

## Digital Mapping of Soil Texture Fractions Using Regression Kriging and Neural Network Residual Kriging Model

Mohammad Shahriari\* , Mohammad Reza Pahlavan-Rad, Masoomeh Delbari, and Peyman Afrasiab

Researcher, Agricultural Engineering Research Department, Agricultural and Natural Resources Research and Education Center, AREEO, Zabol, Iran. [m.shahriari@areeo.ac.ir](mailto:m.shahriari@areeo.ac.ir)

Associate Professor, Soil and Water Research Department, Golestan, Agricultural and Natural Resources Research and Education Center, AREEO, Gorgan, Iran. [pahlavanrad@gmail.com](mailto:pahlavanrad@gmail.com)

Associate Professor of Irrigation and Drainage Engineering Department of Water Engineering, Faculty of Water and Soil, University of Zabol, Zabol, Iran P.O. [masoome.delbari@uoz.ac.ir](mailto:masoome.delbari@uoz.ac.ir)

Associate Professor of Irrigation and Drainage Engineering, Department of Water Engineering, Faculty of Water and Soil, University of Zabol Zabol, Iran P.O. [p-afraasib@yahoo.com](mailto:p-afraasib@yahoo.com)

### «Research Article»

Received: October 10, 2024 and Accepted: February 17, 2025

### Abstract

The aim of this study was to predict digital mapping of soil texture fractions in agricultural lands of Sistan flood plain at a regional scale (area 1300 km<sup>2</sup>). A regression kriging (RK) with neural network residual kriging (RKNR) was used to examine the relation between auxiliary variables and the soil texture components. Soil texture fractions including percentage of sand, silt, and clay content were measured for 160 soil samples collected from surface layer (0-30 cm) of various soil series in agricultural land of Sistan Plain. The additive log-ratio (alr) transformation was applied to transform texture components prior to prediction. Remotely sensed data including Landsat 8's Band (1-8), NDVI index, brightness index, clay index, grain size index (GSI) were used as auxiliary variables for interpolation of soil texture fractions. 80 % of data was used for prediction and 20 % for validation, while RMSE, ME and MAE were used for evaluation. Results show the values of RMSE of estimating percentage of sand, silt, and clay at validation sites using RKNR method were 15 %, 14.3% and 7.18 %, respectively, and the values of RMSE of estimation by a RK model were 10%, 10.6%, and 3.5 % higher than those obtained by RKNR model. Both  $silt_{alr}$  and  $clay_{alr}$  showed a strong exponential-type spatial correlation. A strong spatial correlation was observed for  $silt_{alr}$  and  $clay_{alr}$ . The residuals followed an exponential model of spatial structure for RK, and a spherical structure for RKNR. Therefore, RKNR model had higher accuracy when combined by remotely sensed data and it was a suitable method for mapping soil texture fractions in flood plain at regional scale.


**Keywords:** Auxiliary Variables, Neural Network Residual Kriging; Remote sensing; Soil texture fraction; Spatial variation

---

\* - Corresponding authors email: [m.shahriari@areeo.ac.ir](mailto:m.shahriari@areeo.ac.ir)



# تهیه نقشه رقومی اجزاء بافت خاک با استفاده از مدل ترکیبی رگرسیون کریجینگ و کریجینگ باقی مانده شبکه عصبی

محمد شهبازی<sup>۱\*</sup> , محمد رضا پهلوان راد<sup>۲</sup>، معصومه دلبری<sup>۳</sup> و پیمان افراسیاب<sup>۴</sup>

۱- محقق بخش تحقیقات فنی و مهندسی مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی سیستان، سیستان، زابل، ایران. [m.shahriari@areeo.ac.ir](mailto:m.shahriari@areeo.ac.ir)

۲- دانشیار مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی گلستان، گلستان، گرگان، ایران. [pahlavanrad@gmail.com](mailto:pahlavanrad@gmail.com)

۳- دانشیار گروه مهندسی آب، دانشکده آب و خاک دانشگاه زابل، زابل، ایران. [masooume.delbari@uoz.ac.ir](mailto:masooume.delbari@uoz.ac.ir)

۴- دانشیار گروه مهندسی آب، دانشکده آب و خاک دانشگاه زابل، زابل، ایران. [p-afراسیب@yahoo.com](mailto:p-afراسیب@yahoo.com)

«مقاله پژوهشی»

دریافت: ۱۴۰۳/۷/۱۹ و پذیرش: ۱۴۰۳/۱۱/۲۹

## چکیده

هدف از انجام این پژوهش تهیه نقشه رقومی اجزاء بافت خاک اراضی کشاورزی دشت سیستان با وسعت ۱۳۰۰ کیلومتر مربع با استفاده از مدل‌های رگرسیون کریجینگ و مدل ترکیبی رگرسیون کریجینگ و کریجینگ باقی مانده شبکه عصبی مصنوعی (RKNNRK) می‌باشد. برای این منظور، تعداد ۱۶۰ نمونه لایه سطحی (۰-۳۰ cm) از سری‌های مختلف خاک گرفته شد و درصد اجزاء بافت خاک در آزمایشگاه اندازه گیری گردید قبل از مدل سازی، اجزاء بافت خاک با استفاده از تابع لگاریتمی (alr) تبدیل شدند. از تصاویر باندهای ۱ تا ۸ ماهواره لندست ۸ و شاخص‌های پوشش گیاهی، روشنایی، درصد رس و اندازه ذرات خاک به عنوان متغیرهای کمکی برای درون‌یابی اجزاء بافت خاک استفاده گردید. ۸۰٪ داده‌ها برای پیش‌بینی و ۲۰٪ برای اعتبارسنجی اختصاص یافت. نتایج نشان داد که جزء رس خاک همبستگی مکانی متوسط و اجزاء سیلت و شن خاک ساختار مکانی قوی دارند. مدل‌نمایی بیشترین انطباق را با نیم‌تغییرنمای تجربی با هر سه جزء شن، سیلت و رس خاک و اجزاء تبدیل شده بافت خاک شامل  $Silt_{alr}$  و  $Clay_{alr}$  دارد. همچنین داده‌های  $Silt_{alr}$  و  $Clay_{alr}$  نیز از همبستگی مکانی قوی در منطقه مورد مطالعه برخوردار بودند. نتایج نشان داد که روش RKNNRK با آماره RMSE برابر ۱۵٪، ۱۴/۳۰٪ و ۷/۱۸٪ به ترتیب برای اجزاء شن، سیلت و رس خاک دقت بالاتری در پیش‌بینی اجزاء بافت خاک در مقایسه با مدل رگرسیون کریجینگ داشت. بطوریکه این مقادیر به ترتیب ۱۰٪، ۱۰/۶٪ و ۳/۵٪ نسبت به مقادیر متناظر آن در روش رگرسیون کریجینگ کاهش داشت. بنابراین روش RKNNRK در تلفیق با داده‌های سنجش از دور بر دقت پیش‌بینی نقشه های رقومی اجزاء بافت خاک افزود و به‌عنوان یک روش مناسب قابل توصیه می‌باشد.

