

ارائه مدلی غیرپارامتریک با استفاده از تکنیک k -نزدیک‌ترین همسایه در برآورد جرم مخصوص ظاهری خاک

وحیدرضا جلالی^۱ و مهدی همایی^{۲*}

(تاریخ دریافت: ۱۳۸۹/۱/۱۴؛ تاریخ پذیرش: ۱۳۸۹/۱۱/۲)

چکیده

در مدل‌هایی که به پیش‌بینی فرآیندهای حاکم در محیط خاک می‌پردازند، دانستن جرم ویژه ظاهری خاک به عنوان یک پارامتر ورودی، لازم است. رویکردهای غیرپارامتریک در جنبه‌های مختلفی برای تخمین متغیرهای پیوسته به کار رفته‌اند. در این پژوهش نوعی از الگوریتم‌های غیرپارامتریک از نوع یادگیرنده‌های تنبل موسوم به k -نزدیک‌ترین همسایه، برای تخمین جرم ویژه ظاهری خاک با استفاده از دیگر ویژگی‌های کمکی آن شامل توزیع اندازه ذرات خاک، pH خاک، هدایت الکتریکی عصاره اشباع خاک (EC)، درصد اشباع خاک (SP)، درصد کربن آلی خاک (OC) و مقدار آهک به کار گرفته شد. بر اساس تکنیک cross validation برای تخمین جرم ویژه ظاهری هر نمونه خاک هدف، هشت نمونه خاک که حداکثر تشابه به خاک هدف را داشتند، از بانک مرجع که حاوی ۱۳۶ نمونه خاک بود، انتخاب و مقدار جرم ویژه ظاهری آنها برآورد شد. استفاده از آماره‌های ضریب هم‌بستگی پیرسون ($r=0/86$)، خطای ماکزیمم ($ME=0/15$)، ریشه میانگین مربعات خطا ($RMSE=2/5$)، ضریب تبیین ($CD=1/3$)، کارایی مدل ($EF=0/75$) و ضریب جرم باقی‌مانده ($CRM=0/001$) نشان داد که در اکثر موارد این تکنیک به صورت قابل قبول توانمند است. بر این اساس، می‌توان نتیجه‌گیری کرد که استفاده از این تکنیک به عنوان روشی جایگزین برای اشتقاق توابع انتقالی خاک، به ویژه زمانی که فراهمی داده‌های جدید؛ نیاز به اشتقاق مجدد این توابع را الزام‌آور می‌کند، می‌تواند به کار رود.

واژه‌های کلیدی: تکنیک k -نزدیک‌ترین همسایه، جرم ویژه ظاهری خاک، مدل‌سازی

۱. دانشجوی سابق دکتری خاک‌شناسی، دانشکده کشاورزی، دانشگاه تربیت مدرس تهران و در حال حاضر استادیار خاک‌شناسی، دانشکده

کشاورزی، دانشگاه شهید باهنر کرمان

۲. استاد خاک‌شناسی، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران

*: مسئول مکاتبات، پست الکترونیکی: mhomae@hotmai.com

مقدمه

جرم ویژه ظاهری خاک، در تبدیل روابط جرمی- حجمی، تخمین ظرفیت خاک در ذخیره سازی کربن و تعیین میزان انبارش مواد مغذی در خاک بسیار مورد نیاز است (۲۸). جرم ویژه ظاهری خاک هم چنین در برآورد خصوصیات نگهداشت آب در خاک مورد نیاز بوده و دانستن آن به عنوان یک پارامتر ورودی در مدل هایی که به بررسی حرکت آب، املاح و رسوبات می پردازند؛ اجتناب ناپذیر است. علاوه بر این، جرم ویژه ظاهری به عنوان شاخصی برای آگاهی از میزان تراکم خاک، تخلخل و باروری موضعی آن به کار برده می شود (۲۳).

در نهایت می توان با استفاده از جرم ویژه ظاهری خاک به عنوان یک ابزار کلیدی، به توصیف ساختمان خاک پرداخت. بنابراین، آگاهی داشتن از میزان جرم ویژه ظاهری خاک در بسیاری جنبه های مطالعاتی علوم خاک اجتناب ناپذیر است.

با وجود پیشرفت های تکنیکی و بهبود ابزارآلات به کار رفته در اندازه گیری مستقیم جرم ویژه ظاهری خاک، این روش ها همچنان زمان بر و همراه با خطا هستند. بنابراین در اکثر گزارش های تهیه شده، از این ویژگی صرف نظر شده و یا در صورت اندازه گیری، هر یک به روش جداگانه ای اقدام نموده اند (۹). بنابراین پژوهشگران برای حل این مشکل، روش های غیر مستقیم را مورد توجه قرار داده اند. اشتقاق توابع انتقالی خاک یکی از این روش هاست که با استفاده از ویژگی های زود یافت خاک، ویژگی های دیر یافت آن را برآورد می کند (۴). روش های رگرسیونی و اخیراً شبکه های عصبی مصنوعی دو روش معمول در توسعه توابع انتقالی خاک هستند (۱۰ و ۱۷).

