

مقاله علمی-پژوهشی

## قابلیت طیف‌سنجی مرئی-مادون قرمز نزدیک (VIS-NIR) در پیش‌بینی درصد ذرات خاک با استفاده از شبکه عصبی مصنوعی و رگرسیون حداقل مربعات جزئی

الهام مهرابی گوهری<sup>۱</sup> - حمید رضا متین فر<sup>۲\*</sup> - روح الله تقی زاده مهرجردی<sup>۳</sup> - اعظم جعفری<sup>۴</sup>

تاریخ دریافت: ۱۳۹۸/۰۳/۲۲

تاریخ پذیرش: ۱۳۹۸/۱۱/۰۲

### چکیده

طیف‌سنجی مرئی و مادون قرمز نزدیک (VIS-NIR) به طور گسترده‌ای برای تخمین خصوصیات فیزیکی خاک و اخیراً برآورد بافت خاک استفاده می‌شود. مطالعه حاضر با هدف پیش‌بینی احتمالی بافت خاک با استفاده از اندازه‌گیری‌های طیفی و مدل‌های شبکه عصبی مصنوعی و رگرسیون حداقل مربعات جزئی انجام گرفته است. بر اساس تکنیک هایپرکیوب، محل ۱۱۵ پروفیل شناسایی و سپس نمونه‌برداری از افق‌های خاک انجام گرفت، درصد شن و رس و سیلت نمونه‌های خاک اندازه‌گیری شد. رگرسیون حداقل مربعات جزئی (PLSR) و شبکه عصبی مصنوعی (ANN) برای مدل‌سازی درصد رس، شن و سیلت خاک مقایسه شدند. نتایج این بررسی نشان داد که شبکه عصبی مصنوعی نسبت به رگرسیون حداقل مربعات جزئی کارایی بهتری داشت، برای هر دو مدل از محدوده خاصی از طول موج (بین ۴۰۰-۲۴۵۰ میکرون با اعمال پیش‌پردازش‌ها و حذفیات یکسان) استفاده گردید. هنگامی که مدل رگرسیون مربعات جزئی اجرا شد، دقت بسیار پایینی داشت ( $R^2 \sim 0.1-0.3$ )، در مقابل، روش شبکه عصبی-مصنوعی مقدار  $R^2$  به ترتیب برای رس، شن و سیلت ۰/۷۰، ۰/۷۶ و ۰/۷۳ بود و میانگین ریشه مربعات خطا به ترتیب ۹/۱۴، ۵/۵۴ و ۷/۰۱ گرم بر کیلوگرم براساس داده‌های آزمون (۲۰ درصد) به دست آمد که نشان دهنده دقت بالاتر و خطای کمتر مدل شبکه عصبی-مصنوعی می‌باشد. از آنجایی که رابطه بین درصد ذرات خاک و بازتاب طیفی خاک خطی نیست، به نظر می‌رسد روش شبکه عصبی-مصنوعی برای بررسی و تجزیه و تحلیل رابطه بین اجزای بافت خاک و داده‌های طیفی مناسب باشد.

**واژه‌های کلیدی:** پیش‌بینی، رگرسیون حداقل مربعات جزئی، شبکه عصبی مصنوعی، طیف‌سنجی مرئی، مادون قرمز، مدل‌سازی

### مقدمه

اکولوژیکی، هیدرولیکی، اقلیمی و دیگر مدل‌های زیست‌محیطی شناخته شده‌اند. همچنین، نیاز مبرمی برای تعیین و تخمین دقیق روابط بین هر یک از اجزای بافت خاک با پارامترهای کلیدی زیست محیطی (همچون اقلیم، توپوگرافی، مواد مادری، و ...) جهت بهبود مدیریت پایدار، اقتصادی و مکانی احساس می‌شود (۶). از دیگر سو اجزای بافت خاک پایه و بنیان مدل‌های تخمین زنده محیطی و نقشه‌برداری رقومی خاک است (۹). از سویی خاک‌ها مستعد تغییرپذیری زمانی و مکانی معنی‌داری‌اند که تشخیص پهنه‌بندی و پایش آنها با روش‌های نمونه‌برداری سنتی و تحلیل آزمایشگاهی معمول بسیار هزینه بر و وقت‌گیر است. در نتیجه، توسعه روش‌هایی که برای تحلیل و بررسی خاک و جمع‌آوری اطلاعات آن از هر نظر به صرفه باشد، به اولویت تبدیل شده است (۲۸).

یکی از شیوه‌های موثر در تجزیه و تحلیل خاک و کاربردهای آن طیف‌سنجی مرئی-مادون قرمز است. این روش روشی ساده و تحلیلی است که از آن می‌توان برای افزایش یا جایگزین نمودن روش‌های عادی تحلیل خاک استفاده کرد. این روش برای غلبه بر برخی از

بافت خاک مهم‌ترین متغیر محیطی است زیرا در قابلیت اراضی و فرایندهای انتقال آب، کنترل کیفیت خاک و حاصلخیزی آن نقش بسیار مهمی دارد. همچنین در بسیاری از خصوصیات فیزیکی و شیمیایی خاک و نیز رفتارهایی همچون ظرفیت نگهداری آب و عناصر غذایی خاک، هدایت هیدرولیکی، شکنندگی و مقاومت خاک به عملیات کاشت نیز اثرگذار است. از سویی اطلاعات توزیع مکانی و تغییرپذیری اجزای بافت خاک به منزله پارامتر ورودی به مدل‌های

۱- استادیار، گروه کشاورزی، دانشگاه پیام نور و دانش آموخته دکتری علوم خاک دانشگاه لرستان

۲- دانشیار، گروه علوم خاک، دانشکده کشاورزی، دانشگاه لرستان  
(Email: matinfar.h@lu.ac.ir) \*نویسنده مسئول:

۳- دانشیار، گروه علوم خاک، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان

۴- استادیار، گروه علوم خاک، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان  
DOI: 10.22067/v34i2.80806

همچنین کوآنگ و همکاران (۱۴) بیان داشته‌اند که اجزای رسی را به دلیل پاسخ طیفی مستقیم کانی‌های رسی در دامنه طیفی حدود ۲۲۰۰-۲۳۰۰ نانومتر می‌توان سنجش و آشکارسازی کرد. البته استنبرگ و همکاران (۲۲) اخطار داده‌اند که موقعیت این باندهای جذبی ممکن است بر اساس ترکیبات آنها فرق کند.

برای مدل‌سازی روابط پیچیده بین نشانه‌های طیفی و نیز مشخصات خاک، روش‌های رگرسیون چند گانه نسبت به روابط ساده دو متغیری برتری دارند (۲۱). رگرسیون حداقل مربعات جزئی شایع ترین روش در حال حاضر برای مدل‌سازی روابط میان شدت طیفی مادون قرمز اجزای خاک و خواص خاک از طریق بارگذاری‌ها، نمرات و ضرایب رگرسیون مشتق شده از حداقل مربعات جزئی می‌باشد (۱۱). اگرچه این روش به عنوان روش رگرسیون خطی است، اما به مشخصه‌ای بنام غیر خطی بودن، توسط فاکتورهای اضافی  $PLSR^2$  یا تابع پیش پردازش غیر خطی نسبت داده می‌شود (۱۱). رگرسیون حداقل مربعات جزئی مجموعه‌ای از اجزاء یا بردارهای پنهان را پیدا می‌کند که به طور همزمان کاهش یا تجزیه‌ی  $X$  و  $Y$  را به وجود می‌آورد به طوری که این مولفه‌ها تا حد ممکن کوواریانس بین  $X$  و  $Y$  را توضیح می‌دهد (۲۶). یکی از مزایای رگرسیون حداقل مربعات جزئی در مقایسه با سایر روش‌ها، مانند تحلیل رگرسیون مولفه اصلی، امکان تفسیر برخی از متغیرهای پنهان اول است، زیرا آنها ارتباطات بین مقادیر ویژگی‌های اندازه‌گیری شده و ویژگی‌های طیفی را نشان می‌دهند. بلیناسو و همکارانش (۲) در سال ۲۰۱۰ پی بردند که تحلیل مولفه‌ی اصلی، خاک‌های ناشی از مواد مشابه اصلی را با برخی تمایزات بر اساس دامنه و ارتفاع دسته‌بندی می‌کند. محققان مختلفی نشان دادند که رگرسیون حداقل مربعات جزئی می‌تواند با عملکرد بالایی مدل‌سازی را ارائه دهد (۲۴). این روش در خاک، برای بررسی خواص متفاوت مربوط به مقدار رطوبت و ماده آلی، از جمله مقدار کربن و نیتروژن و یا ظرفیت تبادل کاتیونی بکار می‌رود (۲۰). این روش در ایران توسط خیامیم و همکاران (۱۲) برای برآورد مقدار ماده آلی، کربنات و گچ خاک‌های سطحی اصفهان استفاده شده است. تحقیقات نشان داده است که در گستره مرئی و مادون قرمز نزدیک (VIS-NIR)، طول موج ۴۰۰ تا ۳۰۰۰ نانومتر) و مادون قرمز میانی (MIR)، طول موج ۳۰۰۰ تا ۳۰۰۰۰ نانومتر) می‌توان مقدار ماده آلی خاک را مورد مطالعه قرار داد (۵). سامرس و همکاران (۲۳) با بررسی ۳۰۰ نمونه خاک در منطقه جنوب استرالیا به ارزیابی روش طیف سنجی مرئی مادون قرمز نزدیک در برآورد کربن آلی، مقدار رس، اکسیدهای آهن و کربنات‌های خاک پرداختند. آنها نتیجه گرفتند که ضریب تبیین برای درصد رس، کربن آلی، اکسید آهن و کربنات‌های

