیفیت داده ها مورد استفاده و برای کاهش خطاهای سیستمیک و غیر سیستماتیک، داده ها تحت نظارت و پردازش قرار گرفتند. سپس شاخص تناوب عادی (NDVI)، شاخص رشد گیاه شناسی (PVI)، شاخص عادی گیاه شناسی تفاوت سبز (GNDVI)، شاخص گیاهی مرتفع شده خاک سبز (GSAVI)، شاخص اختلاف آب نرمال (NDWI)، شاخص رشد گیاه شناسی اصلاح شده خاک (MSAVI) برآورد شده است. تصاویر نیز قبل از استفاده زمین مرجع شده و شاخص های سنجش از دور برای توصیف بهتر منطقه مورد مطالعه در مدل سازی (جدول ۲) مورد استفاده قرار گرفتند. یکی دیگر از داده های کمکی در این مطالعه طیفهای برداشتی نمونه های خاک توسط طیف سنج انعکاسی می باشد. برای این منظور از دستگاه اسپکترو رادیومتر (FieldSpec®3, ASD, FR, USA) با لامپ هالوژن ۲۰ واتی به عنوان منبع نوری مورد استفاده قرار گرفت. طیف سنجی انعکاسی یک روش جایگزین مناسب در تحلیل خصوصیات فیزیکی و شیمیایی خاک برای تخمین محدوده وسیعی از خصوصیات خاک می باشد. نمونه های خاک هوا خشک از الک ۲ میلی متر عبور داده شد



داده کیفی: در منطقه مورد مطالعه، یک نقشه ژئومورفیک نیز تهیه شد. به این ترتیب، بر روی عکسهای هوایی ۱/۵۵۰۰۰ منطقه پوشش براق برای رسم کردن سطوح ژئومورفیک طراحی شد. برای تفکیک ژئومورفیک از روش تفسیر چشمی به کمک استریوسکوپ برای تشخیص تفاوت ها استفاده شد و در طول تعریف استریوسکوپی در مناظر در منطقه مطالعه، دانش موجود در روابط خاک با هم و با زمین شناسی، توپوگرافی و ژئومورفولوژی مورد استفاده قرار گرفت. سپس عکسهای هوایی و روکش مربوطه اسکن شده و وارد محیط سامانه جغرافیایی GIS شد. در مراحل بعد، عکس ها و روکشهای وارد شده به سامانه جغرافیایی با استفاده از تصاویر ماهواره‌ای به روش ارتوفوتوژئورفرنسینگ زمین مرجع شدند. با رقومی کردن مرزهای ترسیم شده بر روکش عکس ها، نقشه ژئومورفولوژی تهیه شد (شکل ۲).

گلای، نرمال سازی بر اساس میانگین و فیلتر گوسین انجام شدند. سپس از رگرسیون حداقل مربعات جزئی (PLSR) برای پیش بینی شن و سیلت و رس استفاده شد. بدین منظور ابتدا مجموعه داده ها به صورت تصادفی به دو گروه کالیبراسیون و اعتبارسنجی تقسیم گردید. تعداد نمونه های گروه کالیبراسیون ۸۰ (حدود دو سوم داده‌ها) و اعتبارسنجی ۳۵ نمونه (حدود یک سوم داده‌ها) در نظر گرفته شد. در نهایت بهترین مدل برازش داده شده بر اساس حداقل ریشه میانگین مربعات خطای پیش بینی (RMSE) معرفی شد. سپس مقادیر طیف های تاثیر گذار بر روی درصد رس، شن و سیلت در مدل استخراج شد و به عنوان داده کمکی وارد مدل های شبکه عصبی، رگرسیون درختی و نروفازی شد. مراحل توصیف های آماری متغیرها، پیش پردازش طیفها و مدلسازی با استفاده از نرم افزار Unscrambler X 10.3 انجام شد. در مطالعه حاضر، در کل به ترتیب از 30، 30 و 29 لایه اطلاعاتی کمکی برای برآورد رس، شن و سیلت بهره گرفته شد.



شکل ۲: نقشه واحدهای ژئومورفولوژی (کدهای مربوط به جدول ۱)

جدول ۱: راهنمای نقشه ژئومورفولوژی برای منطقه مورد مطالعه

Landscape لندسکیپ	Landform لند فرم	Lithology لیتولوژی	Geomorphic surface سطح ژئومورفیک	Code
Hill(تپه)	رخنمون فرسایش یافته	کنگلومرا، ماسه سنگ	سیستم زهکشی شاخه درختی	Hi111
		دولومیت و سنگ آهک	سطح سنگی	Mo111
Mountain(کوه)	رخنمون فرسایش یافته	ماسه سنگ، سنگ	سطح سنگی	Mo121
		آتشفشانی، دولومیت و شیل		
Sand dunes(تپه های شن)	Dune	رسوبات سنگی	تپه های منحنی شکل فعال در حال گسترش مسیل دار	Sd111
		آبرفت های سنگ های	فن فعال، قسمت بالایی، شیب زیاد، شبکه متراکم زهکش	Pi111
		آتشفشانی، کوارتز، ماسه سنگ، دولومیت و شیل	قسمت پایین با زهکش کمتر و شیب کمتر	Pi112
دامنه pdiment	فن بادبزی شکل		فن فعال، شیب زیاد	Pi121
		شیل، ماسه سنگ، سیلت سنگ، کوارتز	فن فعال، تراکم آبراهه، شیب کم	Pi122
		مواد گچی سخت شده و ماسه سنگ	فن فعال، قسمت بالایی	Pi131
			قسمت بالایی، شبکه متراکم زهکش، شیب خیلی زیاد	Pi211
	فن های متصل	رسوبات آبرفتی ماسه سنگ، سنگ آهک و دولومیت	قسمت پایینی، زهکش متراکم	Pi212
			زهکش، شیب کمتر	Pi311
	فن های متصل و بریده شده قدیمی	آبرفت های سنگ های آهک های مختلف، آتشفشانی، ماسه سنگ، و شیل	آبرفت های جدید با زهکش موازی سطح با ارتفاع بالا، شیب زیاد و زهکشی عمیق	Pi312
				Pi411
	فن های متصل قدیمی	آبرفت های سنگ های آهک - های مختلف، گچ، سنگ های آتشفشانی، ماسه سنگ، و شیل	رسوبات یافت درشت، شیب کم، افزایش فاصله زهکشی	Pi412
			آبرفت های جدید با زهکشی موازی	Pi511
	فن بریده شده و شکل گرفته	رسوبات آهکی سنگ های مختلف، سنگ های آتشفشانی، ماسه سنگ و سنگ شیل	بخش بالا، شبکه متراکم زهکشی، شیب بسیار زیاد	Pi511
		سیلت، رس، نمک	خاک رس کشت شده مسطح	PI111
		خاک رس، نمک و مرطوب	پهنه رسی صاف، بسیار شور و مرطوب	PII21
پلایا playa	سطح رسی	رسوبات آبرفتی ریز و درشت، نمک زیاد	مرطوب صاف، مرطوب و شور، آبراهه های متراکم	PI122