اسکاپ و همکاران (۲۵) با استفاده از شبکه های عصبی مصنوعی، توابعی انتقالی با نام تجاری *Rosetta* برای تخمین و برآورد خصوصیات هیدرولیکی خاک ارائه نمودند. وجه تشابه بین اکثر توابع انتقالی موجود، در اشتقاق آنها بر مبنای رویکرد پارامتریک است. بدین معنی که همه این توابع متشکل از پارامترهایی هستند که از برازش یکسری توابع معین بر داده ها به دست آمده اند، که این رویکرد، خود کاستی هایی به همراه دارد.

تعیین رابطه صحیح و حصول اطمینان از یک نواختی توزیع تابع احتمال خطا در بین داده ها، معمولاً کار ساده ای نیست. هم چنین هنگامی که بانک داده از تعدادی اندک تشکیل شده باشد، تخمین های شکل گرفته بر اساس رویکرد مذکور، بسیار ناپایدار خواهد بود و از طرفی، در مواردی که داده های جدید (در مقیاس زمانی و مکانی متفاوت با داده های موجود در بانک مرجع) مهیا شد، بازنگری کلی در روابط قبلی و توسعه مجدد آنها الزام آور خواهد شد. به همین دلیل کاربران به راحتی قادر به اضافه نمودن داده های محلی خود برای بهبود تخمین این توابع نیستند (۱۹).

استفاده از روش های غیرپارامتریک می تواند به عنوان رویکردی جایگزین، برای این چنین تخمین هایی به کار گرفته شود. این تکنیک ها، به جای برازش دادن یکسری توابع معین بر داده ها، بر اساس تشخیص الگو و استفاده از اصل تشابهات بنا نهاده شده اند. به عنوان نمونه تیم تحقیقاتی اسکاپ و همکاران که در سال ۲۰۰۱ نرم افزار *Rosetta* را بر اساس رویکرد پارامتریک و با استفاده از شبکه های عصبی مصنوعی ابداع نموده بودند، در پژوهشی نوین در سال ۲۰۰۹ با استفاده از همان پایگاه داده ای که در اشتقاق توابع هیدرولیکی خاک به کار برده بودند، به این نتیجه رسیدند که استفاده از تکنیک های غیرپارامتریک کارایی چشمگیری در بهبود تخمین های صورت گرفته خواهد داشت (۲۹). به همین ترتیب نمس و همکاران (۱۸) توابع انتقالی که توسط رولز و همکاران در سال ۱۹۸۲ به روش رگرسیون خطی اشتقاق یافته بودند را بررسی نمودند و دریافتند که این توابع انتقالی از دقت کافی جهت استفاده آنها در مقیاس ایالات متحده آمریکا برخوردار نبوده و با ارزیابی روش غیرپارامتریک *k*- نزدیک ترین همسایه، بیان نمودند که روش مذکور از توانایی بالاتری برای تخمین توابع هیدرولیکی در مقیاس کل ایالات متحده آمریکا برخوردار است (۱۸).

استفاد از الگوریتم های غیرپارامتریک در مواردی که نحوه ارتباط بین ورودی و خروجی از قبل به طور کامل مشخص نباشد، سودمند و مؤثر خواهد بود (۲۶ و ۳۱). رویکرد *k*-

می‌رود- جهت یافتن نزدیک‌ترین (مشابه‌ترین) خاک به خاک هدف، مورد جستجو واقع می‌شود. نخستین گام در این زمینه، تعیین فاصله بین نمونه هدف با هر یک از داده‌های موجود در بانک داده است. در اکثر مطالعات صورت گرفته در این زمینه، جهت اندازه‌گیری فاصله بین نمونه مجهول (هدف) و نمونه خاک‌های بانک مرجع، از روابط کلاسیک محاسبه فاصله اقلیدسی نمونه هدف تا هر یک از نمونه‌های موجود در بانک مرجع استفاده می‌شود. به طور نمونه برای حالتی که میزان فاصله بین یک نمونه خاک از بانک مرجع با نمونه هدف مدنظر باشد، بر اساس گزارش جاگتاب و همکاران (۱۲)، می‌توان از شکل کلی رابطه فیثاغورث استفاده نمود (رابطه ۱).

$$D(X, Y) = \sqrt{\sum_{i=1}^{nf} (x_i - y_i)^2} \quad [1]$$

که در آن X : نماینده خاکی با چند پارامتر مشخص (x_1 تا x_n) (مانند درصد اندازه ذرات، EC، pH، OC و...) از بانک داده مرجع بوده و Y : نمونه خاک هدف با همان تعداد پارامتر (y_1 تا y_n) است.