محدودیت‌های روش‌های عادی آزمایشی، موثر است و ممکن است برای پیش‌بینی مشخصات متعدد خاک استفاده شود (۷). طیف‌سنجی مرئی-مادون قرمز به عنوان روشی موثر برای تحلیل خصوصیات خاک توسط کاربران است و نشان داده شده است که این روش، اشاره به داده‌های دقیقی در مورد مشخصات شیمیایی و فیزیکی خاک دارد که برای نقشه‌برداری رقومی خاک، مفید می‌باشند (۱۳). اگرچه طیف سنجی مرئی-مادون قرمز، نمونه‌برداری سریع و مقرون به صرفه و دقیق را تامین یا ممکن می‌سازد، اما محققان به برخی از کاستی‌هایی پرداخته‌اند که در ارتباط با بی‌ثباتی استفاده از وسایل در شرایط محیطی مانند نور، دما و غیره، کالیبراسیون در بین ابزارهای مختلف، مشکلات مرتبط به مقیاس یا سنجش مدل در سطوح جهانی، قاره‌ای، منطقه‌ای، کشوری، محلی و میدانی در برابر دقت و دیگر مسائل است (۲۱).

معمولاً سنجش و بررسی پارامترهای خاک با استفاده از فناوری‌های ابر طیفی (اعم از آزمایشگاهی یا سیار، زمینی یا هوایی/فضایی) بر مبنای رفتارها و علائم طیفی است که خاک‌ها از خود نشان می‌دهند. روی هم رفته رفتارهای طیفی خاک و بالطبع منحنی‌های بازتابی طیفی خاک از کروموفورهای<sup>۱</sup> خاک (عوامل فعال رنگی / طیفی) تاثیر می‌پذیرد. بر این اساس کروموفورهای خاک که در واقع عوامل فعال اثرگذار در رفتارهای طیفی خاک به شمار می‌آیند به دو دسته تقسیم می‌شوند: شیمیایی و فیزیکی (۴). کروموفورهای شیمیایی شامل آن موادی‌اند که تابش ورودی را در سطوح انرژی مجزا جذب می‌کنند. به طوری که همه پدیده‌ها در دامنه طیفی مرئی-مادون قرمز علائم طیفی مشخصی دارند. در خاک‌ها سه کروموفور شیمیایی غالب شناخته شده‌اند: ۱- کانی‌ها (غالباً شامل رس، اکسیدهای آهن، کانی‌های اولیه فلدسپار، نمک‌ها و مواد مقاوم به حل شدن، همچون کربنات‌ها و فسفات‌ها) ۲- مواد آلی (تازه و یا تجزیه شده) ۳- آب (جامد، مایع و گاز). کروموفورهای فیزیکی خصوصیات هستند که در کل دامنه طیفی و نیز موقعیت باندهای ویژه اثرگذارند. نمونه‌هایی از این نوع کروموفورها شامل تغییرات اندازه ذرات خاک (بافت) و شاخص‌های انکساری مواد است که از یک شرایط تابشی به شرایط دیگر تغییر می‌کنند (۴). اجزای بافت خاک از نظر دانش طیف سنجی حد واسط کروموفورهای فیزیکی و شیمیایی به حساب می‌آید که باید بیشتر آن را مطالعه کرد. بر این اساس توانایی و قابلیت برآورد مقادیر اجزای رسی با استفاده از دورسنجی مادون قرمز نزدیک نیز مورد بررسی قرار گرفته است. طبق نظر استنبرگ و همکاران (۲۲) جزء رس از مهم‌ترین اجزای بافتی خاک است که پدیده‌های جذبی قابل تشخیصی در طول موج‌های مرئی و مادون قرمز نزدیک دارد.

2- Partial Last square regression

1- Soil Chromophores

می‌باشد. متوسط سالانه بارندگی، درجه حرارت و تبخیر و تعرق به ترتیب ۶۱ میلی‌متر، ۱۷ درجه سانتی‌گراد و ۱۷۵۰ میلی‌متر می‌باشد (۱). در منطقه مورد مطالعه بر اساس تکنیک هایپرکیوب، محل ۱۱۵ پروفیل شناسایی و سپس نمونه‌برداری از افق‌ها 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 یادداشت‌برداری و از افق‌های هر پروفیل نمونه‌برداری شد. سپس در کلیه نمونه‌های سطحی خاک پس از هوا خشک شدن و عبور از الک ۲ میلی‌متری بافت خاک به روش هیدرومتری، اندازه‌گیری شد.

### آنالیز طیفی

به منظور اندازه‌گیری بازتاب طیفی نمونه‌های خاک، از دستگاه اسپکترو رادیومتر زمینی<sup>۱</sup> استفاده شد. نمونه‌های خاک برای کاهش آثار مزاحم رطوبت و تداخل ساختاری خاک در رفتار طیفی نمونه‌ها هوا خشک و الک شدند و سپس در یک پتری‌دیش به قطر تقریبی ده سانتی‌متر قرار گرفتند و با کاردک سطح آن‌ها هموار شد و سپس جهت بررسی‌های طیفی به اتاق تاریک منتقل شدند. هر نمونه چهار بار (به ازای هر چرخش نود درجه‌ای متوالی) برای حذف آثار تغییر در هندسه تابش مورد سنجش طیفی قرار گرفت. هندسه تابش قادر است در تابع توزیع بازتاب دو جهته اثر بگذارد بنابراین لازم است که آثار تغییر هندسه تابش بر بازتاب‌های سنجش شده به کمترین میزان برسد. پیش از آغاز نمونه‌برداری طیفی از گزینه جریان تاریک برای افزایش نسبت سیگنال به نویز و نیز از مرجع سفید اسپکترون به طور تقریب به ازای هر نیم ساعت نمونه‌برداری طیفی برای کالیبره کردن انعکاس طیفی بهره برده شد. بدین طریق، نمونه‌های خاک اسکن شد و بازتاب‌های مطلق در دامنه طیفی ۲۵۰۰-۳۵۰ نانومتر و با قدرت تفکیک طیفی یک نانومتر سبب تولید ۲۱۵۰ نقطه داده طیفی به ازای هر نمونه خاک شد. منحنی‌های به دست آمده بلافاصله و به طور خودکار با استفاده از نرم‌افزار RS3 موجود بر روی رایانه قابل حمل متصل به دستگاه میانگین‌گیری شده و به صورت یک منحنی طیفی به نمایش در آمد. برای هر نمونه ۵ تکرار ثبت گردید.