جدول ۲: داده‌های کمکی مورد استفاده به عنوان پیش‌بینی‌کننده در مدل‌سازی

منبع	تعریف	پارامترها	داده های کمکی
National Cartographic Center (2010)	ارتفاع از سطح دریا بر حسب متر	Elevation	داده های مستخرج از DEM
SAGA GIS	درجه شیب	Slop	
SAGA GIS	جهت شیب	Aspect	
Gallant and Dowling (2003)	شاخص همواری دره	Multi-resolution Valley Bottom Flatness Index (MrVBF)	
O.Conrad (c) 2012	عمق دره بر حسب متر	Valley depth	
ویلسون و گالانت، ۲۰۰۰	شاخص خیسی	Topographic wetness index	
SAGA GIS	میانگین گرادیان بالای مسیر جریان	Catchment slope (CS)	
Gallant and Dowling (2003)	شاخص بالای پشته	Multi-resolution Ridge-top Flatness Index(MRrtf)	
O'Callaghan, J.F. / Mark, D.M. (1984)	مساحت حوزه های اصلاح شده (محاسبه تجمع جریان و پارامترهای مربوط به آن)	Modified catchment area	
Boehner, J., Selige, T. (2006)	الگوریتم جریان چندگانه و کمک به تخمین دقیق تجمع جریان	LS_Factor (Slope Length and Steepness factor)	
Boettinger et al. (2008)	$(B4 - B3)/(B4 + B3)$	Normalized Difference Vegetation Index (NDVI)	داده های سنجش از دور (لندست ۸)
Boettinger et al. (2008)	$-SINa(B5)COS(B4)$	Perpendicular Vegetation Index (PVI)	
Boettinger et al. (2008)	$(B5-B3)/(B5+B3)$	Green Normalized Difference Vegetation Index(GNDVI)	
Boettinger et al. (2008)	$(B5-B3)/B5+B3+0.5*1.5$	Green Soil Adjusted Vegetation Index (GSAVI)	
Boettinger et al. (2008)	$(B3-B5)/(B3+B5)$	Normalized difference water index (NDWI)	
Boettinger et al. (2008)	$(2*B5+1-\sqrt{(2*b5+1)^2-8*(b5-b4)})/2$	Modified Soil-adjusted Vegetation Index (MSAVI)	
	باند ۲ ماهواره لندست ۸	B2	
	باند ۳ ماهواره لندست ۸	B3	
	باند ۴ ماهواره لندست ۸	B4	



	B5	باند ۵ ماهواره لندست ۸	
	B6	باند ۶ ماهواره لندست ۸	
	B7	باند ۷ ماهواره لندست ۸	
	B8	باند ۸ ماهواره لندست ۸	
	B10	باند ۱۰ ماهواره لندست ۸	
	B11	باند ۱۱ ماهواره لندست ۸	
ژئومورفولوژی	Geomorphology map	سطوح ژئومورفولوژی	Toomanian et al. (2006)
طیف های سنجش از نزدیک اندازه گیری شده توسط FieldSpec®3	SILTG	طیف ۱۴۵۶	Esbensen, K.H. (2006)
	SILTM	طیف ۱۹۹۸	Esbensen, K.H. (2006)
	SILTK	طیف ۱۹۰۴	Esbensen, K.H. (2006)
	SANDF	طیف ۸۵۲	Esbensen, K.H. (2006)
	SANDG	طیف ۸۷۹	Esbensen, K.H. (2006)
	SANDP	طیف ۲۳۹۶	Esbensen, K.H. (2006)
	SANDK	طیف ۱۹۰۷	Esbensen, K.H. (2006)
	CLAYE	طیف ۸۷۹	Esbensen, K.H. (2006)
	CLAYF	طیف ۸۹۰	Esbensen, K.H. (2006)
	CLAYQ	طیف ۲۴۲۸	Esbensen, K.H. (2006)
	CLAYO	طیف ۲۴۰۴	Esbensen, K.H. (2006)

### آماده سازی داده ها برای مدلسازی

برای پهنه بندی کلاسهای بافت خاک در سطح منطقه، در این مطالعه ابتدا هر یک از داده های ذرات نسبی خاک (رس، شن و سیلت) در افق سطحی A به عنوان متغیر وابسته در نظر گرفته شدند و در فرآیند نقشه برداری رقومی خاک قرار گرفتند. در نهایت نقشه های رس، شن و سیلت، خاک مدلسازی شد. همچنین، بر روی داده های کمکی استخراج شده از طریق طیف سنجی انعکاسی روش های تجزیه مولفه های اصلی و رگرسیون حداقل مربعات جزئی به کار رفت و از آنها داده های تاثیر گذار را جدا گردید و سپس تمام لایه های اطلاعاتی یا کمکی به فرمت رستری با اندازه سلولی استاندارد ۹۰ متری در محیط GIS تهیه شد. این اطلاعات به عنوان متغیرهای وابسته در مدل اسکورپین 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 (JMP, GIS) آماده شدند.