$$X = (x_1, x_2, x_3, \dots, x_n)$$

$$Y = (y_1, y_2, y_3, \dots, y_n)$$

بدین ترتیب نمونه خاک‌های بانک داده به ترتیب صعودی از کمترین (حداکثر تشابه) تا بیشترین فاصله (حداقل تشابه) از نمونه مورد نظر دسته‌بندی و ارزش‌گذاری خواهند شد. مرحله دوم که باید به آن پرداخته شود، تعداد خاک‌هایی (K) است که از فهرست فوق جهت تخمین ویژگی‌های خاک هدف از آنها باید استفاده گردد. به عبارت دیگر برای برآورد ویژگی‌های خاک هدف، چند نمونه خاک از بانک مرجع باید انتخاب گردد؟ پر واضح است که میزان کارایی این روش به طور قابل ملاحظه‌ای به کیفیت انتخاب نزدیک‌ترین (مشابه‌ترین) نمونه‌ها از بانک مرجع با خاک هدف وابسته است. زیرا به راحتی نمی‌توان بیان داشت که برای نیل به بیشترین دقت در تخمین‌ها، استفاده از نزدیک‌ترین نمونه در بانک مرجع با کمترین فاصله، استفاده از دو نمونه نزدیک، پنج نمونه نزدیک، ده نمونه نزدیک

نزدیک‌ترین همسایه، یکی از مهم‌ترین و توسعه یافته‌ترین رویکردهای غیرپارامتریک می‌باشد که در بسیاری از پژوهش‌های نوین جهت تشخیص الگو و کلاسه‌بندی‌های آماری به کار گرفته شده است (۶). کاربردهای وسیع تکنیک‌های غیرپارامتریک، در جنبه‌های مختلف، کارآیی بالایی این تکنیک‌ها را به اثبات رسانده‌اند. شبیه‌سازی و تفریق جریان رواناب‌های سطحی (۱۴، ۲۶ و ۲۷)، شبیه‌سازی بارش با استفاده از مدل غیرهمگن زنجیره مارکوف (۱۶)، پخش سیلاب (۲۴)، شبیه‌سازی آب و هوایی با استفاده از تکنیک k -نزدیک‌ترین همسایه (۳)، نمونه‌هایی از این کاربردها در هیدرولوژی است. لوپز و همکاران (۱۵) در تحقیقی به ارزیابی تراکم گونه‌های مختلف جنگلی و ایجاد نقشه پوشش گیاهی با استفاده از تکنیک k -نزدیک‌ترین همسایه پرداختند و نتیجه‌گیری نمودند که استفاده از تکنیک فوق، علاوه بر سهولت محاسبات، از دقت بالایی نیز برخوردار بوده است.

تحقیق نمس و همکاران (۲۱) در رابطه با تفسیر توزیع اندازه ذرات خاک با کمک تکنیک k -نزدیک‌ترین همسایه، در واقع یکی از اولین موارد استفاده این تکنیک در علوم خاک بوده است. پس از اثبات توانایی روش مذکور، نمس و همکاران (۲۱) با استفاده از تکنیک k -نزدیک‌ترین همسایه، به تخمین ویژگی‌های هیدرولیکی خاک پرداختند و بیان نمودند که علی‌رغم دقت یکسان تکنیک مذکور و روش شبکه‌های عصبی مصنوعی در اشتقاق و تخمین توابع هیدرولیکی، قابلیت روش k -نزدیک‌ترین همسایه جهت وارد نمودن داده‌های محلی، ارجحیتی نسبی برای این روش ایجاد می‌نماید.

تکنیک k -نزدیک‌ترین همسایه

بر خلاف توابع انتقالی کلاسیک، تکنیک k -نزدیک‌ترین همسایه از هیچ تابع ریاضیاتی از پیش تعریف‌شده‌ای جهت تخمین متغیرهای مختلف استفاده نمی‌نماید. در این رویکرد، یک بانک داده مرجع ('reference' data set) - همانند بانک داده‌ای که در آموزش و توسعه توابع انتقالی کلاسیک به کار

pH (۲۲)، هدایت الکتریکی عصاره اشباع خاک، EC (۲۲)، درصد مواد آلی خاک، OC (۳۰)، درصد رطوبت اشباع، SP (۵) و میزان آهک خاک نیز تعیین شد (۱۳).

تکنیک k -نزدیک‌ترین همسایه و سایر مشتقات آن متعلق به گروه الگوریتم‌های یادگیرنده تبیل (lazy learning algorithms) می‌باشند. این الگوریتم، داده‌های در حال توسعه را به صورت غیرفعال (Passive) فقط ذخیره می‌نماید و تا هنگامی که نیاز به تخمین جدید نباشد، هیچ‌گونه فرآیند یادگیری و آموزش صورت نخواهد پذیرفت. به همین دلیل اصطلاح تبیل برای این گونه الگوریتم‌ها به کار برده می‌شود. استفاده از این تکنیک به مفهوم شناسایی و بازیابی نزدیک‌ترین (مشابه‌ترین) حالت نمونه در بانک داده به نمونه هدف بود.