### تحلیل آماری-طیفی

جهت ساخت مدل مناسب برای پیش‌بینی درصد رس، شن و سیلت خاک روش کمترین مربعات جزئی با تعداد فاکتور ۱ تا ۱۰ با استفاده از نرم‌افزار آن اسکرمل<sup>۲</sup> و مدل‌سازی روش شبکه عصبی مصنوعی (ANN) با استفاده از نرم‌افزار JMP به کار گرفته شد.

خاک به ترتیب ۰/۶۶، ۰/۵۷، ۰/۶۱ و ۰/۶۹ می‌باشد و مقادیر RMSE نیز به ترتیب ۳/۱۳، ۰/۳۵، ۰/۲۳ و ۲/۹ درصد گزارش شده است (۲۳). با این حال، محققان دیگر گزارش دادند که سایر تکنیک‌های مدل‌سازی، مانند شبکه عصبی-مصنوعی، می‌توانند دقت پیش‌بینی بیشتری را نسبت به رگرسیون حداقل مربعات جزئی ارائه دهند (۱۳). روش شبکه عصبی-مصنوعی می‌تواند برای حل و بررسی واکنش‌های طیفی غیر خطی نسبت به رگرسیون حداقل مربعات جزئی موثرتر باشد و به عنوان روشی با دسترسی به دقت زیاد پیش‌بینی تعریف شده است (۲۶). زائو و همکاران (۲۷) از شبکه عصبی برای پیش‌بینی توزیع مکانی بافت خاک استفاده کردند. همچنین ایشان مدل خود را در منطقه‌ای مشابه آزمون کردند و نتایج قابل قبولی گرفتند. زو و همکاران (۲۹) نشان دادند که استفاده از شبکه عصبی مصنوعی کارایی بالاتری نسبت به رگرسیون خطی چند متغیره و مدل‌هایی با رابطه توانی در پیش‌بینی غلظت رسوب دارد. موازن و همکاران (۱۶) به این نتیجه رسیدند که بهترین دقت پیش‌بینی برای درصد کربن آلی خاک با شبکه عصبی-مصنوعی بر اساس داده‌هایی در مورد متغیرهای پنهان رگرسیون حداقل مربعات جزئی کسب شده است. تاکنون مطالعه‌ای برای مقایسه روش رگرسیون حداقل مربعات جزئی و روش شبکه عصبی-مصنوعی برای بررسی تخمین بافت خاک صورت نگرفته است. فرضیه‌ی این مطالعه این است که شبکه عصبی-مصنوعی نتایج موثری را برای پیش‌بینی درصد رس، شن و سیلت خاک ارائه می‌دهد. هدف این مطالعه مقایسه نمودن روش‌های رگرسیون حداقل مربعات جزئی و شبکه عصبی-مصنوعی برای مدل‌سازی داده‌های طیفی در برآورد درصد ذرات رس، شن و سیلت می‌باشد.

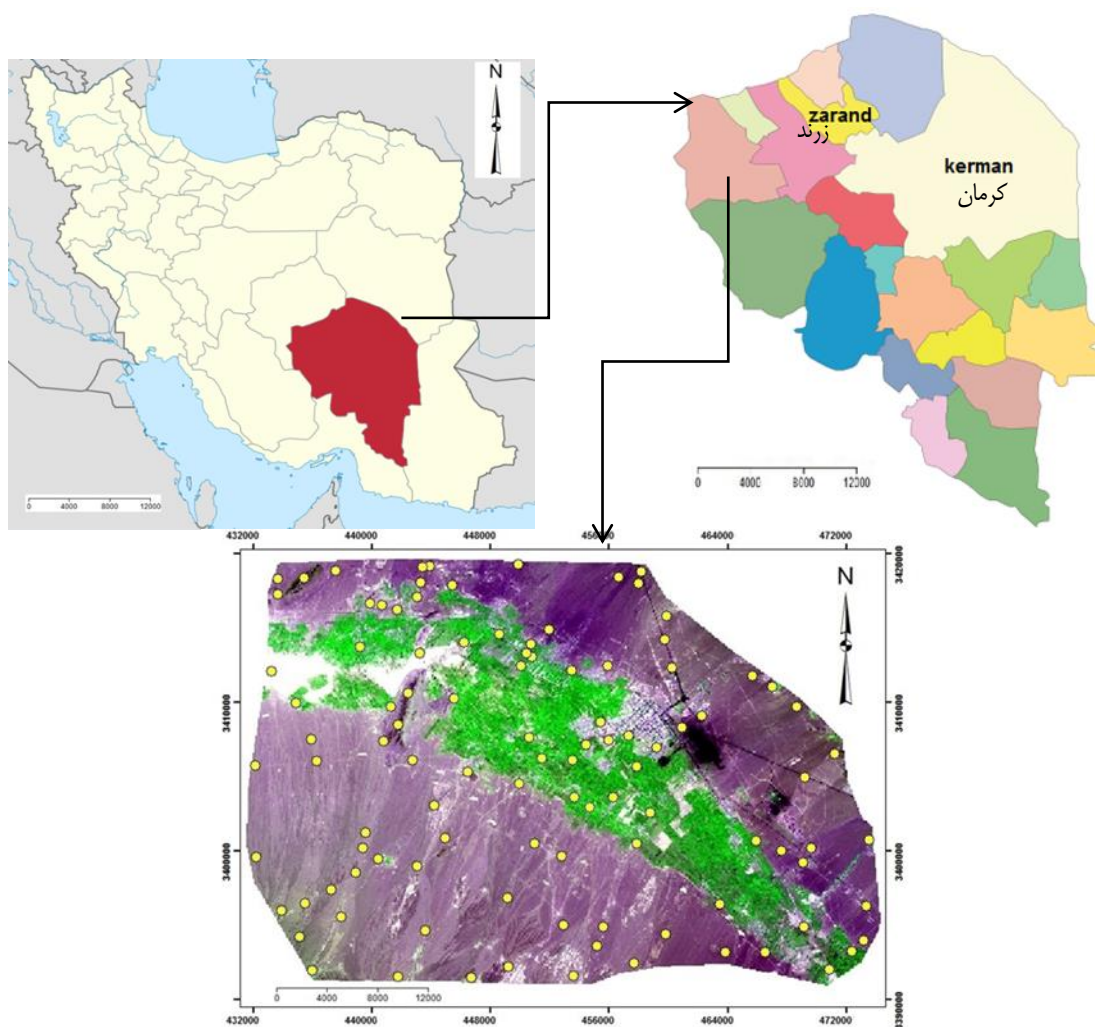
### مواد و روش‌ها

#### تشریح محدوده مطالعاتی

منطقه مورد مطالعه در جنوب شرق ایران، تقریباً در فاصله ۷۰ کیلومتری شهر کرمان بین عرض جغرافیایی ۳۰° ۴۰' تا ۳۱° ۰۰' درجه شمالی و طول جغرافیایی ۱۰° ۵۶' تا ۵۶° ۵۰' درجه شرقی قرار گرفته است. این منطقه مساحتی حدود ۱۰۰۰۰۰ هکتار را می‌پوشاند و شهرستان زرنند را نیز در بر می‌گیرد. 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 هم‌مرز 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 کرده‌اند. لندفرم‌های اصلی این منطقه شامل مخروط‌افکنه‌های قدیمی و جدید، سطوح رسی (دق) و تپه‌های شنی

1- FieldSpec@3, ASD, FR, USA

2- Unscrambler



شکل ۱- موقعیت منطقه مورد مطالعاتی و نحوه پراکنش مکانی داده های خاک  
 Figure 1. Location of study area and selected site.