واژه های کلیدی: اجزاء بافت خاک، تغییرات مکانی، سنجش از دور، متغیر کمکی

\* - آدرس ایمیل نویسنده مسئول: [m.shahriari@areeo.ac.ir](mailto:m.shahriari@areeo.ac.ir)

## مقدمه

تغییرات مکانی خصوصیات فیزیکی و شیمیایی خاک باعث تغییرپذیری تولید می‌گردد (فائو، ۲۰۲۲). بافت خاک از جمله فاکتورهای مؤثر بر بسیاری از خصوصیات فیزیکی و شیمیایی خاک، فعالیت‌های کشاورزی، کیفیت آب و حفاظت از محیط‌زیست است (Amirian-Chakan و همکاران، ۲۰۱۹؛ Dunkl و Ließ، ۲۰۲۰؛ Mgohele و همکاران، ۲۰۲۴) که مقدار نگهداری آب و عناصر غذایی، نفوذپذیری، تهویه، مقدار کربن آلی (Azizi و همکاران، ۲۰۲۳؛ Li و همکاران، ۲۰۲۳)، تخلخل و پیش‌بینی پارامترهای هیدرولیکی خاک نظیر نقطه پژمردگی، ظرفیت زراعی و هدایت هیدرولیکی اشباع خاک را تحت تأثیر قرار می‌دهد (Akpa و همکاران، ۲۰۱۴؛ Vaudour و همکاران، ۲۰۱۹؛ Zheng و همکاران، ۲۰۲۳)؛ بنابراین کمبود اطلاعات در مورد اجزاء بافت خاک منجر به مدیریت نامناسب خاک، فعالیت‌های کشاورزی و محیط‌زیستی خواهد شد (Keshavarzi و همکاران، ۲۰۲۲؛ Zeraatpishah و همکاران، ۲۰۱۹). این موضوع در دشت‌های سیلابی به دلیل تغییرات زیاد اجزاء بافت خاک (پهلوان راد و همکاران، ۲۰۱۸ و Wälder و همکاران، ۲۰۰۷) اهمیت مضاعفی دارد. تهیه نقشه‌های بافت خاک در مقیاس بزرگ و به‌ویژه در دشت‌های آبرفتی به علت نیاز به برداشت نمونه بیشتر، وقت‌گیر، پرهزینه و نیاز به تجهیزات خاص و تکنسین‌های ماهر دارد؛ لذا از یک طرف با افزایش هزینه‌ها و صرف زمان زیاد روبرو است و از سویی دیگر نقشه‌های تولید شده دقت و جزئیات کمتری از نحوه پراکنش مکانی اجزاء بافت را تشریح می‌کند (Dhiman و همکاران، ۲۰۲۳؛ Dornik و همکاران، ۲۰۲۲؛ Mallah و همکاران، ۲۰۲۲)؛ بنابراین یافتن راه‌حلی که علاوه بر کاهش هزینه‌ها و مدت‌زمان انجام کار از دقت کافی نیز برخوردار باشد، دارای اهمیت است. تولید نقشه‌های مکانی خصوصیات خاک با تأکید بر داده‌های سنجش‌ازدور به‌ویژه در مناطق خشک و نیمه‌خشک به‌عنوان راهکاری سودمند برای تولید نقشه

پیوسته خصوصیات خاک بادقت بالا و هزینه و زمان کمتر توصیه شده است (Chagas و همکاران، ۲۰۱۶؛ Ben-Dor و همکاران، ۲۰۰۸؛ Zhou و همکاران، ۲۰۲۰؛ Wu و همکاران، ۲۰۱۹؛ Poggio و Gimona، ۲۰۱۷).

در روش‌های تولید نقشه‌های پیوسته خصوصیات خاک نظیر اجزاء بافت خاک برای یافتن ارتباط بین متغیرها و خصوصیت خاک از روش‌های مختلفی نظیر شبکه عصبی<sup>۱</sup>، روش‌های هیبریدی زمین آماری<sup>۲</sup>، درخت تصمیم<sup>۳</sup> و سایر مدل‌ها استفاده می‌شود. مدل‌های هیبریدی زمین آماری روش‌های جدیدی هستند که در سال‌های اخیر برای مدل‌کردن تغییرات غیرخطی متغیرهای مکانی خصوصیات خاک‌ها ارائه شده‌اند. این مدل‌ها از ترکیب روش‌های زمین آماری و شبکه عصبی مصنوعی به وجود می‌آیند. از جمله این مدل‌ها می‌توان به مدل ترکیبی رگرسیون کریجینگ با کریجینگ باقی‌مانده شبکه عصبی<sup>۴</sup> (RKNNRK) و مدل رگرسیون کریجینگ اشاره کرد (Padarian و همکاران، ۲۰۱۲؛ Song و همکاران، ۲۰۱۷؛ Tarasov و همکاران، ۲۰۱۷).

Padarian و همکاران (۲۰۱۲) الگوی توزیع کربن آلی خاک را در خاک‌های چایل با استفاده از روش‌های زمین آماری کریجینگ معمولی، کوکریجینگ، کریجینگ معمولی با واریوگرام محلی و کریجینگ باقی‌مانده شبکه عصبی<sup>۵</sup> (NNRK) بررسی کردند که همه مدل‌ها نتایج آماری خوبی را ارائه دادند.

Dai و همکاران (۲۰۱۴) تغییرات مکانی کربن آلی خاک را با استفاده از روش ترکیبی باقی‌مانده کریجینگ معمولی با شبکه عصبی (ANN-kriging)، شبکه عصبی و وزن دهی عکس فاصله<sup>۶</sup> (IDW) در منطقه‌ای مسطح در کشور چین پیش‌بینی کردند و نتیجه گرفتند که دقت روش ترکیبی باقی‌مانده کریجینگ معمولی با شبکه عصبی

1-Artificial Neural Network

2-Hybrid Geostatistics

3-Decision Tree

4 - Regression Kriging And Neural Network Residual Kriging

5 - Neural Network Residual Kriging

6 - Invers Distance Weighting

(GRNNRK) بررسی کردند و نتیجه گرفتند که مدل‌های GRNNRK و <sup>۷</sup>MLPRK داری بهترین دقت پیش‌بینی در مقایسه با مدل‌های <sup>۸</sup>MLP و <sup>۹</sup>GRNN بودند. مروری بر مطالعات پیشین نبود یا کمبود مطالعات در زمینه کاربرد مدل‌های هیبریدی را در بررسی پراکنش مکانی خصوصیات فیزیکی خاک‌ها در دشت‌های سیلابی و در مقیاس منطقه‌ای نشان می‌دهد. این تحقیق باهدف پیش‌بینی الگوی تغییرات مکانی اجزاء بافت خاک اراضی کشاورزی دشت سیستان واقع در شمال استان سیستان و بلوچستان و جنوب شرقی ایران با استفاده از روش هیبریدی RKNRK می‌باشد.