### مدلسازی خاک

درخت تصمیم: مدل درختی طبقه بندی و رگرسیون، یک روش ناپارامتری الگوریتمی است که قادر به پیش بینی متغیرهای کمی یا متغیرهای طبقه بندی شده بر اساس مجموعه ای از متغیرهای پیش بینی کننده کمی و کیفی است. در این روش، مجموعه های از شرط های منطقی (-if then) به صورت یک الگوریتم با ساختار درختی برای طبقه بندی یا پیش بینی کمی یک متغیر به کار می رود. ایجاد درخت تصمیم شامل دو مرحله است. مرحله اول ایجاد و رشد درخت است. این مرحله شامل پیوند و انشعاب می باشد. مرحله دوم، مرحله توقف و هرس است. هدف از این مرحله به حداقل رساندن خطای پیش بینی است. در تحقیق حاضر از نرم افزار جمپ (JMP) برای ساختن

کرد و الگوریتم یادگیری ساختارها، پارامترها و یا هر دو آن ها را اصلاح می کند. برای ایجاد این شبکه باید چند پارامتر نوع تابع عضویت، تعداد تابع، روش یادگیری، و تعداد اپوک بهینه شوند. برای این کار همه حالات با سعی و خطا به دست می آید.

### مقایسه تکنیکهای نقشه برداری رقومی

برای بررسی عملکرد مدل های مختلف در برآورد متغیرهای وابسته (رس، شن و سیلت) از سه روش خطای مختلف برای ارزیابی عملکرد مدل ها در پیش بینی متغیرهای وابسته (خاک رس، شن و ماسه) استفاده شد) ضریب تعیین ( $R^2$ )، خطای متوسط ( $ME$ ) و متوسط مربعات خطا ( $RMSE$ ).  $RMSE$  یک اندازه گیری از دقت پیش بینی است و برای پیش بینی دقیق مقدار آن نزدیک به صفر است.  $ME$  نشان دهنده تعصبات پیش بینی است و باید برای روش های بی طرفانه نزدیک به ۰ باشد.  $R^2$  یک معیار آماری است که درصد پیش بینی را نسبت به نقاط داده واقعی مقایسه میکند.

$$R^2 = \frac{\left[ \sum (X_e - \bar{X}_e)(X_o - \bar{X}_o) \right]^2}{\sqrt{((X_e - \bar{X}_e)^2)(X_o - \bar{X}_o)^2}} \quad (3)$$

$$RMSE = \left[ \frac{\sum (X_o - X_e)^2}{n} \right]^{\frac{1}{2}} \quad (4)$$

$$ME = \frac{1}{n} \sum_{i=1}^n (X_o - X_e) \quad (5)$$


رگرسیون درختی و در نهایت پیش بینی ذرات نسبی خاک (رس، شن و سیلت) استفاده شد.

شبکه عصبی مصنوعی: در این تحقیق شبکه عصبی مصنوعی پرسپترون چند لایه با یک لایه مخفی که دارای تابع فعال سازی سیگموئید در لایه مخفی و تابع فعال سازی 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 آموزشی لوبزمارکوارت استفاده شد. در تحقیق حاضر از نرم افزار جمپ برای ساختن شبکه عصبی مصنوعی و پیش بینی ذرات نسبی خاک (رس، شن و سیلت) استفاده شد.

نروفازی: در این تحقیق سیستم فازی تطبیق پذیر مبتنی بر شبکه عصبی مورد بررسی قرار گرفت. ساختار مجموعه های فازی را می توان به عنوان وزن ارتباطات و متغیرهای ورودی و خروجی را به عنوان نورون ها تفسیر

$0x$ : متغیرهای کمی مشاهده شده،  $ex$ : متغیرهای کمی تخمین زده،  $0\bar{x}$ : میانگین متغیرهای مشاهده شده،  $e\bar{x}$ : میانگین متغیرهای کمی برآورد شده

متغیرهای کمکی، بیشترین همبستگی بین شاخص خیسی و شاخص‌های تنوع مشاهده شد (شکل ۳). هیچ‌گونه تغییراتی از شاخص تنوع خاک در شاخص خیسی حداقل مشاهده نگردید. بیشترین انترویی در لندفرم‌های پلایا، باهادای بریده بریده، باهادای قدیمی و کمترین انترویی در زمین‌نمای کوه و تپه‌های ماسه‌ای مشاهده شد.



شکل ۳: نقشه همبستگی بین شاخص خیسی و شاخص انترویی شانن که روی نقشه شاخص خیسی قرار گرفته است. خطوط سیاه نشان دهنده همبستگی بالای شاخص خیسی و شاخص شانن است.

## نتایج و بحث

### خلاصه آماری داده‌ها

در جدول ۳ خلاصه آماری رس، سیلت و شن آمده است. همان‌طور که مشاهده می‌شود، درصد رس از میزان ۳ درصد تا ۴۲ درصد متفاوت بود و میزان شن از ۲۷ درصد تا حدود ۹۵ درصد و میزان سیلت نیز بین ۲ درصد تا ۴۲ درصد در منطقه متغیر بود. میزان بالاتر درصد رس و سیلت در خاک مربوط به قسمت‌های مرکزی منطقه مورد مطالعه می‌باشد که از نظر زمین‌شناسی در پلایاها (P1111, P1121, and P1122) واقع شده است. میزان بالای درصد رس در مناطق شمالی و جنوبی منطقه دیده می‌شود که مربوط به دامنه‌ها می‌باشد که از آبرفت‌های بادبزی شکل و باهادا‌های مختلف که در دامنه کوه‌ها قرار گرفته‌اند تشکیل شده است. کلاس‌های مختلف بافت خاک در منطقه مورد مطالعه از لومی شنی تا رسی مشاهده گردید که بافت‌های لومی شنی و شنی در قسمت‌های دامنه‌ای و آبرفت‌های بادبزی شکل منطقه مشاهده می‌شود و بافت‌هایی با درصد رس بیشتر در قسمت مرکزی منطقه و در پلایاها دیده می‌شود دیده می‌شوند. نقشه انترویی شانن و غنا براساس نقشه خاک پیش‌بینی شده در هر طبقه ایجاد گردید. بنابراین باید یک ارتباط مشخصی بین شاخص‌های تنوع خاک و متغیرهای محیطی وجود داشته باشد. در بین