متغیرهای طیفی تخمینگر (X) می شود و تا آنجا که امکان دارد سبب همبستگی بین متغیرهای پاسخ (Y) با متغیرهای مستقل (X) می شود (۲۳). اگر چه رگرسیون حداقل مربعات جزئی دارای مزایای بسیار مانند سادگی، اطمینان، قابلیت پیش بینی، دقت و توضیحات کمی آشکار و واضح است، اما ضعف اصلی این مدل این است که رابطه بین متغیرهای پیش بینی کننده و متغیرهای پاسخ را به خوبی بیان نمی کند و مجدداً از الگوریتم های مدل بین ابزارهای مختلف استفاده نمی کند (۱۵). در مقابل روش شبکه عصبی-مصنوعی به طور معمول در لایه ها سازماندهی شده است و این لایه ها از تعدادی گره های متصل شده تشکیل شده اند که دارای یک تابع فعال هستند (۱۵). در این تحقیق شبکه عصبی مصنوعی پرسپترون با یک لایه مخفی که 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 متغیر بوده

PLSR (رگرسیون حداقل مربعات جزئی) از معمول ترین روش های آماری سنجی چند متغیره است که با هدف کالیبراسیون طیفی و تخمین خصوصیات خاک به کار برده می شود (۸). رگرسیون حداقل مربعات جزئی سبب استخراج ترکیبات خطی متوالی از تخمینگرها می شود که تغییرات پاسخ و تغییرات تخمینگر را هم زمان مورد بررسی مطلوب قرار می دهد (۹). افزون بر آن روشی است که از طریق بهره گیری از تکنیک تحلیل مولفه های اصلی (PCA) و رگرسیون خطی چند گانه (MLR)، بر مشکلات چند هم خطی گری و خود همبستگی بین متغیرهای طیفی و نمونه ها غلبه می کند و مجموعه ای از اجزا یا بردارهای پنهان را می یابد که سبب کاهش و یا تجربه ماتریس

#### 1- Multiple Linear Regression

توان در دو رده اریدی سول و انتی سول طبقه‌بندی کرد.

### ویژگی‌های طیف‌های خاک

شکل ۲-الف طیف انعکاسی محدوده مرئی-مادون قرمز نزدیک اندازه‌گیری شده در ده نمونه خاک را نشان می‌دهد. شکل کلی همه طیف‌ها در همه خاک‌ها تقریباً مشابه است، به طوری که ویژگی‌های جذبی آب و رس در همه طیف‌ها مشاهده می‌شود، البته اختلافاتی در میزان شدت انعکاس وجود دارد. ویژگی جذبی آب در ۱۴۰۰ و ۱۹۰۰ نانومتر به علت فرکانس ارتعاشات پایه مولکول آب شامل کشش متقارن و نامتقارن پیوند H-O و خمش O-H مشاهده می‌شود. ویژگی جذبی رس در ۲۲۰۰ نانومتر می‌باشد. کانی‌های خاک نور را در ناحیه‌های مرئی-مادون قرمز نزدیک و میانی جذب می‌کنند. پاسخ طیفی کانی‌های رسی در نتیجه ارتعاش مولکول‌های آب ساختمانی، گروه‌های هیدروکسیل، چارچوب سیلیکات و کاتیون‌های اکسیدرال، تتراهدرال و بین لایه‌ای است. اکسیدهای آهن در محدوده مرئی و کربنات‌ها در ۲۳۰۰ نانومتر قابل مشاهده هستند. مقادیر انعکاس از طریق رابطه (۳) به جذب تبدیل شد. در رابطه (۳) A و R به ترتیب مقادیر جذب و انعکاس بر حسب درصد را نشان می‌دهند. شکل ۲-ب نمودارهای جذب طیف مرئی-مادون قرمز ده نمونه خاک را نشان می‌دهد.

$$A = \log(1/R) \quad (3)$$

### عملیات پیش پردازش طیفی

به دلیل این که هنگام اندازه‌گیری‌های طیفی و به ویژه در صحرا این اندازه‌گیری‌ها تحت تأثیر عوامل ناخواسته مثل رطوبت خاک، زبری سطح خاک، بقایای آلی درشت، آلودگی پروب به علت گرد و غبار، تغییر فاصله حسگر و خاک و تأثیرات پرتوافکنی جوی قرار می‌گیرند، پیش‌پردازش داده‌های طیفی نقش مؤثری در بهبود کالیبراسیون دارد (۱۸).

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 لونیبرگ مارکوارت استفاده شد.

### اعتبارسنجی مدل‌ها

پارامترهایی که در این تحقیق برای اعتبارسنجی مدل استفاده شد (۱) ریشه میانگین مربعات خطای پیش‌بینی می‌باشد که این مقدار از رابطه RMSE به دست می‌آید. (۲) ضریب تبیین  $R^2$  بین مقادیر اندازه‌گیری شده توسط روش‌های آزمایشگاهی و پیش‌بینی شده توسط مدل می‌باشد. لازم به توضیح است که برای پیش‌بینی، داده‌ها به دو دسته آموزش (۸۰ درصد از داده‌های نمونه‌برداری شده) و آزمون (۲۰ درصد از داده‌های نمونه‌برداری شده) به طور تصادفی تقسیم شدند.

$$R^2 = \frac{\left[ \sum \left( (X_e - \bar{X}_e)(X_o - \bar{X}_o) \right) \right]^2}{\sqrt{\left( \sum (X_e - \bar{X}_e)^2 \right) \left( \sum (X_o - \bar{X}_o)^2 \right)}} \quad (1)$$

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

$\bar{X}_o$ : میانگین متغیرهای کمی مشاهده شده،  $\bar{X}_e$ : میانگین متغیرهای کمی برآورد شده و n تعداد داده‌ها می‌باشد.

### نتایج و بحث


#### خلاصه آماری داده‌ها

در جدول ۱ خلاصه آماری رس، سیلت و شن خاک‌های تحت مطالعه آمده است. مجموعه عوامل سطوح مختلف ژئومورفیک و سطح آب زیرزمینی باعث تمایز و تفکیک خاک‌ها گردیده است که آنها را می

جدول ۱- پارامترهای آماری مربوط به خصوصیات شن، رس و سیلت

Table 1- Statistical parameters related to the characteristics of sand, clay and silt

انحراف استاندارد Standard deviation	متوسط Average	حداکثر Max	حداقل Min	درصد ذرات Particle size distribution (%)
8.91	18.59	42.65	3.00	رس (Clay)
15.13	64.10	94.88	27.97	شن (Sand)
9.58	17.26	42.15	2.00	سیلت (Silt)



شکل ۲- مقادیر انعکاس الف، ب (جذب و ج) مشتق اول، طیفهای محدوده مرئی-مادون قرمز نزدیک در ده نمونه خاک به صورت تصادفی  
 Figure 2a- Representative VNIR/SWIR spectra of 10 selected soil samples, 2b- Absorption spectra of VNIR/SWIR spectra of 10 selected soil samples, 2c- Savitzky-Golay plus the first derivative, of 10 selected soil sample randomly

بازتاب برآزش داده شد، تولید شد. شکل ۴ سمت راست ارتباط بین مقادیر اندازه‌گیری شده و پیش‌بینی شده برای اعتبارسنجی متقابل را نشان می‌دهد. نتایج پیش‌بینی نشان داد که ریشه مربعات خطا برای جزء رس، شن و سیلت به ترتیب ۷/۴۶، ۱۲/۵۷ و ۸/۸۰ گرم بر کیلوگرم به دست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰/۲۵، ۰/۱۸ و ۰/۱۷ به دست آمد.