## مواد و روش‌ها

### منطقه مورد مطالعه

منطقه مورد مطالعه شامل اراضی کشاورزی دشت سیستان واقع در شمال استان سیستان و بلوچستان در محدوده جغرافیایی ۶۰/۲۵ درجه تا ۶۱/۸۳ درجه طول شرقی و ۳۰/۰۸ درجه تا ۳۱/۴۶ درجه عرض شمالی با مساحت ۱۳۰۰ کیلومترمربع است (شکل ۱). آب و هوای منطقه بر اساس طبقه‌بندی کوپن، آب و هوای گرم و خشک با میانگین دراز مدت سالیانه بارش، درجه حرارت و تبخیر و تعرق پتانسیل به ترتیب ۵۵ میلیمتر، ۲۱/۷ درجه سانتی‌گراد و ۴۵۰۰ میلیمتر می‌باشد. کاربری اراضی منطقه زمین‌های بایر، مرتع، جنگل‌کاری، زمین‌های کشاورزی، مجموعه‌های آبی و شن‌زار است. اراضی دشت نسبتاً مسطح بوده و از لحاظ ژئومورفولوژی دشت آبرفتی متأثر از رسوبات انشعابات رودخانه هیرمند می‌باشد. رژیم‌های رطوبتی و حرارتی خاک به ترتیب اریدیک و هایپرترمیک است. اراضی محدوده دارای شیب بسیار جزئی بوده و فاقد پستی و بلندی قابل ملاحظه‌ای است. تنها منبع آب سطحی موجود در این منطقه، رودخانه هیرمند و رودخانه‌های

(ANN-kriging) در مقایسه با سایر روش‌های زمین‌آماری بیشترین است.

Mirzaee و همکاران (۲۰۱۶) بررسی تغییرات مکانی کربن آلی خاک را با استفاده از داده‌های سنجش از دور در منطقه سلین در شمال آذربایجان شرقی ایران انجام دادند که در این مطالعه از مدل‌های زمین‌آماری و مدل‌های هیبریدی استفاده شد و نتیجه گرفتند که مدل‌های هیبریدی شامل کریجینگ ساده با رگرسیون<sup>۱</sup>، کریجینگ معمولی با رگرسیون<sup>۲</sup>، کریجینگ ساده با شبکه عصبی<sup>۳</sup> و کریجینگ معمولی با شبکه عصبی<sup>۴</sup> نتیجه واقعی‌تری نسبت به مدل‌های زمین‌آماری شامل کریجینگ ساده، کریجینگ معمولی و کوکریجین ارائه کردند.

Song و همکاران (۲۰۱۷) پیش‌بینی توزیع مکانی کربن آلی خاک در منطقه‌ای در شرق چین را با استفاده از روش‌های هیبریدی و کریجینگ معمولی انجام دادند و نتیجه گرفتند که دقت پیش‌بینی مدل<sup>۵</sup> ELMOK در مقایسه با سایر روش‌ها افزایش یافته است.

Zhang و همکاران (۲۰۱۳) به درون‌یابی مکانی بافت خاک با استفاده از کریجینگ ترکیبی و رگرسیون کریجینگ با در نظر گرفتن ویژگی‌های ترکیبی داده‌ها و متغیرهای کمکی پرداختند. هدف آنها مقایسه عملکرد روش مکانی پیش‌بینی بافت خاک با توجه به ویژگی‌های داده‌های ترکیبی و متغیرهای کمکی بودند. پیش‌بینی مدل با استفاده از روش ترکیبی کریجینگ از دقت بالاتری برخوردار بود و آن‌ها نتیجه گرفتند که در صورت انتخاب متغیرهای مناسب به‌عنوان متغیر کمکی، پیش‌بینی تغییرات مکانی بافت خاک منطقی خواهد بود.

Tarasov و همکاران (۲۰۱۷) تغییرات مکانی آلودگی خاک‌های سطحی در کشور روسیه را با استفاده از مدل ترکیبی شبکه عصبی مصنوعی و کریجینگ باقی‌مانده<sup>۶</sup>

- 1 - Regression-Simple Kriging
- 2 - Regression-Ordinary Kriging
- 3 - Artificial Neural Network-Simple Kriging
- 4 - Artificial Neural Network-ordinary Kriging
- 5 - Extreme Learning Machine-Ordinary Kriging
- 6 - Generalized Regression Neural Network Residual Kriging

7 - Multi-Layer Perceptron Residual Kriging

8 - Multi-Layer Perceptron

9 - Generalized Regression Neural Network

منشعب از آن است که از کوه‌های هندوکش در افغانستان سرچشمه گرفته و حوزه آبریز وسیعی را شامل می‌شود (پهلوان‌راد و همکاران، ۲۰۲۰).

### نمونه برداری‌ها و متغیرهای کمکی

در این تحقیق بر اساس روش تصادفی طبقه‌بندی شده در سری‌های مختلف خاک تعداد ۱۶۰ نقطه انتخاب گردید و سپس نمونه برداری‌ها از لایه سطحی خاک (۰-۳۰ cm) انجام شد. شکل (۱) موقعیت نقاط نمونه برداری را نشان می‌دهد. درصد اجزاء بافت خاک از روش هیدرومتري و مطابق با استاندارد بین‌المللی خاکشناسی تعیین گردید. همچنین از داده‌های سنجش از دور تصویر ماهواره لندست ۸ شامل تصاویر باندهای ۱ تا ۸ و شاخص‌های پوشش گیاهی<sup>۱</sup> (NDVI)، شاخص روشنایی<sup>۲</sup>، اندازه ذرات خاک<sup>۳</sup> (GSI) و شاخص رس<sup>۴</sup> (جدول ۱) به عنوان متغیرهای کمکی برای میان‌یابی اجزاء بافت خاک کمک گرفته شد. بدین منظور تصویر ماهواره لندست در سطح LIT که بالاترین سطح تصاویر ماهواره لندست از نظر کیفیت، تصحیحات هندسی و رادیومتریکی دارد، انتخاب شد برای انجام تصحیحات هندسی از نقشه آبراهه‌ها و رودخانه‌ها، دریاچه‌ها، جاده‌ها و سایر نقاط ثابت موجود در منطقه استفاده شد و مطابق راهنمای استفاده از تصاویر لندست ۸ تصحیحات رادیومتری و اتمسفری در نرم افزار ENVI3.5 انجام شد. بعد از آماده‌سازی تصاویر باندهای مختلف و انجام محاسبات مربوطه، موقعیت جغرافیایی نقاط نمونه‌برداری شده زمینی بر روی تصاویر در محیط نرم‌افزار Arc Gis10.5 منتقل و ارزش رقومی<sup>۵</sup> (DN) هر پیکسل مرکزی استخراج و از آنها به عنوان متغیر مستقل و داده‌های اندازه‌گیری شده اجزاء بافت خاک به عنوان متغیر وابسته استفاده شد.