ذکر این نکته در اینجا ضروری است که منظور از داده هدف، نمونه خاکی است که تمام متغیرهای فیزیکی و شیمیایی آن به جز متغیر موردنظر (جرم ویژه ظاهری خاک) مشخص است. در این حالت الگوریتم $k.n.n$ از میان k تعداد از مشابه‌ترین خاک‌های موجود در بانک داده (۱۳۶ نمونه خاک با متغیرهای مشخص) به خاک هدف، به تخمین مقدار جرم ویژه ظاهری خاک هدف (مجهول) می‌پردازد.

به همین منظور، با استفاده از رابطه لال و شارما (۱۴) تخمینی اولیه از تعداد k نمونه جهت وارد نمودن در محاسبات به عمل آمد و سپس با استفاده از تکنیک Leave-One-Out Cross Validation، تعداد دقیق k نمونه خاک محاسبه شد.

تکنیک Cross Validation روشی آماری است که در واقع کیفیت تخمین‌های یک مدل را بر اساس تعداد و نوع داده‌های ورودی مشخص می‌کند. نام دیگر این تکنیک، تخمین چرخشی (Rotation estimation) است، زیرا با جایگذاری n تعداد از داده‌های ورودی، به تخمین متغیر مجهول پرداخته و میزان اختلاف داده تخمینی و مشاهده‌ای را ثبت می‌کند، در گردش بعدی میزان اختلاف بین داده تخمینی و مشاهده‌ای را برای $n+1$ تعداد از داده‌های ورودی محاسبه می‌کند. این چرخش تا

و حتی بیشتر، تعداد نقاط منجر به تخمینی با دقت قابل قبول خواهد شد. برای تعیین تعداد بهینه k در تخمین نمونه هدف، استفاده از تکنیک Leave-One-Out Cross Validation پیشنهاد شده است (۲۱). ایشان در تحقیقات وسیع خود در شرایط مختلف رابطه $k = n^{1/2}$ for $n > 100$ را ارائه نمودند که در آن n تعداد نمونه در بانک مرجع است. از آنجا که هیچ تحقیقی مشابه در این زمینه صورت نگرفته و هیچ اطلاعات اولیه‌ای در زمینه بهینه‌ترین تعداد k جهت تخمین جرم ویژه ظاهری خاک وجود ندارد، بهینه‌سازی تعداد k نیز بخشی از این تحقیق بوده است.

علی‌رغم کاربرد وسیع و مؤثر رویکردهای غیرپارامتریک بطور عام و رویکرد k -نزدیک‌ترین همسایه به طور خاص، در زمینه‌های مختلف علوم محیطی و اثبات توانایی‌های این روش، تاکنون پژوهشی در زمینه استفاده از تکنیک k -نزدیک‌ترین همسایه جهت برآورد جرم ویژه ظاهری خاک در سطح دنیا صورت نگرفته است. هدف از انجام این تحقیق، بررسی توانایی تکنیک مورد نظر و ارائه مدلی غیرپارامتریک برای برآورد میزان جرم ویژه ظاهری خاک بوده است.

مواد و روش‌ها

منطقه مورد مطالعه، دشت دامنه‌ای قره‌میدان واقع در ۷۰ کیلومتری شمال‌غرب بجنورد واقع شده است. وسعت منطقه بیش از ۳۰۰ هکتار و شیب عمومی آن حدود ۱۵ درصد است. در آغاز پژوهش، با استفاده از نرم‌افزار ArcGIS و دستگاه GPS، کل منطقه به شبکه‌هایی با طول مساوی ۱۵۰ متر تقسیم‌بندی شد. از بخش‌های مذکور از عمق ۰-۲۵ سانتی‌متری نمونه‌برداری خاک انجام شد و تعداد ۱۳۶ نمونه خاک تهیه گردید. جرم ویژه ظاهری نمونه‌ها به روش کلوخه تعیین شد (۵). نمونه‌ها در مجاورت هوای آزاد خشک و از الک ۲ میلی‌متری عبور داده شدند. فراوانی نسبی اندازه ذرات به روش هیدرومتری اندازه‌گیری و کلاس بافتی خاک‌ها تعیین گردید (۷). همچنین ویژگی‌های شیمیایی خاک شامل واکنش خاک،

زمانی ادامه می‌یابد تا سرانجام، ترکیب مورد نظر که دارای کمترین خطا بین مقادیر تخمینی و مشاهده‌ای است، به دست آید.

پس از تعیین تعداد k نزدیک‌ترین همسایه جهت ورود به محاسبات، برنامه موردنظر جهت ورود ویژگی‌های هر خاک شامل مختصات جغرافیای هر نقطه در سیستم متریک، درصد ذرات شن، سیلت و رس، درصد آهک، هدایت الکتریکی عصاره اشباع خاک (EC)، واکنش شیمیایی خاک (pH) و درصد اشباع آن (SP) در محیط برنامه‌نویسی R اجرا شد. فواصل اقلیدسی داده هدف با هر یک از داده‌های بانک مرجع محاسبه و ذخیره گردید. مقدار تخمینی ρ_b برای هر کدام از نمونه‌های هدف بر اساس میانگین وزنی k تعداد از نزدیک‌ترین همسایه‌های از پیش تعیین‌شده، به دست آمد. در نهایت اقدام به ارزیابی و اعتبارسنجی عملکرد مدل با استفاده از یکسری شاخص‌های آماری شد. یکی از شاخص‌های آماری که برای ارزیابی مدل‌ها از آن استفاده می‌شود، ضریب هم‌بستگی پیرسون می‌باشد که توسط رابطه زیر تعریف می‌شود (رابطه ۲).