### نتایج مدل‌سازی مکانی به کمک تکنیک شبکه عصبی مصنوعی

توپولوژی شبکه یک فاکتور اساسی در طراحی شبکه عصبی مصنوعی می‌باشد به علت اینکه این ساختار اثر برروی سرعت یادگیری و صحت طبقه‌بندی نهایی تأثیرگذار است. تعداد لایه‌های مخفی و تعداد نرون‌ها جزء اجزای اصلی شبکه پرسپترون می‌باشد. بجز توپولوژی شبکه عصبی مصنوعی که ذکر شد تعداد نرون در مرحله یادگیری بسیار حائز اهمیت می‌باشد. تعداد نرون‌ها در لایه‌های ورودی و خروجی ثابت بوده و بسته به تعداد ورودی (متغیرهای کمکی) و خروجی (رس، شن و سیلت) مدل به کار گرفته شده دارد. لایه ورودی شبکه شامل ۱۹، ۱۷ و ۱۶ ورودی برای رس، شن و سیلت می‌باشد. لایه خروجی شامل یک نرون می‌باشد. تعداد نرون‌ها و لایه‌های مخفی بستگی به پیچیدگی مسئله مورد نظر دارد. در اینجا یک لایه مخفی برای ایجاد شبکه پرسپترون مورد استفاده قرار گرفت. تعداد نرون‌های لایه مخفی و همچنین تعداد اپوک در فرآیند آموزش و

به منظور انجام پیش پردازش طیف‌ها، ابتدا دو بخش نویری ابتدا و انتهای طیف‌ها در محدوده ۳۵۰-۴۰۰ و ۲۴۵۰-۲۵۰۰ نانومتر حذف گردید. به علاوه وقفه حاصل از تغییر ردیاب در محدوده ۹۰۰ تا ۱۰۰۰ نانومتر نیز حذف شد (۲۵). انواع روش‌های پیش‌پردازش شامل مشتق اول، مشتق دوم به همراه فیلتر میان‌ه و فیلتر ساویتزکی<sup>۱</sup> و گالای<sup>۲</sup> (۱۸)، تصحیح پخشیده‌چندگانه و متغییر نرمال استاندارد بر روی داده‌های طیفی به کمک نرم‌افزار 10.3 Unscambler انجام شد.

### مدل‌سازی مکانی

#### نتایج مدل‌سازی مکانی به کمک تکنیک رگرسیون

##### کمترین مربعات جزئی

با استفاده از تجزیه و تحلیل رگرسیون حداقل مربعات جزئی طول موج‌هایی برای پیش‌بینی درصد رس، شن و سیلت خاک انتخاب شد (شکل ۳) که ۱، ۲۳۶۱، ۲۲۴۵، ۲۲۰۰، ۲۱۷۸، ۲۰۰۵، ۱۹۳۷، ۱۴۱۹، ۱۴۱۳، ۳۴۴، ۲۳۹۶، ۱۹۰۷، ۱۸۴۴، ۱۴۵۶ و ۲۴۰۴ نانومتر بود. این طول موج‌ها می‌تواند به صورت طیفی به OH در آب ۱۴۰۰ و ۱۹۰۰ نانومتر (۱۰)، و Al-OH در مواد معدنی رس ۲۲۰۰ و ۲۲۵۰ نانومتر (۱۰) اختصاص یابد. همچنین با استفاده از تجزیه و تحلیل رگرسیون حداقل مربعات جزئی، بهترین مدل زمانی که اولین مشتق به مقادیر

1- Savitzky  
 2- Golay


همکاران (۱۹)، طراحی شبکه عصبی-مصنوعی نیازی به نوع معادله خاصی ندارد و می‌توان ارتباط مناسب بین داده‌های ورودی و خروجی را بدست آورد. با توجه به وجود روابط غیرخطی بین متغیرهای وابسته و پیش‌بینی شده، شبکه عصبی-مصنوعی عملکرد بهتری دارد. نتایج به دست آمده از این مطالعه با آنچه زائو و همکاران در چین به دست آوردند، سازگار است (۲۶). آنها نقشه دیجیتالی بافت خاک را توسط یک شبکه عصبی-مصنوعی با دقت کل ۰.۸۸ تهیه کردند. عملکرد عالی شبکه عصبی مصنوعی را می‌توان به توانای این مدل برای رفتار غیر خطی بافت خاک در طیف‌سنجی مرئی-مادون قرمز ربط داد. نتایج مقایسه انواع مدل‌ها برای پیش‌بینی رس، شن و سیلت در جدول ۲ آورده شده است. بنابراین به نظر می‌رسد که رابطه‌ی بین درصد ذرات رس، شن و سیلت خاک و بازتاب خاک خطی نیست و به همین دلیل روش شبکه عصبی-مصنوعی بهتر آن را تحلیل می‌کند. در واقع، هنگام ارزیابی درصد ذرات رس، شن و سیلت برآوردی توسط مدل رگرسیون حداقل مربعات جزئی یا شبکه عصبی مصنوعی برای مجموعه‌های ناهمگن خاک، محدوده طیفی باید با شناسایی طول موج‌هایی که داده‌های طیفی آن را بهترین رفتار تحلیلی می‌نامند، کاهش یابد.

در این تحقیق، بر اساس آزمون مارتین، از طول موج‌هایی که در شکل ۳ نشان داده شده است استفاده شد که بن دور و همکاران (۳) در مطالعه‌ای که بر روی خاک‌های اسرائیل داشتند نتایج مشابهی به دست آوردند. این نتیجه تایید می‌کند که می‌توان انواع مختلف خاک را با استفاده از دامنه‌های خاصی از طول موج مدل‌سازی کرد. مزیت این مطالعه در این نکته است که هنگام استفاده از شبکه عصبی-مصنوعی، هیچ پیش‌پردازشی قبل از اعمال مدل به داده‌های بازتاب داده نشد.

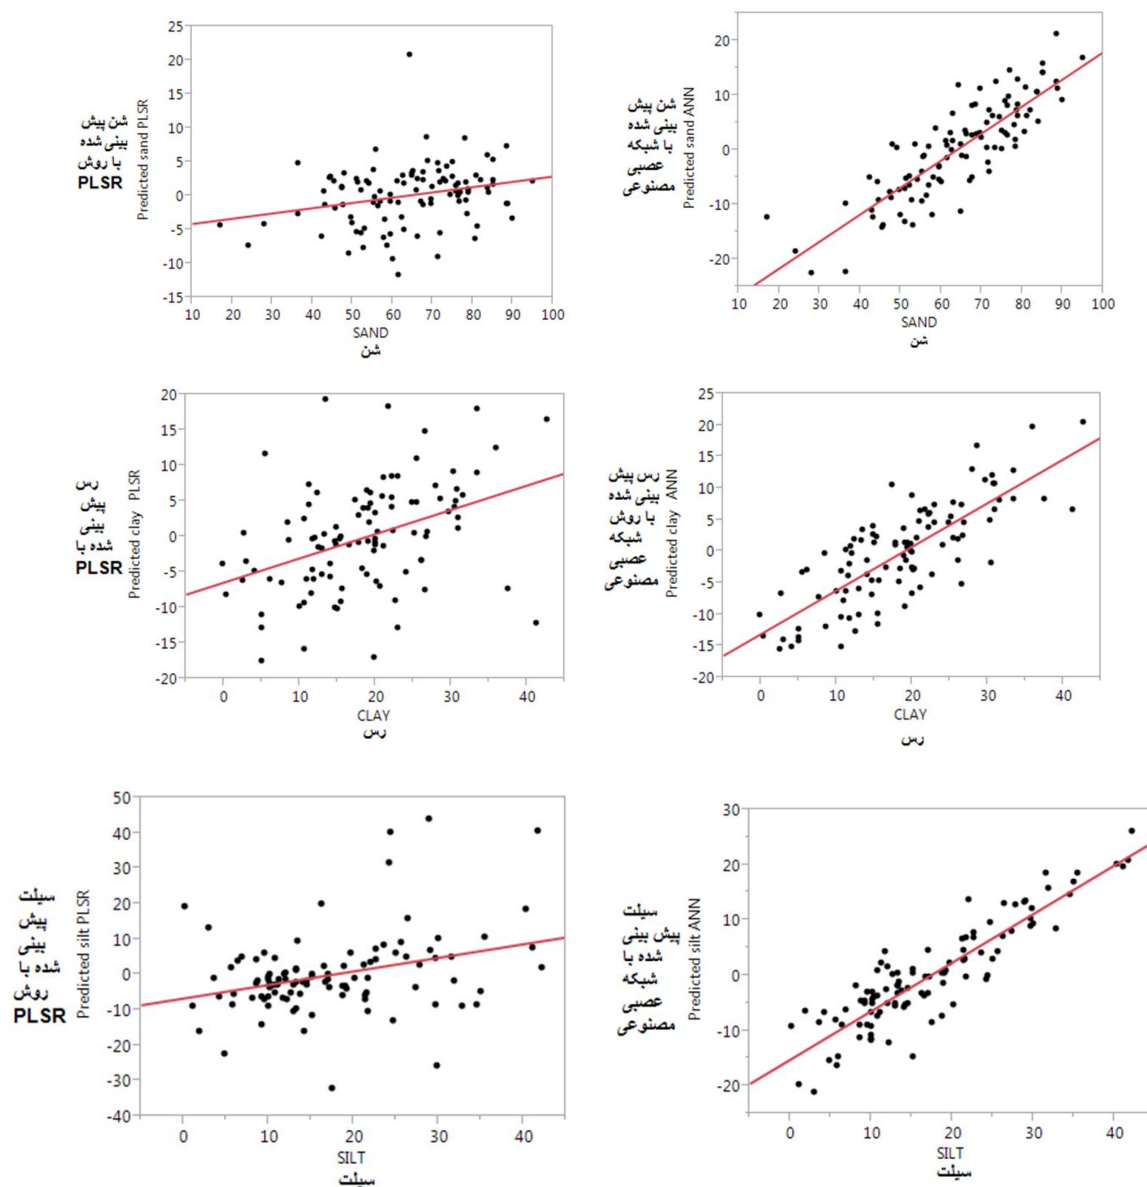
به صورت سعی و خطا به دست آمدند. در این پژوهش، تعداد نرون ۲ تا ۱۰ مورد آزمایش قرار گرفت. برای تعیین بهترین ترکیب از شاخص ریشه مربعات خطا و ضریب تبیین استفاده شد. نتایج نشان داد که تعداد نرون ۹،۸ و ۱۰ دارای بهترین ترکیب برای پیش‌بینی رس، شن و سیلت خاک می‌باشند. نمودارهای شکل ۵ سمت چپ با استفاده از رویکرد شبکه عصبی-مصنوعی، مقادیر اندازه‌گیری شده در مقابل پیش‌بینی شده از درصد رس، شن و سیلت خاک را نشان می‌دهد. نتایج ریشه مربعات خطا برای جزء رس، شن و سیلت خاک به ترتیب ۳/۴۲، ۶/۱۲ و ۴/۳۸ گرم بر کیلوگرم به دست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰،۸۴، ۰،۸۳ و ۰،۸۱ به دست آمد. بعد از به دست آوردن ساختار بهینه در مرحله آموزش شبکه عصبی مصنوعی که در بالا توضیح داده شد، شبکه آموزش دیده را بر روی داده‌های آزمون آزمایش کرده تا دقت این مدل برای پیش‌بینی رس، شن و سیلت خاک سطحی مشخص شود. نتایج ریشه مربعات خطا برای جزء رس، شن و سیلت ۵/۹، ۵۴/۱۴ و ۷/۰۱ گرم بر کیلوگرم به دست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰،۷۰، ۰،۷۶ و ۰،۷۳ به دست آمد. این نتایج نشان می‌دهد که مدل شبکه عصبی-مصنوعی به خوبی سیستم را آموخته و توانایی‌های تعمیم و ارزشیابی خوبی دارد.