۱ - Normalized Difference Vegetation Index

۲ - Brightness Index

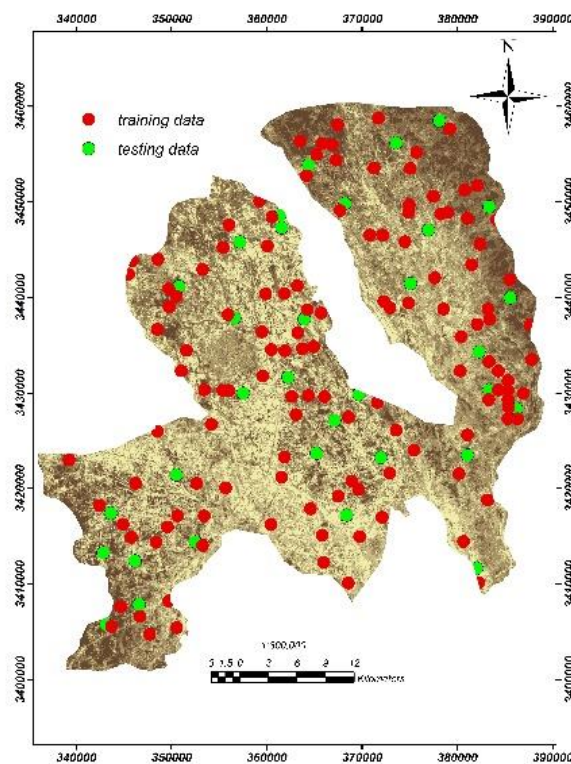
۳ - Grain Size Index

۴ - Clay Index

۵ - Digital Number

جدول ۱- مشخصات متغیرهای کمکی مورد استفاده برای پیش بینی اجزاء بافت خاک

متغیرهای محیطی	تعریف	منبع
Band 1	coastal	
Band 2	Blue Band	
Band 3	Green Band	
Band 4	Red Band	
Band 5	NIR Band	
Band 6	SWIR Band	
Band 7	SWIR Band	
Band 8	Panchromatic Band	
Band 4 / Band 3	Ratio Red and Green Bands	
Band 4 / Band 8	Ratio Red and Panchromatic Bands	
Brightness index	$((Red)^2 + (NIR)^2)^{0.5}$	Metternich and zinck (2003)
Grain Size Index (GSI)	$(Red-Blue) / (Red+Blue+Green)$	Xiao et al (2006)
Normalized Difference Vegetation Index (NDVI)	$(NIR-Red) / (NIR+Red)$	Boettinger et al (2008)
Clay Index	Ratio Band 6 and Band 8	Boettinger et al (2008)



شکل ۱- موقعیت نقاط نمونه برداری شده

### تبدیل داده‌های اجزاء بافت خاک

داده‌های بافت خاک به دلیل اینکه مجموع درصد‌های اجزاء آن شامل درصد‌های رس، شن و سیلت برابر با ۱۰۰ است به عنوان رایج‌ترین داده ترکیبی خاک

محسوب می‌شود. داده مرکب داده‌ای است که دارای چند جزء غیر منفی است که مجموع آنها برابر با واحد است یکی از مشکلات برآورد این گونه داده‌ها این است که اگر هر جزء به طور جداگانه برآورد شود، تضمینی وجود ندارد که مجموع اجزاء برآوردی برابر با ۱۰۰ شود (Lark و Bishop, ۲۰۰۷؛ Adhikari و همکاران، ۲۰۱۳؛

در این تحقیق با استفاده از بسته نرم‌افزاری Codapack داده‌های اجزاء بافت خاک به دو جزء مطابق با روابط (۳) و (۴) تبدیل گردید:

$$clay_{atr} = \ln \frac{clay}{sand} \quad (3)$$

$$silt_{atr} = \ln \frac{silt}{sand} \quad (4)$$

### مدل‌سازی‌ها

#### روش رگرسیون کریجینگ (RK)

این روش شامل یک مدل رگرسیونی (رابطه رگرسیونی بین متغیرهای کمکی و اجزاء بافت خاک) و کریجینگ (برای پیش‌بینی مکانی باقی‌مانده‌های مدل رگرسیونی) بوده و با استفاده از روابط ۵ و ۶ تعریف می‌شود (Odeh و همکاران، ۲۰۰۳):

$$Z_{RK} * (u_i) = m(u_i) + e(u_i) \quad (5)$$

$$Z_{RK} * (u_i) = \sum_{k=1}^p \beta_k q_k(u_i) + \sum_{j=1}^n w_j(u_i) e(u_i), \quad q_k(u_i) \equiv 1; j = 1, \dots, n \quad (6)$$

که در این رابطه  $Z_{RK}(u_i)$  مقدار پیش‌بینی شده در نقطه  $u$ ،  $m(u_i)$  بخش قطعی روند،  $\beta_k$  ضرایب مدل روند،  $q_k(u_i)$  پیش‌بینی‌کننده‌ها،  $w_j(u_i)$  وزن‌های کریجینگ هستند که با استفاده از تابع نیم تغییرنا تعیین شده و  $e(u_i)$  باقی‌مانده از رگرسیون در نقطه  $u_i$  است.

باتوجه به اینکه رابطه بین متغیرهای کمکی و اجزاء بافت خاک یک رابطه غیرخطی است. برای پیدا کردن ارتباط بین متغیرهای کمکی و داده‌های اجزاء بافت خاک از رگرسیون درختی استفاده شد. به‌طور کلی روش رگرسیون طی مراحل زیر ایجاد شده است. ۱) ایجاد رگرسیون درختی بین متغیرهای کمکی و اجزاء بافت خاک (۲) پیش‌بینی اجزاء بافت خاک با استفاده از مدل رگرسیون درختی (۳) محاسبه باقی‌مانده‌ها و تخمین باقی‌مانده‌ها با استفاده از روش کریجینگ. تخمین‌های نهایی از حاصل جمع مقادیر پیش‌بینی مدل رگرسیون درختی (مرحله ۲) و

تاکنون و در روش‌های معمول و متداول برآورد داده‌های بافت خاک مرکب بودن آن در نظر گرفته نشده است که در نتیجه یا مجموع اجزاء برآوردی برابر با ۱۰۰ نمی‌شود و یا دو جزء برآورد شده و سپس جزء سوم از اختلاف دو جزء برآوردی از ۱۰۰ محاسبه می‌شود که در این حالت نیز با وجود اینکه مجموع جزءهای پیش‌بینی برابر ۱۰۰ می‌شود ولی بسته به اینکه کدام دو جزء ابتدا برآورد گردد، نتایج متفاوتی حاصل می‌شود (Lark و Bishop، ۲۰۰۷). لذا با توجه به اینکه در یک داده‌های بافت خاک نسبت‌های رس، سیلت و شن مستقل از هم نیستند و حداقل یک همبستگی منفی بین دو جزء وجود دارد، لذا برآورد اجزاء بافت خاک به طور جداگانه و بدون در نظر گرفتن این همبستگی منطقی نیست (Odeh و همکاران، ۲۰۰۳). از راهکارهای حل این‌گونه مسائل تبدیل داده‌ها قبل از پیش‌بینی است (Aitchison، ۱۹۸۶). روش‌های مختلفی برای تبدیل داده‌ها وجود دارد که اکثراً روش‌های لگاریتمی هستند (Shi و Wang، ۲۰۱۷). تبدیل لگاریتمی  $alr$  رایج‌ترین تبدیل برای پیش‌بینی اجزاء بافت خاک در مدل‌های رگرسیونی (Akpaka و همکاران، ۲۰۱۴؛ Huang و همکاران، ۲۰۱۴) و مدل‌های زمین‌آماري (Dobarco و همکاران، ۲۰۱۶؛ Odeh و همکاران، ۲۰۰۳) است. تبدیل  $alr$  بر روی یک داده ترکیبی ( $z$ ) با تعداد ( $D$ ) جزء با استفاده از رابطه (۱) و (۲) اعمال می‌شود (Aitchison، ۱۹۸۶):