$$r = \frac{n \left(\sum_{i=1}^n (P_i)(O_i) \right) - \left(\sum_{i=1}^n P_i \right) \left(\sum_{i=1}^n O_i \right)}{\sqrt{\left[n \sum_{i=1}^n (P_i)^2 - \left(\sum_{i=1}^n P_i \right)^2 \right] \left[n \sum_{i=1}^n (O_i)^2 - \left(\sum_{i=1}^n O_i \right)^2 \right]}}, \quad [2]$$

$$-1 \leq r \leq 1$$

در این رابطه r ضریب هم‌بستگی، P_i : مقدار پیش‌بینی شده برای نمونه i ام و O_i : مقدار مشاهده شده برای نمونه i ام می‌باشد. از آنجا که مقادیر ضریب هم‌بستگی همواره در بازه $[-1, 1]$ قرار می‌گیرند، قضاوت از روی این ضریب ساده بوده و ممکن است به نظر برسد که ضریب هم‌بستگی می‌تواند معیار مناسبی در ارزیابی مدل باشد. با این حال باید توجه داشت که ضریب هم‌بستگی نمی‌تواند به تنهایی شاخص مناسبی برای ارزیابی مدل باشد. زیرا ممکن است در یک مدل فرضی مقادیر پیش‌بینی و مشاهده شده دارای اختلافی فاحش باشند ولی این اشتباهات به گونه‌ای باشد که از یک روند یک‌نواخت پیروی نماید. بنابراین اگرچه ضریب هم‌بستگی به خوبی نشان‌دهنده

میزان هم‌آهنگی روند تغییرات مقادیر مشاهده شده نسبت به مقادیر پیش‌بینی شده است ولی گویای تطابق آنها نیست (۸).

شاخص‌های کمی دیگری که می‌توان در برآورد دقت مدل از آنها استفاده نمود، عبارت‌اند از آماره‌های خطای ماکزیمم (ME) (Maximum Error)، ریشه میانگین مربعات خطا (RMSE) (Root Mean Square Error)، ضریب تبیین (CD) (Coefficient of Determination)، کارایی مدل (EF) (Efficiency of model) و ضریب جرم باقی‌مانده (CRM) (Coefficient of Residual Mass) است. بیان ریاضی آماره‌های مذکور به صورت زیر است (۱۱):

$$ME = \max |P_i - O_i|_{i=1}^n \quad [3]$$

$$RMSE = \left[\frac{\sum_{i=1}^n (P_i - O_i)^2}{n} \right]^{\frac{1}{2}} \quad [4]$$

$$CD = \frac{\sum_{i=1}^n (O_i - \bar{O})}{\sum_{i=1}^n (P_i - \bar{O})} \quad [5]$$

$$EF = \frac{\sum_{i=1}^n (O_i - \bar{O}) - \sum_{i=1}^n (P_i - O_i)}{\sum_{i=1}^n (O_i - \bar{O})} \quad [6]$$

$$CRM = \frac{\sum_{i=1}^n O_i - \sum_{i=1}^n P_i}{\sum_{i=1}^n O_i} \quad [7]$$

که در آنها P_i مقادیر برآورد شده، O_i مقادیر اندازه‌گیری شده و n تعداد نمونه است. کمترین مقدار برای ME ، $RMSE$ و CD صفر است. مقدار ME نمایانگر بدترین حالت برآورد مدل است. در حالی که مقدار $RMSE$ نشان‌دهنده بیش‌برآورد (Overestimate) یا کم‌برآورد (Underestimate) است. CD نسبت بین پراکنش مقادیر برآورد شده و اندازه‌گیری شده را نشان می‌دهد. بیشترین مقدار برای EF یک است. مقادیر EF و CRM می‌توانند منفی باشند. EF مقادیر برآورد شده را نسبت به مقدار میانگین اندازه‌گیری‌ها مقایسه می‌کند. مقدار منفی EF دلالت بر آن دارد که میانگین مقادیر اندازه‌گیری شده تخمین بهتری را نسبت به مقادیر برآورد شده ارائه می‌دهند. CRM بیان‌کننده گرایش مدل به تخمین بیشتر و یا کمتر از مقادیر

را جدا، و با میانگین وزنی، مقدار جرم ویژه ظاهری خاک هدف را تخمین بزند. شکل ۲ مقادیر اندازه‌گیری و برآورد شده جرم ویژه ظاهری خاک را در مقابل هم به تصویر کشیده است و در شکل ۳، نقشه پراکنش میزان جرم ویژه ظاهری اندازه‌گیری شده و برآورد شده توسط مدل به تصویر کشیده شده است.