**نتایج مقایسه مدل‌ها**

جدول ۲ نتایج مقایسه انواع مدل‌ها برای پیش‌بینی رس، شن و سیلت را نشان می‌دهد. همانطور که مشاهده می‌شود، بهترین نتیجه‌ی پیش‌بینی برای رگرسیون حداقل مربعات جزئی برای نمونه شن بدست آمده است. اما آنچه بارز است نتایج این مطالعه نشان می‌دهد که عملکرد شبکه عصبی-مصنوعی بهتر از رگرسیون حداقل مربعات جزئی بوده و کارآمدتر است که منطبق با یافته‌های موازن و همکاران (۱۶) و نیز ویسکارا روسل (۲۵) است. طبق گفته‌های اسکپ و



شکل ۳- ضرایب رگرسیون پذیرفته شده برای مدل عمومی (مجموعه اطلاعات اعتبارسنجی متقابل)  
Figure 3- Accepted regression coefficients for the general model (mutual validation data se)



شکل ۴- مقادیر اندازه گیری شده در مقابل پیش بینی شده از درصد رس، شن و سیلت خاک حاصل از تجزیه و تحلیل شبکه عصبی-مصنوعی و رگرسیون حداقل مربعات جزئی

Figure 4- Estimated values from clay, sand and soil silt as a result of neural network analysis and partial least squares regression

جدول ۲- نتایج مقایسه انواع مدل‌ها برای پیش‌بینی رس، شن و سیلت بر اساس داده‌های آزمون

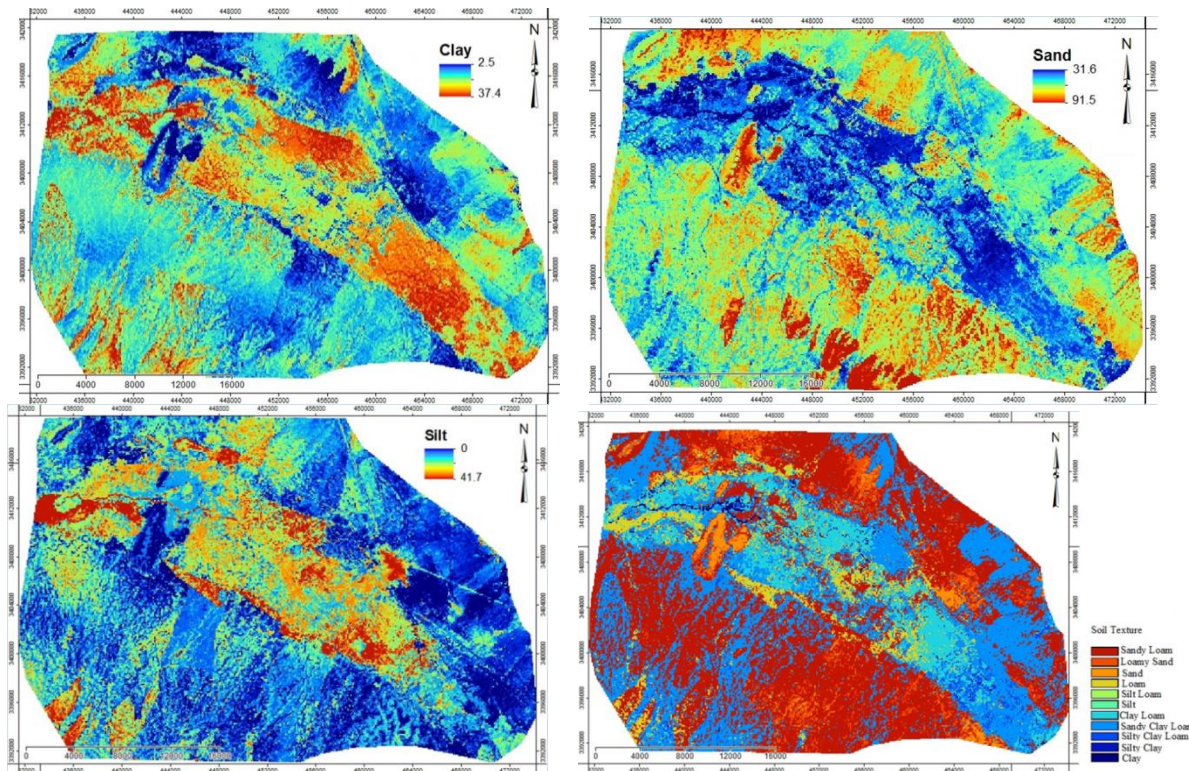
Table 2- Results of comparison of different models for predicting clay, sand and gravel based on test data

MODEL	R2			RMSE(g kg <sup>-1</sup> )		
مدل	ضریب تبیین			میانگین مربعات خطا		
	Silt سیلت	Sand شن	Clay رس	Silt سیلت	Sand شن	Clay رس
(ANN)	0.73	0.70	0.76	7.01	9.14	5.54
(PLSR)	0.17	0.25	0.18	8.80	12.57	7.46



های مرکزی منطقه مورد مطالعه که دشت‌های هموار رسی هستند، می‌باشد که البته دارای شوری بالاتری نسبت به اطراف بودند. مقدار شن و سنگریزه در دامنه‌ها و فن‌های بادبزی شکل بالا و پایین منطقه بیشتر نشان داده شد.