$$alr(z) = \left( \ln \frac{z_1}{z_2} \dots \ln \frac{z_{D-1}}{z_D} \right) \quad (1)$$

$$\sum_{i=1}^D z_i = 1 \quad z = [1 \dots D]$$

$$z = \frac{\exp(w)}{j^T \exp(w)} \quad (2)$$

که  $w = [x^T, 0]^T$  و  $j$  یک بردار و  $D$  برابر تعداد اجزاء داده ترکیبی است.

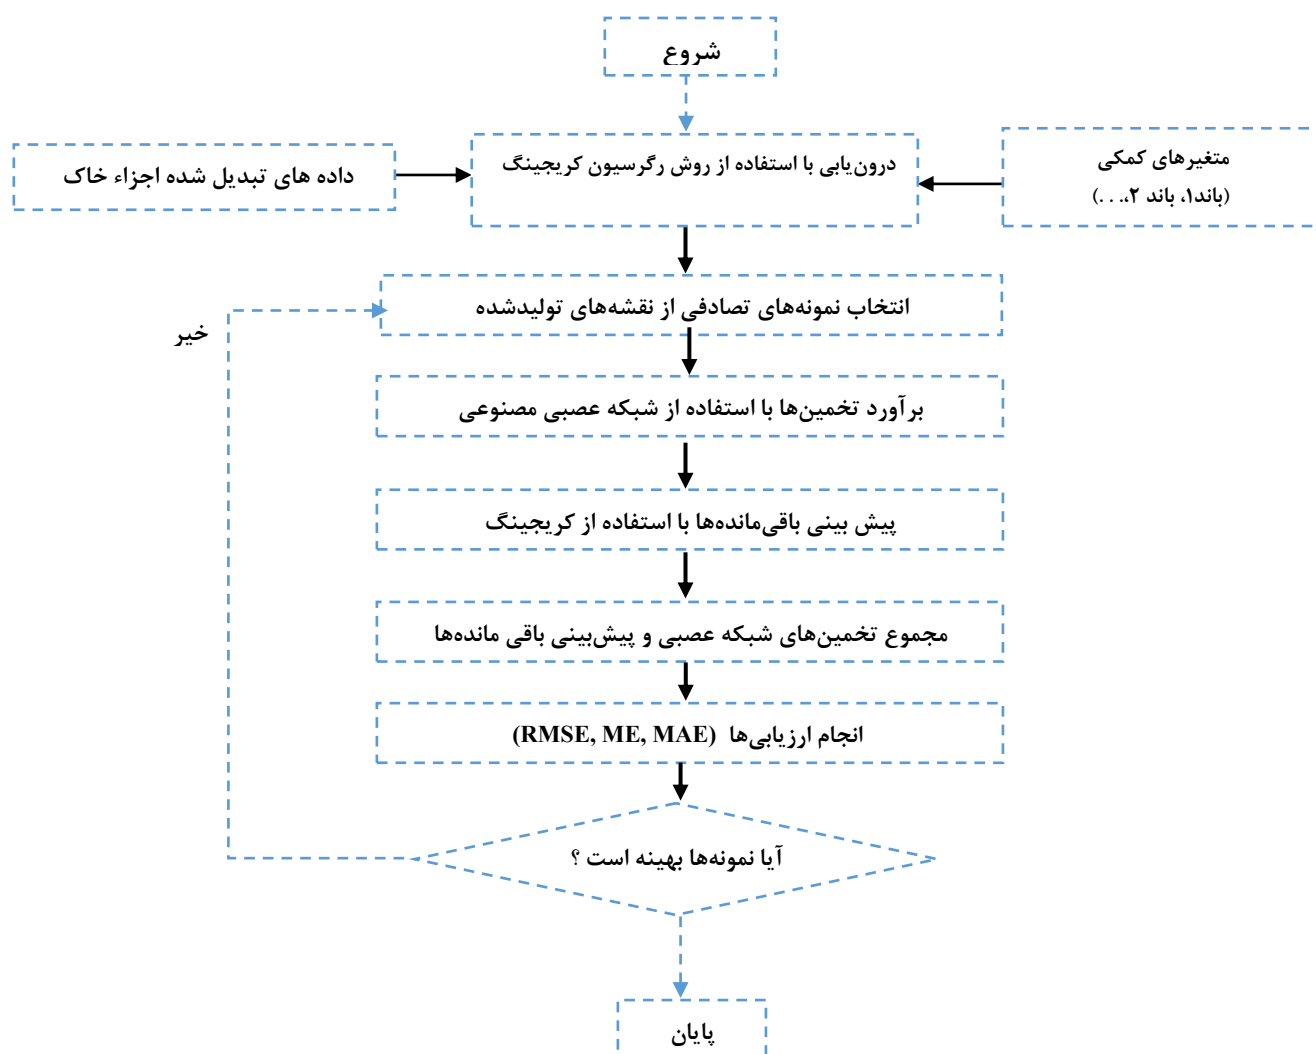
مقادیر برآورد شده باقی‌مانده‌ها (مرحله ۳) حاصل می‌شود.

کل فرایند آن‌قدر تکرار می‌شود تا تعداد بهینه نمونه برای مدل‌کردن روند مکانی پیدا شود و تعداد بهینه نمونه بر اساس شاخص‌های ارزیابی تعیین می‌شود. در این مطالعه ابتدا از نقشه‌های تهیه شده داده‌های پیش‌بینی به روش رگرسیون کریجینگ نمونه‌های ۱۰۰، ۲۵۰، ۴۰۰، ۶۵۰، ۹۰۰، ۳۰۰۰ و ۵۵۵۰ تایی با استفاده از نرم‌افزار Arc Gis 10.5 انتخاب شدند با استفاده از نرم‌افزار Matlab 2015b شبکه عصبی مناسب پیاده‌سازی شد. محاسبه باقی‌مانده‌ها و میان‌یابی آن‌ها در روش کریجینگ با استفاده از نرم‌افزار GS<sup>+</sup> انجام شد و مقدار نهایی از حاصل جمع مقادیر پیش‌بینی باقی‌مانده‌ها و روند تخمین زده شده با شبکه عصبی به دست می‌آید. برای یافتن تعداد نمونه بهینه این فرایند برای تمام نمونه‌ها ادامه یافت تا زمانی که معیارهای ارزیابی یکسانی حاصل شود. الگوریتم مراحل انجام روش RKNRRK در شکل (۲) ارائه شده است.