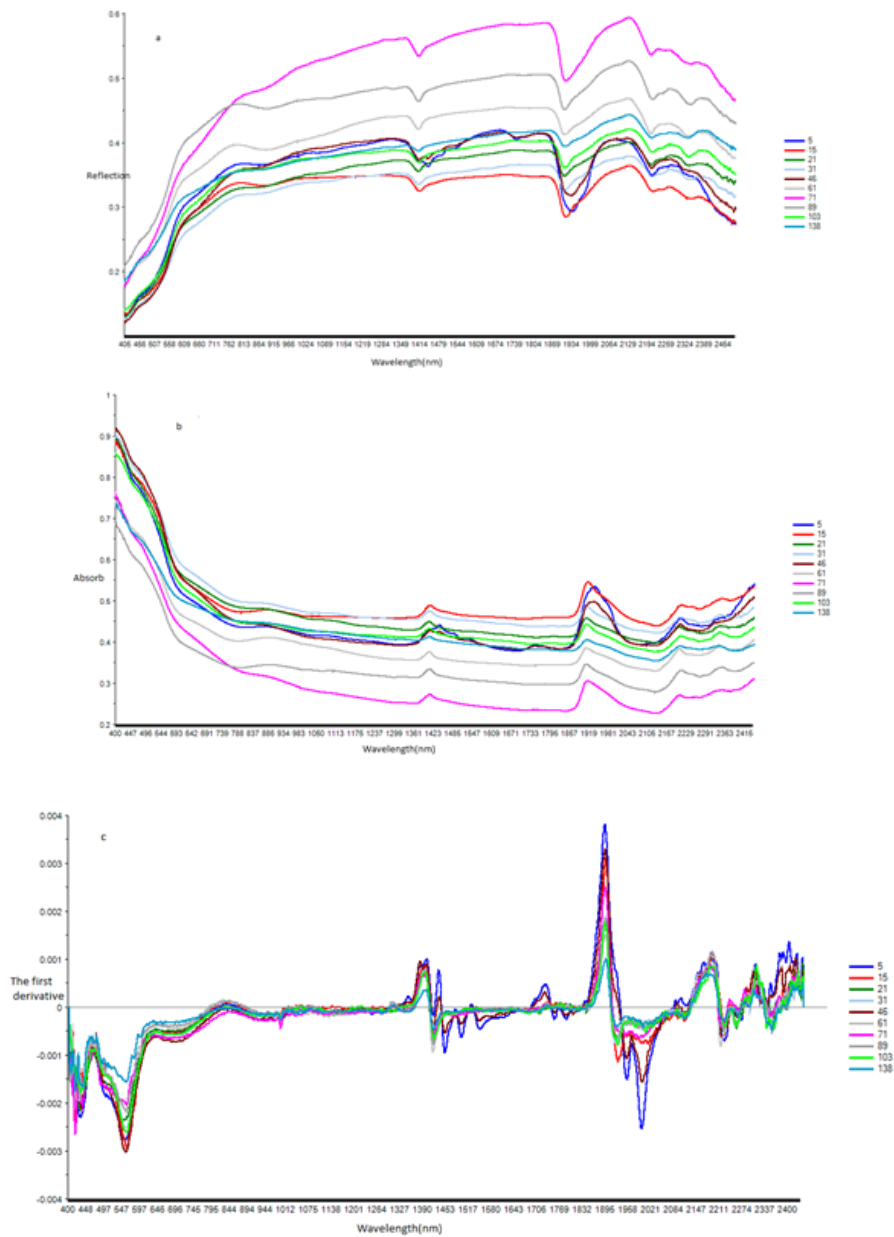
جدول (۳): پارامترهای آماری مربوط به خصوصیات شن، رس و سیلت

انحراف معیار Standard deviation	میانگین (Average)	حداکثر (max)	حداقل (min)	خصوصیت (درصد) (%) Feature
۸/۹۱	۱۸/۵۹۱۸	۴۲/۶۱۵	۳/۰۰	رس (clay)
۱۵/۱۳	۶۴/۱۰	۹۴/۸۸	۲۷/۹۷	شن (sand)
۹/۵۸	۱۷/۲۶	۴۲/۱۵	۲/۰۰	سیلت (silt)


وجود دارد. مقادیر بازتابی به جذب تبدیل شد. شکل ۴(ب) جذب طیفی قابل مشاهده مادون قرمز از ده نمونه خاک را نشان می دهد. شکل ۴(ج) طیف های قابل مشاهده در نزدیکی مادون قرمز را در ده نمونه خاک پس از پیش پردازش (اولین مشتق + فیلترهای ساواتزکی و گلای) را نشان می دهد.

### ویژگی های طیف های خاک

شکل ۴(الف) طیف محدوده قابل مشاهده در نزدیکی سطح مادون قرمز را در ده نمونه خاک نشان می دهد. شکل کلی همه طیف ها در تمام خاک ها تقریباً یکسان است، به طوری که خواص جذب آب و رس در تمامی طیف ها مشاهده می شود، هر چند که در شدت انعکاس تفاوت



شکل (۴): مقادیر انعکاس الف، ب (جذب و ج) مشتق اول، طیف های محدوده مرئی-مادون قرمز نزدیک در ده نمونه خاک به طور تصادفی



شکل (۵): نتایج متغیرهای مهم محیطی در پیش بینی ذرات رس، سیلت و شن (توضیح هر یک از داده های کمکی در جدول ۲ آمده است)

#### داده های کمکی موثر:

سرزمین، شاخص خیسی یا رطوبتی است که برای تعیین توزیع مکانی نفوذ و جریان آب سطحی بکار می رود. در واقع تأثیر توپوگرافی بر مکان و میزان تجمع رطوبت در خاک و یا آب در سطح زمین نما را نشان می دهد. این پارامتر با متغیرهای وابسته ای که با رطوبت ارتباط دارند و تحت تأثیر رطوبت قرار دارند، همبستگی بیشتری نشان می دهد. به طوری که در مطالعه حاضر، شاخص خیسی به عنوان یک متغیر پیش بینی کننده معنی دار در ذرات سیلت وارد مدل شده است. شاخص خیسی مناطق مستعد

بعضی از متغیرهای کمکی مانند طیف سنجی انعکاسی، شاخص خیسی و سطح ژئومورفولوژی بالاترین تأثیر را بر روی پیش بینی ذرات خاک را دارند (شکل ۵). این شکل تأثیر هر متغیر کمکی را بر روی مدل درختی بیشتر نشان میدهد. با توجه به این شکل، اینگونه استنباط می شود که طیف سنجی انعکاسی یکی از موثرترین متغیرهای کمکی در هر سه مدل می باشد. یکی از اجزاء

همکاران (۲۰۱۰) از مدل رگرسیون درختی برای نقشه برداری خاک نیز استفاده کردند و همچنین تقی زاده و همکاران (۲۰۱۴) در منطقه اردکان اقدام به تهیه نقشه سه بعدی شوری خاک با استفاده از مدل رگرسیون درختی کردند و نتایج مشابهی به دست آوردند. با این وجود مونجان و همکاران (۲۰۱۰) اقدام به مقایسه تکنیک شبکه عصبی مصنوعی و درخت تصمیم برای پیش بینی واحدهای خاک نموده و نشان دادند که تفاوت معنی داری بین دو تکنیک برای پیش بینی وجود ندارد.