از آنجایی که رابطه بین درصد ذرات خاک (رس و شن و سیلت) و بازتاب خاک خطی نیست، روش شبکه عصبی-مصنوعی برای بررسی و تجزیه و تحلیل رابطه بین خاک‌ها بسیار مفید می‌باشد. در نهایت نقشه درصد رس، شن و سیلت و نقشه بافت خاک توسط روش شبکه عصبی مصنوعی در محیط جی‌آی‌اس تهیه گردید (شکل ۵). همانطور که در شکل ۵ دیده می‌شود بیشترین مقدار رس در قسمت



شکل ۵- نقشه رقوم ذرات رس، شن و سیلت و نقشه بافت خاک با استفاده از مدل شبکه عصبی-مصنوعی

Figure 5- Map of clay, sand and silt particles prediction map and soil texture map using artificial neural network model

متغیرهای وابسته و پیش‌بینی شونده شبکه عصبی عملکرد بهتری نسبت به رگرسیون حداقل مربعات جزئی در پیش‌بینی درصد رس، شن و سیلت داشته است. برای هر دو مدل از محدوده خاصی از طول موج استفاده شد. مدل‌های کالیبراسیون که در این مطالعه طراحی شده و مورد استفاده قرار می‌گیرند می‌توانند برای استفاده با خاک‌های دیگر منتقل شوند. هنگامی که مدل رگرسیون حداقل مربعات جزئی اجرا شد، دقت بسیار پایینی داشت ( $0 \sim 0.1R^2 - 0.3$ )، در مقابل، روش شبکه عصبی-مصنوعی دارای دقت بالا و خطای کمتری بود. توجه داشته باشید که هر چند مدل‌سازی شبکه عصبی-مصنوعی نتایجی با دقت بالا از بافت خاک برآورد می‌کند، هر دو رویکرد به انتخاب طول موج‌ها بستگی دارد و بنابراین انتخاب طول موج‌ها باید قبل از استفاده از هر ۲ مدل در نظر گرفته شود. رابطه معنی‌دار بین

## نتیجه‌گیری

نتایج این پژوهش نشان داد که شبکه عصبی-مصنوعی نسبت به رگرسیون حداقل مربعات جزئی کارایی بهتری داشته است. نتایج نشان داد که ریشه مربعات خطا در روش شبکه عصبی-مصنوعی برای جزء رس، شن و سیلت ۹/۱۴، ۵/۵۴ و ۷/۰۱ گرم بر کیلوگرم به دست آمد. همچنین نتایج ضریب تبیین به ترتیب ۰/۷، ۰/۷۶ و ۰/۷۳ به دست آمد. زیرا احتمالاً از یک طرف کارایی توابع انتقالی به دست آمده در مناطق مختلف با هم متفاوت هستند و از طرف دیگر در طراحی شبکه‌های عصبی نوع خاصی معادلات لازم نیست و با ایجاد ارتباط مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست پیدا کرد و به علت وجود روابط غیر خطی میان

دهد. مدل سازی شبکه عصبی-مصنوعی نتایج با دقت بالا از بافت خاک برآورد می کند، هر دو رویکرد به انتخاب طول موجها بستگی دارد و بنابراین انتخاب طول موجها باید قبل از استفاده از هر ۲ مدل در نظر گرفته شود. در نهایت رابطه معنی دار بین طول موج انتخاب شده و درصد رس، شن و سیلت خاک در تحقیق حاضر نشان می دهد که ارزیابی بافت خاک توسط طیفسنجی بازتابی نه تنها امکان پذیر است، بلکه قابل اعتماد است.

طول موج انتخاب شده و درصد رس، شن و سیلت خاک در تحقیق حاضر نشان می دهد که ارزیابی بافت خاک توسط طیفسنجی بازتابی نه تنها امکان پذیر است، بلکه قابل اعتماد است. در نهایت نتایج نشان داد که تکنیک های پدومتری، به ویژه شبکه عصبی برای طیف گسترده ای از رشته های علمی می تواند روند نقشه برداری خاک را در مقیاس وسیع و با هر گونه پیچیدگی طبیعی انجام دهد، روش سنتی را بهبود بخشد، سرعت و کارایی نقشه ها را در انتقال داده ها افزایش

## منابع

- Bellinaso H., Alexandre J., Dematte J.A.M., and Romeiro S.A. 2010. Soil spectral library and its use in soil classification. R. Bras. Ci. Solo 34: 861-870.
- Ben-Dor E., Goldshleger N., Benyamini Y., Blumberg D.G., and Agassi M. 2003. "The spectral reflectance properties of soil structural crusts in the 1.2- to 2.5- $\mu$ m spectral region," Soil Science Society of America Journal 67(1): 289-299.
- Ben-Dor E., Taylor R.G., Hill J., Dematte J.A.M., Whiting M.L., Chabrilat S., and Sommer S. Imaging Spectrometry for Soil Applications, Advances in Agronomy, Vol.97, No. 2008, Elsevier Inc.
- Clark R.N. 1999. Spectroscopy of rocks and minerals, and principles of spectroscopy. In: Rencz, A.N. (Ed.), Remote Sensing for Earth Sciences. Manual of Remote Sensing. John Wiley and Sons, Inc., Toronto, pp. 3-58.
- Greve M.H., Kheir R.B., Greve M.B., and Bocher P.K. 2012. Quantifying the Ability of Environmental Parameters to Predict Soil Texture Fractions Using Regression-Tree Model with GIS and LIDAR Data: The Case Study of Denmark, Ecological Indicators 18: 1-10.
- Gholizadeh A.A., Soom M.A.M., Saberioon M.M., and Boruvka L. 2013. Visible and near infrared reflectance spectroscopy to determine chemical properties of paddy soils. J. Food Agric. Environ 11: 859-866.
- Gomez C., Lebissonais Y., Annabi M., Bahri H., and Raclot D. 2013. Laboratory Vis-NIR Spectroscopy as an Alternative Method for Estimating the Soil Aggregate Stability Indexes of Mediterranean Soils, Geoderma 209-210: 86-97.
- Hartemink A.E., and Minasny B. 2014. Towards Digital Soil Morphometrics, Geoderma 230231: 305-317.
- Hunt G.R. 1977. Spectral signatures of particulate minerals in visible and near-infrared. Trans. Am. Geophys. Union 58: 553.
- Janik L.J., Forrester S.T., and Rawson A. 2009. The prediction of soil chemical and physical properties from mid-infrared spectroscopy and combined partial least-squares regression and neural networks (PLS-NN) analysis. Chemometr. Intell. Lab., 97: 179-188.
- Khayamim F., Khademi H., Stenberg B., and Wetterlind J. 2015. Capability of vis-NIR Spectroscopy to Predict Selected Chemical Soil Properties in Isfahan Province. JWSS - Isfahan University of Technology 19(72): 81-92.
- Kodaira M., and Shibusawa S. 2013. Using a mobile real-time soil visible-near infrared sensor for high resolution soil property mapping. Geoderma 199: 64-79.
- Kuang B., Mahmood H.S., Quraishi M.Z., Hoogmoed W.B., Mouazen A.M., and Van Henten E.J. 2012. Sensing Soil Properties in the Laboratory, In Situ, and On-Line: A Review: Advances in Agronomy, Elsevier Inc, Vol. 114.
- Li D., Durand M., and Margulis S.A. 2011. Potential for Hydrologic Characterization of Deep Mountain Snowpack via Passive 2012. in the Tropics, Earth-Science Reviews 106: 52-62.
- Mouazen A.M., Kuang B., DE Baerdemaeker and Ramon H. 2010. Comparison between principal component, partial least squares and back propagation neural network analyses for accuracy of measurement of selected soil properties with visible and near infrared spectroscopy. Geoderma 158: 23-3
- Ramadan Z., Hopke P.K., Johnson M.J., and Scow K.M. 2005. Application of PLS and Back-Propagation Neural Networks for the estimation of soil properties. Chemometr. Intell. Lab., 75: 23-30.
- Savitzky A., and Golay M.J. 1964. Smoothing and differentiation of data by simplified least squares.
- Schaap M.G., Leij F.J., and van Genuchten M.Th. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. Journal Soil Sci. Soc. Am 62: 847-855.
- Shepherd K.D., and Walsh M.G. 2002. Development of reflectance spectral libraries for characterization of soil properties. Soil Sci. Soc. Am. J. 66: 988-998.
- Soriano-Disla J.M., Janik L.J., Viscarra-Rossel R.A., Macdonald L.M., and Mclaughlin M.J. 2014. The Performance of visible, near-, and mid-infrared reflectance spectroscopy for prediction of soil physical,