## روش ترکیبی رگرسیون کریجینگ و باقی‌مانده شبکه عصبی مصنوعی

این روش یک مدل درون‌یابی مکانی است که ترکیبی از روش رگرسیون کریجینگ، شبکه‌های عصبی مصنوعی و کریجینگ باقی‌مانده است. در واقع این مدل تنها از داده‌های مشاهده‌ای به‌عنوان داده‌های آموزش استفاده نمی‌کند، بلکه از داده‌هایی که به‌صورت تصادفی از نقشه‌های میان‌یابی شده توسط روش رگرسیون کریجینگ استخراج شده است، نیز برای تخمین روند مکانی استفاده می‌کند. این مدل شامل یک الگوریتم‌های چهارمرحله‌ای است. مرحله‌ی اول شامل میان‌یابی مکانی با استفاده از رگرسیون کریجینگ است. مرحله‌ی دوم شامل نمونه-برداری تصادفی از نقشه‌ی درون‌یابی شده است. مرحله‌ی سوم شامل تخمین روند مکانی با استفاده از شبکه عصبی مصنوعی است و مرحله‌ی چهارم شامل درون‌یابی باقی‌مانده‌ها با استفاده از روش کریجینگ است و تخمین‌های نهایی با جمع روند مکانی و باقی‌مانده‌ها به دست می‌آیند.





شکل ۲- فلوجارت روش RKNNRK

## نتایج و بحث

### تحلیل‌های آماری

بوده که بیانگر ناهمگنی بافت خاک منطقه می‌باشد. میانگین مقدار شن و سیلت خاک ۳۸ و ۴۳ درصد و میانگین مقدار رس خاک ۲۰ درصد است که بیانگر بافت متوسط خاک در منطقه می‌باشد. مشابه درصد اجزاء بافت خاک متغیرهای کمکی مورد استفاده نیز مورد تحلیل‌های آماری قرارگرفت که نتایج بیانگر این است که تفاوت معنی‌داری در داده‌ها وجود ندارد. همه متغیرهای کمکی

### معیارهای ارزیابی

در این تحقیق برای بررسی دقت و ارزیابی مدل، داده‌ها به دودسته داده‌های آموزش و داده‌های آزمون تقسیم شدند، ۸۰ درصد به داده‌های آموزش و ۲۰ درصد به داده‌های آزمون اختصاص یافتند. مدل‌سازی بر روی داده‌های آموزش صورت‌گرفته و ارزیابی داده‌های آزمون بر اساس معیار ریشه دوم میانگین مربعات خطا (RMSE) و معیارهای MAE و MBE انجام شد.

رس مثبت و برای سیلت خاک منفی بوده که این ناهمگنی در تغییرات مکانی این اجزاء می باشد (Delbari و همکاران، ۲۰۱۱؛ Mitran و همکاران، ۲۰۱۸). همچنین بررسی خلاصه مشخصات آماری داده‌های تبدیل شده اجزاء بافت خاک (جدول ۳) بیانگر تغییرات زیاد  $Clay_{air}$  و  $Silt_{air}$  در منطقه است.

به جز شاخص پوشش گیاهی (NDVI) با ۳۲ درصد و شاخص اندازه ذرات خاک (GSI) با ۱۱۳ درصد، دارای ضریب تغییرات اندکی می‌باشند. که بیانگر همگن بودن متغیرهای کمکی مورد استفاده است. بررسی مقادیر چولگی داده‌ها نشان می‌دهد که داده‌ها از توزیع نرمال برخوردار هستند. مقادیر چولگی برای داده‌های شن و

جدول ۲- خلاصه آماری داده‌های پیش بینی و اعتبارسنجی اجزاء بافت خاک

خصوصیت	داده‌های پیش‌بینی					داده‌های آزمون				
	حداقل	حداکثر	میانگین	انحراف معیار	ضریب تغییرات	حداقل	حداکثر	میانگین	انحراف معیار	ضریب تغییرات
	درصد					درصد				
Clay	۴	۴۸	۲۰	۱۰	۵۱	۶	۴۰	۲۱	۹	۴۵
Silt	۲	۷۹	۴۳	۱۵	۳۵	۷	۷۶	۴۳	۱۴	۳۳
Sand	۶	۹۱	۳۸	۲۰	۵۳	۱۰	۸۲	۳۶	۱۹	۵۳

جدول ۳- خلاصه مشخصات آماری داده‌های تبدیل شده اجزاء بافت خاک

متغیر	داده‌های پیش‌بینی			داده‌های آزمون		
	حداقل	حداکثر	میانگین	انحراف معیار	انحراف معیار	ضریب تغییرات
$Clay_{air}$	-۳/۱۲	۱/۸۹	-۰/۶۰	۱/۰۶	-۲/۵۹	۱/۳۶
$Silt_{air}$	-۲/۹۰	۲/۴۰	-۰/۲۳	-۰/۹۸	-۲/۴۶	۱/۷۶

جدول ۴ - خلاصه آماری داده‌های پیش‌بینی و آزمون متغیرهای کمکی

متغیرهای کمکی	داده‌های اعتبارسنجی			داده‌های پیش‌بینی		
	ضریب تغییرات	انحراف معیار	میانگین	ضریب تغییرات	انحراف معیار	میانگین
Band 1	۱۰	۸	۸۰	۱۰	۸	۷۹
Band 2	۱۳	۱۰	۸۱	۱۲	۱۰	۸۰
Band 3	۱۶	۱۳	۸۰	۱۵	۱۲	۷۹
Band 4	۱۸	۱۴	۷۸	۱۷	۱۳	۷۷
Band 5	۱۵	۹	۵۹	۱۴	۸	۵۹
Band 6	۱۵	۲	۱۶	۱۴	۲	۱۶
Band 7	۱۷	۱	۵	۱۶	۱	۵
Band 8	۱۷	۱۳	۸۰	۱۷	۱۳	۷۹
Band 4 / Band 3	۳	-۰/۰۳	-۰/۹۶	۳	-۰/۰۳	-۰/۹۶
Band 4 / Band 8	۵	-۰/۰۵	-۰/۹۷	۳	-۰/۰۳	-۰/۹۷
Brightness	۱۶	۱۶	۹۷	۱۶	۱۵	۹۷
GSI	۱۲۵	-۰/۰۲	-۰/۰۲	۱۱۳	-۰/۰۲	-۰/۰۲
NDVI	۳۳	-۰/۰۴	-۰/۱۴	۳۲	-۰/۰۴	-۰/۱۲
clay index	۶	-۰/۰۱	-۰/۰۲	۶	-۰/۰۱	-۰/۰۲