با توجه به شکل فوق می‌توان نتیجه گرفت که روند تغییرات مقادیر برآوردی توسط مدل با مقادیر اندازه‌گیری شده، هم‌آهنگ بوده و یا به عبارت دیگر مدل مورد نظر توانسته است با دقت نسبتاً خوبی مقادیر جرم ویژه ظاهری خاک را برآورد نماید ($R^2 = 0.748$). همان‌طور که قبلاً نیز اشاره شد، در تکنیک‌های رگرسیون خطی ضریب هم‌بستگی و یا توان دوم آن که به ضریب تبیین مشهور است، جهت تشخیص هم‌روندی دو متغیر به کار می‌روند. بنابراین، جهت تشخیص میزان دقت و توانایی یک مدل نیاز به یکسری پارامترهای آماری دیگر می‌باشد (۲).

بنابراین در این پژوهش علاوه بر محاسبه ضریب هم‌بستگی، از آماره‌های خطای ماکزیم (ME)، ریشه میانگین مربعات خطا ($RMSE$)، ضریب تبیین (CD)، کارایی مدل (EF) و ضریب جرم باقی‌مانده (CRM) به عنوان شاخص‌هایی کمی جهت تعیین میزان کارایی مدل k نزدیک‌ترین همسایه استفاده شد. جدول ۲ میزان هر کدام از این آماره‌ها را نشان می‌دهد.

همان‌طور که از داده‌های جدول برمی‌آید، علاوه بر هم‌روندی مقادیر تخمینی با مقادیر اندازه‌گیری شده که از روی ضریب هم‌بستگی نسبتاً بالا ($r = 0.86$) استنباط می‌شود، مقدار بالای آماره EF ($EF = 0.75$) نیز میزان کارایی مدل k - نزدیک‌ترین همسایه را نشان می‌دهد. آماره CD ، تمایل مدل را به بیش‌برآورد و یا کم‌برآورد کردن مدل نشان می‌دهد. هرچه مقدار این آماره از یک بیشتر باشد، با توجه به شکل رابطه (رابطه ۵)، تمایل مدل را به بیش‌برآورد نمودن مقادیر تخمینی نشان می‌دهد. همان‌طور که از مقدار آماره CD از جدول برمی‌آید ($CD = 1/3$)، مدل اندکی تمایل به بیش‌برآورد نمودن

اندازه‌گیری شده است. به دست آوردن مقدار منفی CRM برای یک مدل تمایل مدل را برای بیش‌برآورد اندازه‌گیری‌ها نشان می‌دهد. اگر تمامی داده‌های برآورد شده و اندازه‌گیری شده یکسان باشند، نتایج آماره‌ها به صورت $ME = 0$ ، $RMSE = 0$ ، $CD = 1$ ، $EF = 0$ و $CRM = 0$ خواهد بود (۲).

نتایج و بحث

جدول ۱، توصیف آماری ویژگی‌های انتخابی خاک‌های موجود در بانک داده را نشان می‌دهد.

همان‌طور که اشاره شد رابطه لال و شارما (۲) تخمینی اولیه از مقدار k تعداد بهینه از نزدیک‌ترین همسایه‌ها از بانک مرجع به داده هدف ارائه می‌دهد. با توجه به این که تعداد داده موجود در بانک مرجع ۱۳۶ ($n > 100$) عدد بوده لذا خواهیم داشت:

$$k = n^{1/2} \text{ for } n > 100$$

$$k = 136^{1/2} = 11.7$$


عدد به دست آمده حدود تقریبی میزان k بهینه را نشان می‌دهد ولی برای تعیین دقیق عدد k از تکنیک Cross Validation استفاده شد (شکل ۱).

شکل ۱ میزان دقت را در تکنیک Cross Validation جهت تعیین تعداد k بهینه را بر اساس آماره مجموع مربعات خطا ($Sum of Square Error$) (SSE) نشان می‌دهد. همان‌طور که مشاهده می‌شود، میزان خطا در کمترین تعداد همسایگی یعنی $K = 1$ حداکثر بوده و با افزایش این تعداد از میزان خطا کاسته شده است. این روند تا $K = 8$ ادامه یافته ولی پس از آن دوباره میزان خطا افزایش یافته و یا به عبارت دیگر دقت تخمین‌ها کاهش یافته است. پس در واقع در دامنه مورد نظر (۱ تا ۱۵) تعداد $K = 8$ بهینه‌ترین تعداد همسایگی جهت انجام تخمین‌ها بوده است.