نتایج مدل سازی مکانی به کمک تکنیک شبکه عصبی مصنوعی، توپولوژی شبکه یک فاکتور اساسی در طراحی شبکه عصبی مصنوعی میباشد به علت اینکه این ساختار اثر تاثیرگذار بر روی سرعت یادگیری و صحت طبقه بندی نهایی میگذارد. تعداد لایه های مخفی و تعداد نرون ها جزء اجزای اصلی شبکه پرسپترون میباشد. بجز توپولوژی شبکه عصبی مصنوعی که ذکر شد تعداد اپوک در مرحله یادگیری بسیار حائز اهمیت میباشد. تعداد نرونها در لایه های 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 ۳۰، ۳۰ و ۲۹ نرون برای رس، شن و سیلت میباشد. لایه خروجی شامل یک نرون میباشد. تعداد نرونها و لایه های مخفی بستگی به پیچیدگی مسئله مورد نظر دارد. در اینجا یک لایه مخفی برای ایجاد شبکه پرسپترون مورد استفاده قرار گرفت. تعداد نرون های لایه مخفی و همچنین تعداد اپوک در فرآیند آموزش و به صورت سعی و خطا به دست آمدند. در این پژوهش، تعداد نرون 2 تا 10 مورد آزمایش قرار گرفت. برای تعیین بهترین ترکیب از شاخص ریشه مربعات خطا، میانگین خطا و ضریب تبیین استفاده شد. نتایج نشان داد که تعداد نرون ۹،۸ و ۱۰ دارای بهترین ترکیب برای پیش بینی رس، شن و سیلت خاک می باشند. نتایج ریشه مربعات خطا برای جزء رس، شن و سیلت خاک به ترتیب ۰،۱۵۲، ۰،۲۰۱ و ۰،۲۲۳ به دست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰،۸۹۰، ۰،۹۰ و ۰،۹۰ به دست آمد که با نتایج بسیاری

برای دریافت رسوبات را نشان می دهند. 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 خاکسازی میباشد. جعفری و همکاران (۲۰۱۲) نیز در منطقه خشک اقدام به پیش بینی رقومی خاک کرده اند و شاخص خیزی را به عنوان پارامتر مهم برای مدل خود معرفی کردند. به طور مشابه مور و همکاران (۱۹۹۱) اهمیت شاخص خیزی را در نقشه برداری رقومی خاک در منطقه خود تایید کرده اند. نکته حائز اهمیت این است که تاثیر پارامترهای طیف سنجی انعکاسی بسیار نزدیک پارامترهای شاخص خیزی و MRVBF می باشد به طوری که برای رس طیف های ۸۷۹ و ۸۹۰ و برای شن ۸۵۲ و ۸۷۹ و برای سیلت طیف های ۱۴۵۶ و ۱۹۹۸ می باشند که بین ۳۴ تا ۴۰ درصد اهمیت رو به خود اختصاص داده اند و از آن جایی که با استفاده از تکنیک های سنجش از نزدیک می توان حجم زیادی از داده های مکانی خاک را به سهولت و با صرف هزینه و نیروی انسانی کمتر جمع آوری کرد، می توان پیشنهاد نمود در تحقیق های بعدی که از این پارامترها و طیف های مشخص آنها استفاده نمود.

### مدلسازی مکانی

نتایج مدل سازی مکانی به کمک تکنیک رگرسیون درختی: در روش رگرسیون درختی، مجموعه ای از شرط های منطقی به صورت یک الگوریتم با ساختار درختی برای پیش بینی ذرات خاک به کار می رود. نتایج پیش بینی نشان داد که ریشه مربعات خطا برای جزء رس، شن و سیلت ۰،۴۷، ۰،۱۴ و ۰،۵۲ به دست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰،۷۰، ۰،۶۸ و ۰،۶۳ به دست آمد که با نتایج برخی از پژوهشگران تطابق دارد از جمله: جعفری و همکاران (۲۰۱۲) در منطقه خشک اقدام به پیش بینی کلاسهای خاک از طریق مدل رگرسیون درختی کرده اند و شاخص خیزی و همواری دره با درجه تفکیک بالا را به عنوان پارامتر مهم برای مدل خود معرفی کردند. خیر و



داد که فازی عصبی دارای کارایی بالاتری نسبت به دو مدل دیگر بود. بسالت پور و همکارانش (۲۰۱۳) با استفاده از مدل ANFIS برای پیش بینی ثبات خاک مرطوب از چندین متغیر محیطی استفاده کردند و نتایج نشان داد که مدل های ANN و ANFIS با ضریب تبیین بالا، پتانسیل بسیار بالایی را در پیش بینی پایداری خاک با استفاده از ویژگی های خاک و محل نشان دادند، در حالی که روش های رگرسیون خطی خوب عمل نکردند. سی و همکاران (۲۰۱۲) عملکرد ANFIS و دو نوع ANN را برای پیش بینی محتوای آب مورد مطالعه قرار دادند و نتیجه گرفتند که مدل ANFIS دقیق تر است.