## رابطه بین داده‌های سنجش‌ازدور (متغیرهای کمکی) و اجزاء بافت خاک

در جدول (۵) ضریب همبستگی پیرسون بین اجزاء بافت خاک شامل شن، سیلت و رس خاک و متغیرهای کمکی نشان داده شده است. نتایج بیانگر این است که شن خاک با همه متغیرهای کمکی به جز نسبت باند ۴ به باند ۸ همبستگی معنی‌داری دارد. بیشترین و کمترین همبستگی داده‌های شن خاک مربوط به باند ۸ برابر ۰/۳۳۸- و شاخص پوشش گیاهی برابر با ۰/۲۱ می باشد. Chagas و همکاران (۲۰۱۶) گزارش دادند که شن خاک با باند ۱ و نسبت باند ۵ به باند ۷ تصاویر ماهواره لندست ۷ رابطه معنی‌داری دارد و همچنین carvalho junior و همکاران (۲۰۱۴) در مطالعه خود یافتند که شن خاک با شاخص پوشش گیاهی، نسبت باند ۳ به باند ۷ و نسبت باند ۵ به باند ۷ تصاویر ماهواره لندست ۵ رابطه معنی‌داری ندارد. همچنین liao و همکاران (۲۰۱۳) گزارش دادند که شن خاک با باندهای ۲ تا ۵ و باند ۷ تصویر ماهواره لندست ۷ رابطه معنی‌دار مثبت دارد.

نتایج نشان داد که جزء سیلت خاک با متغیرهای کمکی باندهای ۱ تا ۵ و باند ۸ و شاخص روشنایی رابطه هم بستگی متوسطی دارد و با بقیه پارامترهای کمکی رابطه هم‌بستگی ضعیفی دارد. (جدول ۴) همچنین سیلت با نسبت باند ۴ به باند ۸ رابطه معنی‌داری ندارد. Chagas و همکاران (۲۰۱۶) رابطه هم‌بستگی غیرمعنی‌دار بین داده های سیلت و باندهای ۱ و ۲ و نسبت باند ۵ به باند ۷ تصاویر ماهواره لندست ۷ گزارش کردند. Sauza junior و همکاران (۲۰۱۱) نیز هم‌بستگی بالایی بین سیلت و باندهای ۱ تا ۸ تصاویر ماهواره ASTER گزارش دادند. همچنین هم‌بستگی پایین سیلت با متغیر های مطالعه شده توسط Islam و همکاران (۲۰۰۳) و weterlined و Stenberg (۲۰۱۰) گزارش شده است. همچنین liao و همکاران (۲۰۱۳) گزارش دادند که سیلت خاک با باند های ۲ تا ۵ و باند ۷ تصویر ماهواره لندست ۷ رابطه هم

بستگی معنی دار منفی دارد بطوریکه بیشترین مقدار آن با باند ۷ و به مقدار ۰/۴۵۳- می‌باشد. برای جزء رس خاک بالاترین ضریب هم بستگی به مقدار ۰/۲۶ مربوط به باند ۸ و کمترین آن مربوط به شاخص پوشش گیاهی برابر ۰/۱۶ برآورد شده است (جدول ۵). Chagas و همکاران (۲۰۱۶) رابطه هم‌بستگی بین متغیرهای کمکی با رس را مشابه شن گزارش دادند. carvalho junior و همکاران (۲۰۱۴) رابطه معنی‌داری بین رس و شاخص پوشش گیاهی، نسبت باند ۳ به باند ۲ و نسبت باند ۵ به باند ۷ گزارش کردند و رابطه غیرمعنی داری با نسبت باند ۳ به باند ۷ تصاویر ماهواره لندسیت ۵ گزارش دادند. همچنین liao و همکاران (۲۰۱۳) گزارش دادند که رس خاک با باندهای ۱ تا ۵ و باند ۷ تصویر ماهواره لندست ۷ رابطه هم‌بستگی معنی‌دار منفی دارد.

جدول ۵- ضریب هم‌بستگی بین اجزاء بافت خاک و متغیرهای کمی

متغیرهای کمی	اجزای بافت خاک					
	رس		سیلت		شن	
	P	r	p	r	p	r
Band 1	۰/۰۰۳	۰/۲۳۲	.	۰/۲۷۵	< ۰/۰۰۰۱	-۰/۳۲
Band 2	۰/۰۰۳	۰/۲۳۷	.	۰/۲۷۷	< ۰/۰۰۰۱	-۰/۳۲۳
Band 3	۰/۰۰۲	۰/۲۴۲	.	۰/۲۷۲	< ۰/۰۰۰۱	-۰/۳۲۳
Band 4	۰/۰۰۱	۰/۲۴۹	.	۰/۲۷۳	< ۰/۰۰۰۱	-۰/۳۲۶
Band 5	۰/۰۰۷	۰/۲۱۰	۰/۰۰۳	۰/۲۲۹	.	-۰/۲۷۷
Band 6	۰/۰۱۳	۰/۱۹۶	۰/۰۰۸	۰/۲۰۸	۰/۰۰۱	-۰/۲۵۴
Band 7	۰/۰۵۱	۰/۱۵۴	۰/۰۲۶	۰/۱۷۶	۰/۰۰۷	-۰/۲۱۱
Band 8	۰/۰۰۱	۰/۲۵۸	.	۰/۲۸۳	< ۰/۰۰۰۱	-۰/۳۳۸
Band 4 / Band 3	۰/۰۱۵	۰/۱۹۲	۰/۰۲۵	۰/۱۷۶	۰/۰۰۴	-۰/۲۲۴
Band 4 / Band 8	۰/۲۰۴	۰/۱۰۱**	۰/۲۵	۰/۰۹۱**	۰/۱۵۷	-۰/۱۱۲**
Brightness index	۰/۰۰۲	۰/۲۴	۰/۰۰۱	۰/۲۶۲	< ۰/۰۰۰۱	-۰/۳۱۵
GSI	۰/۰۰۵	۰/۲۱۹	۰/۰۰۹	۰/۲۰۷	۰/۰۰۱	-۰/۲۶۳
NDVI	۰/۰۳۷	-۰/۱۶۵	۰/۰۲۵	۰/۱۷۶	۰/۰۰۸	۰/۲۰۹
clay index	۰/۰۱	-۰/۲۰۳	۰/۰۰۹	۰/۲۰۶	۰/۰۰۱	۰/۲۵۲

\*\* در سطح احتمال ۹۵ درصد معنی دار نیست.