در مرحله بعد الگوریتم موردنظر در محیط برنامه R نوشته شد تا خود برنامه به شکل هوشمند از بانک داده، نزدیک‌ترین داده‌ها را به داده هدف انتخاب نموده و پس از مرتب‌سازی آنها بر اساس کمترین فاصله اقلیدسی، ۸ داده نزدیک به داده هدف

جدول ۱. خلاصه‌ای از آماره‌های توصیفی پارامترهای خاکی به کار رفته جهت تخمین k نزدیک‌ترین همسایه


ویژگی	واحد	دامنه	کمینه	بیشینه	میانگین	انحراف معیار	واریانس
جرم ویژه ظاهری	g.cm^{-3}	۰/۵	۱/۲۶	۱/۷۵	۱/۵۳	۰/۰۹	۰/۰۰۷
شن	g.g^{-1}	۰/۷	۰/۰۴	۰/۷۵	۰/۲۲	۰/۰۸۴	۰/۰۰۷
سیلت	g.g^{-1}	۰/۵	۰/۱۳	۰/۶۲	۰/۴۹	۰/۰۵۴	۰/۰۰۳
رس	g.g^{-1}	۰/۳	۰/۱۲	۰/۴۴	۰/۳	۰/۰۴۵	۰/۰۰۲
کربن آلی	%	۱/۷	۰/۲۱	۱/۹۱	۰/۸۸	۰/۲۲	۰/۰۴۹
آهک	%	۴۲	۵/۷۵	۴۷/۷۵	۲۱/۹۹	۵/۳۶	۲۸/۷۷
شوری	dS.m^{-1}	۳/۵	۰/۲۷	۳/۸۱	۱/۷۴	۰/۴۸	۰/۲۳
pH	-	۱/۹	۶/۴۴	۸/۳۳	۷/۳۶	۰/۲۹	۰/۰۸۸
درصد اشباع	%	۲۳	۴۳	۶۶	۵۱/۳۲	۴/۲۰	۱۷/۶۶



شکل ۱. تعیین میزان k بهینه بر اساس آماره مجموع مربعات



شکل ۲. جرم ویژه ظاهری اندازه‌گیری شده و برآورد شده توسط تکنیک K -نزدیک ترین همسایه



شکل ۳. نقشه پراکنش میزان جرم ویژه ظاهری اندازه گیری شده و برآورد شده توسط مدل

جدول ۲. آماره های محاسباتی جهت تعیین میزان قابلیت تکنیک k نزدیک ترین همسایه در برآورد جرم ویژه ظاهری خاک

CRM	ME	RMSE	CD	EF	r
۰/۰۰۱	۰/۱۵	۲/۵	۱/۳	۰/۷۵	۰/۸۶

تخمین های خود نشان می دهد. آماره های ME ، $RMSE$ و CRM نیز هر کدام به نوعی نشان دهنده میزان خطای مدل در انجام برآوردها بوده است که هر چه مقادیر این آماره ها اندک و به صفر نزدیک تر باشد، دقت مدل بالا بوده و تخمین های آن به واقعیت نزدیک تر است. با در نظر گرفتن مقادیر $۲/۵$ ، $۰/۱۵$ و $۰/۰۰۱$ به ترتیب برای آماره های $RMSE$ ، ME و CRM می توان نتیجه گیری نمود که مدل k -نزدیک ترین همسایه در انجام تخمین های خود از مقدار خطای اندکی برخوردار بوده و مجدداً می توان از توان بالا و دقت قابل قبول این مدل در انجام تخمین جرم ویژه ظاهری خاک اطمینان حاصل نمود.

نتیجه گیری

در این پژوهش برای نخستین بار تکنیک k -نزدیک ترین همسایه به منظور تخمین جرم ویژه ظاهری خاک از روی سایر

ظاهری خاک داشته و پیشنهاد می‌گردد تا توانایی این شیوه در به کار گرفته شود.
تخمین سایر ویژگی‌های خاکی و با سایر بانک‌های داده