#### نتایج مقایسه مدل ها:

نتایج مربوط به نروفازی، شبکه عصبی و رگرسیون درختی متغیر های رس، شن و سیلت در جدول ۴ آورده شده است. با توجه به این جدول ملاحظه می شود که بهترین عملکرد در همه مدل ها برای پیش بینی درصد اندازه ای ذرات خاک مربوط به مدل نروفازی می باشد که از لحاظ هر سه متغیر رس، شن و سیلت بهتر از شبکه عصبی و رگرسیون درختی می باشد. بعد از مدل ANFIS مدل شبکه عصبی مصنوعی بهترین عملکرد را به خود اختصاص داده است. مقدار پایین RMSE برای اکثر مدل ها، پایین بودن خطا و دقت بالای مدل های برازش شده را نشان می دهد که همین طور که در جدول آمده مقدار RMSE در مدل نروفازی برای متغیر رس ۶.۷۱، برای شن ۸.۴۹ و برای سیلت ۵.۴۲ واحد کاهش داشته که نشان دهنده کارایی بهتر مدل نروفازی می باشد.

از دان شمدان تطابق دارد از جمله: سورش و همکاران (۲۰۰۹) کارایی بالای شبکه عصبی مصنوعی را در پیش بینی فرسایش خاک های تیمار شده با پلیمرهای مصنوعی کنترل فرسایش از قبیل پلی اتیلن را نشان دادند. زائو و همکاران (۲۰۰۹) از شبکه عصبی برای پیش بینی توزیع مکانی بافت خاک استفاده کردند. همچنین ای شان مدل خود را در منطقه ای مشابه آزمون کردند و نتایج قابل قبولی گرفتند.

نتایج مدل سازی مکانی به کمک تکنیک نروفازی: این مدل یک سیستم فازی را در یک ساختار عصبی اجرا می کند و برای فرآیند آموزش از ترکیبی از روش های آموزش پس انتشار خطا و حداقل مربعات خطا استفاده میکند. نتایج پیش بینی نشان داد، ریشه مربعات خطا برای جزء رس، شن و سیلت ۱.۹۸، ۱.۴۳ و ۲.۱۰۱ به دست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰.۹۱، ۰.۹۰ و ۰.۹۲ به دست آمد. محققین مختلف دیگری نیز کارایی زیاد مدل نروفازی را در نقشه برداری رقومی خاک تایید کرده اند. محمدی و طاهری (۲۰۰۵) برای ایجاد توابع انتقالی خاک، دو روش رگرسیون آماری و فازی را مقایسه کردند. نتایج نشان داد روش رگرسیون فازی در شرایطی که روابط بین متغیرها دارای ابهام است و، به طور کلی، در مواردی که با خطاهای ناشی از ابهام در ساختار معادلات رگرسیونی روبه روست، مکمل و یا جایگزین مناسبی برای روش رگرسیون آماری است. مک براتنی و اوده (۱۹۹۷) قابلیت منطق فازی را در علوم خاک، مانند نقشه برداری، ارزیابی، و مدل کردن فرایندهای فیزیکی، به خوبی نشان دادند. مقدم نیا و همکاران (۲۰۰۹) میزان تبخیر را با استفاده از چندین مدل تجربی، شبکه عصبی و ANFIS تخمین زدند و نتایج نشان



جدول ۴: نتایج مقایسه کارایی انواع مدل ها برای پیش بینی رس، شن و سیلت

مدل MODEL	ریشه مربعات خطا	ریشه مربعات خطا	ضریب تبیین	میانگین خطا
نروفازی Neuro-Fuzzy	رس ۱.۴۳ شن ۱.۹۸	رس ۲.۱ شن ۲.۱	رس ۰.۹۰ شن ۰.۹۱	رس ۰.۰۲ شن ۰.۰۶
شبکه عصبی مصنوعی ANN	رس ۱.۵۲ شن ۲.۰۱	رس ۲.۲۳ شن ۲.۲۳	رس ۰.۸۹ شن ۰.۹۰	رس ۰.۰۲ شن ۰.۰۶
رگرسیون درختی REGRESSION TREE	رس ۸.۱۴ شن ۱۰.۴۷	رس ۷.۵۲ شن ۷.۵۲	رس ۰.۶۸ شن ۰.۷۰	رس ۰.۰۴ شن ۰.۰۹

نتایج این بررسی نشان داد که در مورد مطالعه شده، شبکه عصبی مصنوعی نسبت به معادلات رگرسیونی کارایی بهتری داشته است. زیرا احتمالاً کارایی توابع انتقالی به دست آمده در مناطق مختلف با هم متفاوت است و همچنین می توان گفت در طراحی شبکه های عصبی نوع خاصی معادلات لازم نیست و با ایجاد ارتباط مناسب بین داده های ورودی و خروجی می توان به نتایج مناسب دست پیدا کرد و به علت وجود روابط غیر خطی میان متغیر های وابسته و پیش بینی شونده شبکه عصبی عملکرد بهتری نسبت به رگرسیون درختی داشته است. نتایج به دست آمده از این تحقیق با آنچه که زائو و همکاران (۲۰۰۹) در کشور چین بدست آورد هم خوانی دارد. ایشان توانستند با استفاده از شبکه عصبی مصنوعی، نقشه رقومی بافت خاک را با دقت کلی ۸۸٪ و کارایی بالا به دست بیاورند. پاچسکی و همکاران (۱۹۹۶) با استفاده از آمارهای ضریب هم بستگی و ریشه میانگین مربعات خطا به بررسی شبکه عصبی مصنوعی و رگرسیون درختی پرداختند. آنها به این نتیجه رسیدند که شبکه عصبی برآورد بهتر و خطای کمتری بر اساس داده های زود یافت خاک دارد. همان طور که می دانیم تمامی این روش ها بر پایه دقیق بودن متغیر های مورد مطالعه و مشاهدات مربوط به آنها استوار است و روابط بین متغیر ها نیز دقیق فرض می گردد. در صورتی که در سیستم های طبیعی مانند خاک، عموماً با مشاهدات یا روابط ناشناخته بین متغیر