- chemical, and biological properties. *Appl. Spectrosc. Rev.*, 49: 139-186.
- 21- Stenberg B., Viscarra-Rossel R.A., Mouazen A.M., and Wetterlind J. 2010. Visible and near infrared spectroscopy in soil science. *Adv. Agron.*, 107: 163-215.
  - 22- Summers D., Lewis M., Ostendorf B., and Chittleborough D. 2011. Visible near-infrared reflectance spectroscopy as a predictive indicator of soil properties. *Ecol. Indic.*, 11: 123-131.
  - 23- Vasquez G.M., Grunwald S., and Sickman J.O. 2008. Comparison of multivariate methods for inferential modeling of soil carbon using visible/near-infrared spectra. *Geoderma* 146: 14-25.
  - 24- Viscarra Rossel R., Cattle S.R., Ortega A., and Y. 2009. Fouad. In situ measurements of soil colour, mineral composition and clay content by vis-NIR spectroscopy, *Geoderma* 150: 253-266.
  - 25- Weather data of Zarand, Kerman province, 2015.
  - 26- Zhao S.J., Zhang J., XU Y.M., and Xiong Z.H. 2006. Non-linear projections to latent structures method and its applications. *Indian Eng. Chem. Res.*, 45: 3843-3852.
  - 27- Zhao Z., Chow T.L., Rees H.W., Yang Q., Xing Z., and Meng F. 2009. Predict soil texture distributions using an artificial neural network model. *Com. Elec. Agr.*, 65: 36-48.
  - 28- Zhu Y., David C.W., and Zhang W. 2011. Characterizing Soils Using a Portable X-ray Fluorescence Spectrometer-1. *Soil Texture, Geoderma* 167-168: 167-177.29.
  - 29- Zhu Y.M., Lu X.X., and Zhou Y. 2007. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment, China. *Geomorphology* 84: 111-125.

## Visible-Near Infrared (VIS-NIR) Spectrophotometry in Predicting Soil Particle Percentage Using Artificial Neural Network and Partial Least Squares Regression

E. Mehrabi Gohari<sup>1</sup>- H.R. Matinfar<sup>2\*</sup>- R. Taghizadeh-Mehrjardi<sup>3</sup>- A. Jafari<sup>4</sup>

Received: 12-06-2019

Accepted: 22-01-2020

**Introduction:** Soil texture is the most important environmental variable because it plays a very important role in reducing the quality of land and water transfer processes, soil quality control and fertility. On the one hand, soil texture components are the basis of environmental predictive models and digital mapping of soil and on the other hand, soils are temporally and spatially variable, thus distinguish zoning and their monitoring with traditional sampling methods and laboratory analysis is very costly and time consuming. As a result, the development of methods for analyzing the soil and for required information has become very important. Visible and near infrared spectroscopy (VIS-NIR) is widely used to estimate soil physical properties and estimate soil texture. The present study aims to predict soil texture using spectral measurements and artificial neural network models and partial least squares regression.

**Materials and Methods:** The study area in southeastern Iran is approximately 70 km from Kerman. In the study area, based on the hypercube technique, 115 profiles were identified and then horizons were sampled. In this way, for each point of study, the necessary information, including the location of the profile on the ground, the type of geomorphic unit and the type of material, were recorded and taken from the horizons of each profile. In all soil samples, after drying and passing through 2 mm soil, the soil texture was measured by hypercube. Spectral radiometer was used to measure the spectral reflection of soil samples. The soil samples were air dried and sieved and then placed in a petri dish with an approximate diameter of 10 cm and transferred to the dark room for spectral analysis. Each specimen was tested four times (for each 90 degree sequential rotation) to remove the effects of a change in the radiation geometry. Soil samples were scanned, and absolute reflections at a spectral range of 2500-350 nm yielded 2150 spectral data points (SDPs) per soil sample with a spectral resolution of one nanometer. Finally, to construct a suitable model for forecasting the percentage of clay, sand, and silt, the least squares model was used with the number of factors 1 to 10 by Artificial Neural Network (ANN) modeling using JMP software Work.

**Results and Discussion:** The reflectance spectrum of the visible range - near infrared - was measured for specimens. Since preprocessing of spectral data has an effective role in improving the calibration, in order to perform spectral preprocessing, two first nodes of the first and the end of the spectra were first removed in the range of 350-400 and 2450-2500 nm. In addition, the interruption due to the change in the detector in the range of 900 to 1000 nm was also eliminated. Types of preprocessing methods were performed on spectral data. Then, using partial least squares regression analysis, the best model was produced when the first derivative was fitted to reflection values. The explanation coefficients for this low and unacceptable model were obtained. Therefore, using partial least squares regression analysis, the best wavelengths were selected to predict the percentage of clay, sand, soil, and extracted from the model. Then it was used as input in the neural network model. To determine the best combination, root error index and error coefficient were used. The results of artificial neural network showed that the number of neurons 9.8 and 10 had the best composition for predicting clay, sand and soil silt. The root-squared error results for clay, sand, and soil silt were 3.42, 6.94, and 4.383 respectively. Also, the results of the explanatory factor were 0.84, 0.83 and 0.81, respectively. After obtaining the optimal structure in the artificial neural network training phase described above, the trained network has been tested on the test data to determine the accuracy of this model to predict clay, sand and silt of surface soil. The root-squared error results for clay, sand and silt components were obtained at 5.54.9.14 and 7.01. Also, the results of the

1- Assistant Professor, Department of Agriculture, Payame Noor University and Graguated Ph.D. of Soil Science of Lorestan

2- Associate Professor Department of Soil Science, College of Agriculture, Lorestan University, Lorestan, Iran  
(\*- Corresponding Author Email: matinfar.h@lu.ac.ir)

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

4- Assistant Professor Department of Soil Science, Agriculture Faculty, Shahid Bahonar University of Kerman, Kerman

DOI: 10.22067/.v34i2.80806

explanatory factor were 0.76, 0.70 and 0.73 respectively. The best result of the prediction for partial least squares regression was obtained for the sand sample. The results indicate that the neural network performance is better than partial least squares regression, which is consistent with Mouazen et al. (2010) and also Viscarra-Rossel et al. (2009). Acceptable performance of the artificial-neural network can be attributed to the ability of this model for non-linear behavior of soil texture in visible spectroscopy. In this study, specific wavelengths, which Ben Finder et al. (2003) obtained in the study on the soils of Israel, were used. This conclusion confirms that various types of soil can be modeled using specific wavelengths. The advantage of this study is that, when using the artificial neural network, no pre-processing of reflection data is required before applying the model. Since the relationship between the percentage of soil particles (clay and gravel) and the reflection of the soil is not linear, the neural network method is very useful for analyzing the relationship between soils. Finally, the map of clay, sand and silt and map of soil texture was prepared by artificial neural network method in GIS environment.

**Conclusion:** The results of this study showed that the neural-dynamic network has a better performance than partial least squares regression. Calibration models designed and used in this study can be transported for use with other soils. When the partial least squares regression model was implemented, it had a very low accuracy ( $R^2 \sim 0.1-0.3$ ); on the contrary, the neural network-based method had high accuracy and less error. Note that although neural-dynamic modeling estimates higher precision results from soil texture, both approaches depend on wavelength selections, and so wavelengths should be selected before using any of the two models. To be finally, a meaningful relationship between the selected wavelengths and the percentage of clay, sand and silt in the present study indicates that soil texture is not only possible but also reliable by reflection spectroscopy.

**Keywords:** Artificial neural network, Infrared, Modeling, Prediction, Partial least squares regression, Visible spectroscopy