منابع مورد استفاده

۱. جلالی و. ر.، م. همایی و س. خ. میرنیا. ۱۳۸۷. مدلسازی واکنش کلزا به شوری طی مراحل مختلف رشد زایشی. علوم و فنون کشاورزی و منابع طبیعی ۱۲(۴۴): ۱۱۱-۱۲۱.
۲. جلالی و. ر.، م. همایی و س. خ. میرنیا. ۱۳۸۶. مدلسازی واکنش کلزا به شوری طی مراحل مختلف رشد رویشی. تحقیقات مهندسی کشاورزی ۸(۴): ۹۵-۱۱۲.
3. Bannayan, M. and G. Hoogenboom. 2008. Weather Analogue: A tool for lead time simulation of daily weather data based on modified K-nearest-neighbor approach. *Env. Model. and Software* 23: 703-713.
4. Bouma, J. 1989. Using soil survey data for quantitative land evaluation. *Adv. in Soil Sci.* 9:177-213.
5. Carter, M. R. 1993. *Soil Sampling and Methods of Analysis*. Lewis Pub., USA.
6. Dasarathy, B.V. 1991. Nearest neighbor (NN) Norms: NN pattern classification techniques. IEEE Computer Society Press, Los Alamitos, CA.
7. Gee, G.W. and J.W. Bauder. 1986. Particle size analysis. PP. 383-411. In: Klute (Ed.), *Methods of Soil Analysis*. Part 1, 2nd ed., America Society of Agronomy, Madison, WI.
8. Ghorbani Dashtaki, S., M. Homaee, M. H. Mahdian and M. Kouchakzadeh. 2009. Site-dependence performance of infiltration models. *Water Resour. Manag.* 23: 2777-2790.
9. Heuscher, S.A., C.C. Brandt and P. M. Jardine. 2005. Using soil physical and chemical properties to estimate bulk density. *Soil Sci. Soc. Amer. J.* 69:51-56.
10. Homaee, M. and A. Farrokhan Firouzi. 2008. Deriving point and parametric pedotransfer function of some gypsiferous soils. *Aust. J. Soil Res.* 46: 219-2277.
11. Homaee, M., C. Dirksen and R. A. Feddes. 2002. Simulation of root water uptake. I. Non-uniform transient salinity using different macroscopic reduction functions. *Agric. Water Manag.* 57: 89-109.
12. Jagtap, S.S., U. Lall, J.W. Jones, A.J. Gijssman and J.T. Ritchie. 2004. Dynamic nearest-neighbor method for estimating soil water parameters. *Trans. ASAE* 47:1437-1444.
13. Klute, A. 1986. Ed. *Methods of soil analysis, Part 1: Physical and Mineralogical Methods*. 2nd ed., Monogr. 9. ASA and SSSA, Madison, WI.
14. Lall, U. and A. Sharma. 1996. A nearest-neighbor bootstrap for resampling hydrologic time series. *Water Resour. Res.* 32:679-693.
15. Lopez, H.F., A.R. Ek and M.E. Bauer. 2001. Estimation and mapping of forest stand density, volume, and cover type using the k-nearest neighbors method. *Remote Sens. Environ.* 77: 251-274.
16. Marshall, L., D. Nott and A. Sharma. 2004. A comparative study of Markov chain Monte Carlo methods for conceptual rainfall-runoff modeling. *Water Resour. Res.* 40:2501-2512.
17. Minasny, B. and A.B. McBratney. 2002. The Neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Sci. Soc. Amer. J.* 66:352-361.
18. Nemes, A., D.J. Timlin, A. Pachepsky Ya and W.J. Rawls. 2009. Evaluation of the Rawls et al. (1982) Pedotransfer Functions for their Applicability at the U.S. National Scale. *Soil Sci. Soc. Amer. J.* 73:1638-1645.
19. Nemes A., R.T. Roberts, W.J. Rawls, Ya.A. Pachepsky and M.Th. van Genuchten. 2008. Software to estimate θ_{33} and θ_{1500} kPa soil water retention using the non-parametric k-Nearest Neighbor technique. *Environ. Model. and Software* 23: 254-255.
20. Nemes A., W.J. Rawls and Ya. Pachepsky. 2006. Use of the Nonparametric Nearest Neighbor Approach to Estimate Soil Hydraulic Properties. *Soil Sci. Soc. Amer. J.* 70:327-336.
21. Nemes, A., J.H.M. Wösten, A. Lilly and J.H. Oude Voshaar. 1999. Evaluation of different procedures to interpolate the cumulative particle-size distribution to achieve compatibility within a soil database. *Geoderma* 90:187-202.
22. Page, A. L., R. H. Miller and D. R. Keeney. 1982. *Methods of Soil Analysis, Part II, Physical Properties*. ASA, SSSA, Madison, WI.
23. Salifu, K.F., W.L. Meyer and H.G. Murchison. 1999. Estimating soil bulk density from organic matter content, pH, silt and clay. *J. Tropic. For.* 15:112-120.
24. Sankarasubramanian, A. and U. Lall. 2003. Flood quantiles in a changing climate: Seasonal forecasts and causal

- relations. *Water Resour. Res.* 39(5):1134-1144.
25. Schaap MG, Leij FJ, van Genuchten MTh 2001. Rosetta: a computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *J. Hydrol.* 251: 163–176.
26. Sharma, A. and R. O'Neill. 2002. A nonparametric approach for representing interannual dependence in monthly streamflow sequences. *Water Resour. Res.* 38:5-15.
27. Souza Filho, F.A. and U. Lall. 2003. Seasonal to interannual ensemble streamflow forecasts for Ceara, Brazil: Applications of a multivariate, semiparametric algorithm. *Water Resour. Res.* 39:1307-1317.
28. Tamminen, P. and M. Starr. 1994. Bulk density of forested mineral soils. *Silva Fennica* 28:53–60.
29. Twarakavi, N.K.C., J. Šimůnek, and M.G. Schaap. 2009. Development of Pedotransfer Functions for Estimation of Soil Hydraulic Parameters using Support Vector Machines. *Soil Sci. Soc. Amer. J.* 73:1443-1452.
30. Walkley, A. and I.A. Black. 1934. An examination of the Degtjareff for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Sci.* 37: 29-38.
31. Yakowitz, S. 1993. Nearest-neighbor estimation for null-recurrent Markov time series. *Stoch. Proc. Appl.* 48:311–318.