ها رو به رو هستیم. در چنین شرایطی باید از مدل هایی بهره گرفت که قادر به ارائه الگوهای مناسبتر باشند، به گونه ای که بتوانند انطباق بیشتری با دنیای واقعی داشته باشند. به این ترتیب با توجه به ماهیت ابهامی پدیده های مرتبط با خاک یا تقریبی بودن مقادیر اندازه گیری شده ذرات خاک، به نظر می رسد کارایی بالاتر مدل مبتنی بر مجموعه های فازی در پردازش توابع انتقالی خاک به همین علت باشد. محمدی و طاهری (۲۰۰۵) نتیجه گرفتند که روش رگرسیون فازی در شرایطی که روابط ابهامی بین متغیر ها و به طور کلی در مواردی که با خطاهای ناشی از ابهام در ساختار معادلات رگرسیونی مطرح است، می تواند مکمل و یا جایگزین مناسبی برای روش رگرسیون آماری تلقی شود. در تحقیق حاضر نیز نتایج مشابهی بدست آمد. به طوری که شبکه عصبی مصنوعی در مقایسه با نروفازی کارایی کمتری در برآورد پارامتر های خاک داشت. مقدار RMSE محاسبه شده مدل نروفازی در مورد هر سه پارامتر رس، شن و سیلت کمتر از شبکه عصبی و رگرسیون می باشد که نشان دهنده دقت بالاتر این مدل در مقایسه با سایر مدل ها می باشد. البته نتایج نشان داد که در سطح ۵٪ تفاوت معنی داری بین نتایج شبکه عصبی مصنوعی و نروفازی وجود ندارد. اما در مقایسه مدل نروفازی نسبت به مدل رگرسیون درختی مقدار RMSE برای متغیر رس ۶.۷۱، برای شن ۸.۴۹ و برای سیلت ۵.۴۲ واحد کاهش داشته که نشان دهنده



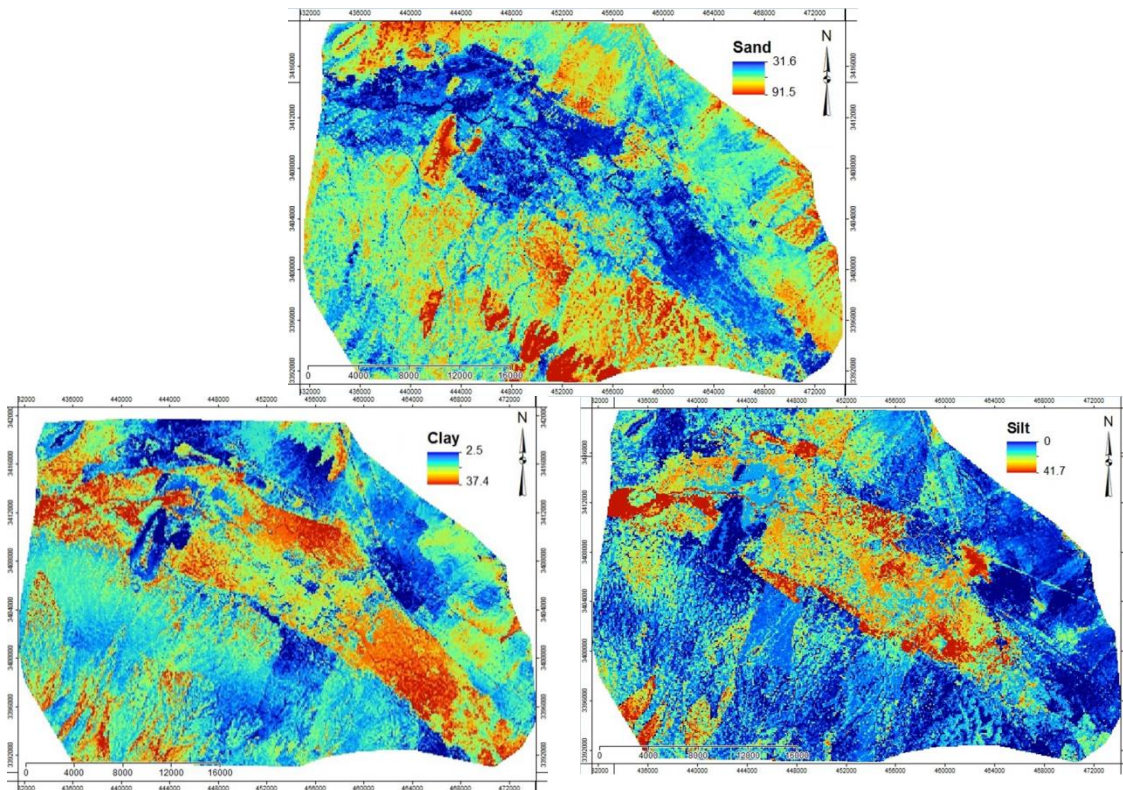
و کمترین انرژی در زمین‌های کوه و تپه‌های ماسه‌ای مشاهده می‌شود. براساس اصول محاسبه تنوع جهانی، وجود رابطه بین شاخص‌های تنوع و متغیرهای محیطی منطقی و امکان‌پذیر است. براین اساس بیشترین همبستگی بین شاخص خیسی و شاخص‌های تنوع مشاهده شد.

همچنین وجود ارتباط قوی بین داده خاک و پارامترهای محیطی نیز یکی از فاکتورهای تاثیرگذار بر روی دقت مدل می‌باشد. به طور کلی نتایج نشان داد که تکنیک‌های پدومتری بخصوص شبکه عصبی و انفیس می‌توانند فرآیند نقشه برداری 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 شبکه عصبی و نروفازی و از داده‌های کمکی تصاویر سنجش از نزدیک در مطالعات آینده استفاده شود.


کارایی بهتر مدل نروفازی می‌باشد. در نهایت نقشه‌های رقومی ذرات رس، شن و سیلت (شکل ۶) و نقشه نهایی بافت خاک با استفاده از مدل نروفازی تهیه شد (شکل ۷).

#### نتیجه‌گیری

نتایج مقایسه مدل‌های نروفازی، شبکه عصبی مصنوعی و رگرسیون درختی برای پیش‌بینی درصد ذرات رس، شن و سیلت نشان داد که مدل نروفازی دارای کارایی بالاتری در پیش‌بینی هر یک از ذرات رس، شن و سیلت می‌باشد و بعد از آن شبکه عصبی مصنوعی نسبت به رگرسیون درختی کارایی بهتر داشت. نتایج همچنین نشان داد که مهم‌ترین متغیرهای کمکی طیف سنجی انعکاسی، شاخص خیسی و MRVBF می‌باشند که از آن جایی که با استفاده از تکنیک‌های سنجش از نزدیک می‌توان حجم زیادی از داده‌های مکانی خاک را به سهولت و با صرف هزینه و نیروی انسانی کمتر جمع‌آوری کرد، می‌توان پیشنهاد نمود در تحقیق‌های بعدی که از این پارامترها و طیف‌های مشخص آنها استفاده نمود. نتایج حاصل از تنوع محلی و جهانی نشان داد که بیشترین انرژی در لندفرم‌های پلایا، باهادای بریده، باهادای قدیمی



شکل (۶): نقشه های پیش بینی ذرات خاک با استفاده از مدل نرو فازی



شکل ۷: نقشه پیش بینی بافت خاک

منابع:

Akpa, S. I. C., I. O. A. Odeh and T.F. A. Bishop . 2014. Digital mapping of soil particle-size fractions for Nigeria. Soil Science Society of America Journal. 78: 1953-1966.



Besalatpour, A.A., S. Ayoubi, M.A. Hajabbasi, M.R. Mosaddeghi, R. Schulin. 2013. Estimating wet soil aggregate stability from easily available properties in a highly mountainous watershed. *Catena*. 111: 72-79.

Jafari, A., P.A. Finke, J.V. de Wauw, S. Ayoubi, and H. Khademi. 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. *E. J. Soil Sci.* 63: 284-298.

Kheir, R.B., M.H. Greve, C. Abdallah, and T. Dalgaard. 2010. Spatial soil zinc content distribution from terrain parameters: A GIS-based decision-tree model in Lebanon. *Environ. Poll.* 158:520-528.

Lie, M., B. Glaser, and B. Huwe. 2012. Uncertainty in the spatial prediction of soil texture: comparison of regression tree and random forest models. *Geoderma*. 170: 70-79.

McBratney, A.B., M.L.M. Santos, and B. Minasny. 2003. On digital soil mapping. *Geoderma*. 117: 3-52.

Moghaddamnia, A., M. Ghafari Gousheh, J. Piri, S. Amin, and D. Han. 2009. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*. 32(6): 88-97.

Mohammadi, J. and M. Taheri. 2005. Estimation of pedotransfer function using fuzzy regression. *J. Agri. Sci. Tech.* 2: 51-60.

Moonjun, R., A. Farshad, D.P. Shrestha, and C. Vaiphasa. 2010. Artificial Neural Network and Decision Tree in Predictive Soil Mapping of Hoi NumRin Sub-Watershed, Thailand. *Digital Soil Mapping. Pro. Soil Sci.* 2: 151-164.

Minasny, B., and A.E. Hartemink. 2011. Predicting soil properties in the tropics. *Earth Science Review*. 106: 52-62.

Pachepsky, Y. A., D. Timilin, and G. Varallyay. 1996. Artificial neural networks to estimate soil water retention from easily measurable data. *J. Soil Sci. Soc. Am.* 60: 727-733.

Si, Jianhua., Feng, Qi., Wen, Xiaohu., Xi, Haiyang., Yu, Tengfei., Li, Wei., Zhao, Chunyan. 2015. Modeling soil water content in extreme arid area using an adaptive neuro-fuzzy inference system. *J. Hydrology*. 527, 679-687.

Suresh, A., A.P. Harsha, and M.K. Ghosh. 2009. Solid particle erosion studies on polyphenylene sulfide composites and prediction on erosion data using artificial neural networks. *Wear*. 266:184-193.

Taghizadeh Mehrjardi R., B. Minasny, F. Sarmadian, and P.B. Malone. 2014. Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma*. 213: 15-28.



Thompson, J. A., S. Roecker, S. Grunwald, and P.R. Owens. 2012. Digital soil mapping: Interactions with and applications for hydropedology. In: H. Lin, ed. Hydropedology. pp. 665-709. Amsterdam: Academic Press.

Zhao, Z., T.L. Chow, H.W. Rees, Q. Yang, Z. Xing, and F. Meng. 2009. Predict soil texture distributions using an artificial neural network model. Com. Elec. Agr. 65: 36-48.



## Investigating the effect of Wetness index and spectral data on the estimation of soil particles percentage using neuro-fuzzy, artificial neural network and regression tree models

Elham Mehrabi Gohari<sup>1</sup>, Hamidreza Matinfar<sup>2</sup>, Rohollah Taghizade Mehrjardi<sup>3</sup>, Azam Jafari<sup>4</sup>

### Abstract

Direct estimation of some soil characteristics is time consuming, costly and sometimes not possible. In recent years, indirect methods have been used to estimate these properties. In the present study, to predict the soil texture fractions, 115 profiles were identified based on the Hypercube technique, and the horizons were sampled and the percentage of sand, clay and silt of soil samples were measured. Environmental variables used in this study include the terrain attributes (derived from a digital elevation model), Landsat 8 image data (acquired in 2015), geomorphological map, and spectrometric data (laboratory data). Artificial neural network, regression tree and neuro-fuzzy models were used to make a correlation between soil data (clay, sand and silt) and environmental variables. The results of this study showed that the neuro-fuzzy model was more accurate in prediction of the three parameters of clay, sand and silt than artificial neural network and tree regression. The RMSE value in the neuro fuzzy model was compared to regression tree model. The neuro fuzzy model results were, for clay surface 1.43 %, for sand surface 1.98% and for silt surface 2.1% that reduced by 6.71%, 8.49% and 5.42% for clay, sand and silt respectively, compared to regression tree model. The results also showed that the most important auxiliary variables are spectrometric data followed by MrVBF and wetness index.

**Keywords:** Wetness Index, VIS\_NIR, Artificial Neural Network, Tree Regression, Neuro-Fuzzy

---

<sup>1</sup>- Faculty, Department of Agriculture, Payame Noor University and Department of Soil Science, College of Agriculture, Lorestan University, Lorestan, Iran . Email: elham.mehrabi1@yahoo.com

<sup>2</sup>- Department of Soil Science, College of Agriculture, Lorestan University, Lorestan, Iran. Email: matinfar.h@lu.ac.ir. Corresponding Author.

<sup>3</sup> - Faculty of Agriculture and Natural Resources, Ardakan University, P.O. Box 89516-56767, Yazd, Iran. Email: rtaghizadeh@ardakan.ac.ir

<sup>4</sup> - Department of Soil Science, Agriculture Faculty, Shahid Bahonar University of Kerman, Kerman, 76169-14111, Iran. Email: a.jafari@uk.ac.ir