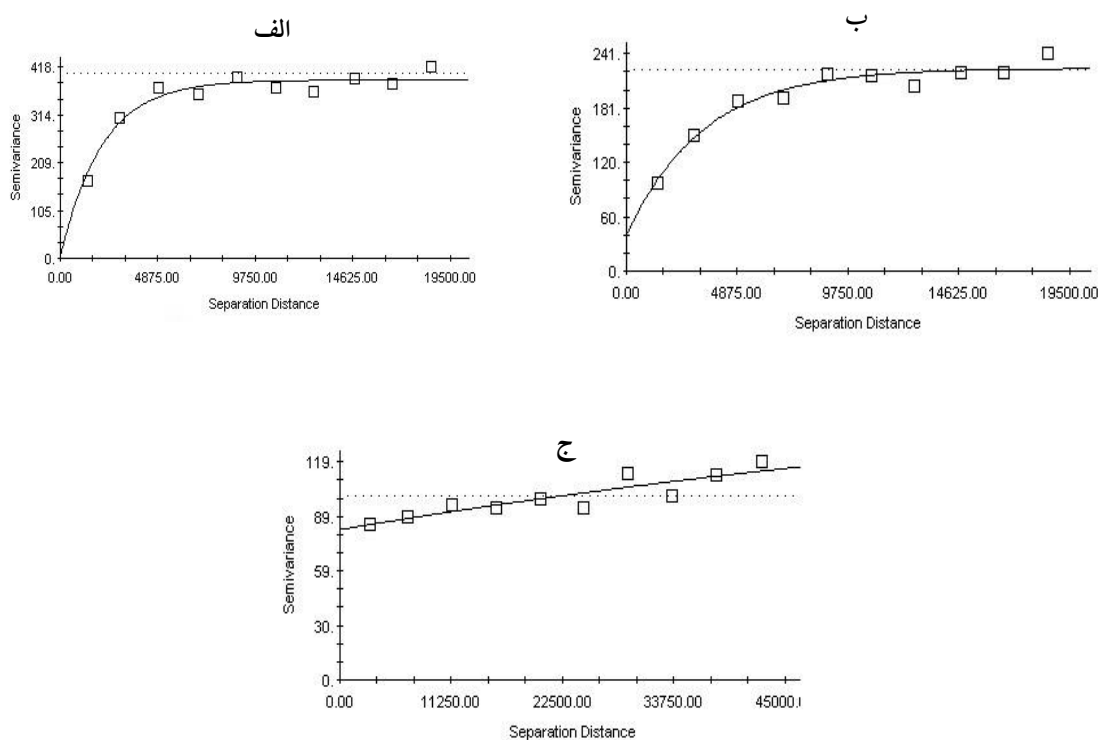
### تحلیل هم‌بستگی مکانی اجزاء بافت خاک

برای بررسی میزان هم‌بستگی مکانی اجزاء بافت خاک، نیم تغییرنمای تجربی اجزاء شن، سیلت و رس خاک با استفاده از نرم افزار GS<sup>+</sup> برآزش داده شد (Robertson, 2000). نیم تغییرنمای تجربی اجزاء بافت خاک در شکل (۳) و نتایج در جدول (۶) نشان داده شده است. نتایج نشان داد که جزء رس خاک از هم‌بستگی مکانی متوسطی در منطقه برخوردار است که با نتایج مطالعات دلبری و همکاران در سال ۲۰۱۱ همخوانی دارد. نسبت اثر قطعه‌ای به آستانه نیم تغییرنما برای سیلت خاک برابر ۱۷/۵ درصد بوده که بیانگر ساختار مکانی قوی است. Liao و همکاران در سال ۲۰۱۳ در جریان پیش‌بینی تغییرات مکانی اجزاء بافت خاک با استفاده از داده‌های سنجش‌ازدور ماهواره لندست یک ساختار مکانی متوسطی برای جزء سیلت گزارش دادند. همچنین زارعیان و همکاران در سال ۱۳۹۳ برای جزء سیلت خاک پیوستگی مکانی قوی گزارش کردند. در منطقه مورد مطالعه شن خاک ساختار مکانی قوی (۵/۰ درصد) دارد. دلبری و همکاران در سال ۲۰۱۱ و Liao و همکاران در سال ۲۰۱۳ و Mitran و همکاران در سال ۲۰۱۰ ساختار

مکانی قوی برای جزء شن خاک گزارش دادند. زارعیان و همکاران هم در سال ۱۳۹۳ برای جزء شن خاک وابستگی مکانی متوسطی گزارش کردند. مدل نمایی بیشترین انطباق را با نیم‌تغییرنمای تجربی اجزاء بافت خاک دارند. Mitran و همکاران در سال ۲۰۱۹ مدل گوسی را بهترین نیم‌تغییرنمای تجربی گزارش دادند. زارعیان همکاران در سال ۱۳۹۳ مدل نمایی و کروی را بهترین مدل گزارش کردند. Sokari و همکاران در سال ۲۰۱۳ مدل نمایی را بهترین مدل نیم تغییرنمای تجربی گزارش کردند. همچنین برای داده‌های تبدیل شده بافت خاک (جدول ۶) مدل نمایی بیشترین انطباق را با نیم تغییرنمای تجربی Silt<sub>alr</sub> و Clay<sub>alr</sub> دارد. ساختار مکانی Silt<sub>alr</sub> و Clay<sub>alr</sub> قوی برآورد شده است. درمورد نیم تغییرنمای داده‌های تبدیل شده بافت خاک مطالعات چندانی در دسترس نمی‌باشد.

جدول ۶- مشخصات بهترین مدل برازش داده شده بر نیم تغییرنمای تجربی

متغیر	مدل	اثر قطعه‌ای (Co)	آستانه (Co+C)	شعاع تأثیر (m)	(Co)/ (Co+C)	ساختار مکانی	R <sup>2</sup>	RSS
Sand	نمایی	۲	۳۸۹/۹	۳۹۲۸	۰/۵	قوی	۰/۹۴	۳۹۲۸
Silt	نمایی	۳۹/۳	۲۲۴/۵	۳۳۸۰	۱۷/۵	قوی	۰/۹۵	۷۷۳
Clay	نمایی	۱۷۴/۳	۸۱/۷	۱۰۱۰۰	۴۸/۶	متوسط	۰/۸۸	۲۱۶
Silt <sub>alt</sub>	نمایی	۰/۱	۰/۹۱	۷۶۲۰	۰/۱۱	قوی	۰/۷۷	۰/۰۷۵
Clay <sub>alt</sub>	نمایی	۰/۰۰۱	۱	۶۰۹۰	۰/۱	قوی	۰/۸۹	۰/۰۳۲
Re. silt <sub>alt</sub> (RK)	نمایی	۰/۱	۰/۴۷	۱۳۱۰۰	۲۱	قوی	۰/۶۷	۰/۰۱۷
Re. Clay <sub>alt</sub> (RK)	نمایی	۰/۲۸	۰/۵۷	۱۱۱۰۰	۴۹	متوسط	۰/۶۲	۰/۰۱۳
Re. silt <sub>alt</sub> (RKNNRK)	کروی	۰/۰۰۱	۰/۱۱	۶۳۱۰	۰/۰۹	قوی	۰/۹۹	۰/۰۰۰۳
Re. Clay <sub>alt</sub> (RKNNRK)	کروی	۰/۰۰۰۱	۰/۱۴	۶۲۸۰	۰/۰۷	قوی	۰/۹۹	۰/۰۰۰۴



شکل ۳- نیم تغییرنمای تجربی (مربعات توخالی) و مدل برازش شده (خط ممتد) (الف) شن، (ب) سیلت، (ج) رس (محور Xها، فاصله برحسب متر و محور Yها، نیم تغییرنما برحسب توان دو درصد است)

## ارزیابی روش‌ها

### روش رگرسیون کریجینگ

مشخصات بهترین مدل برازش داده شده بر نیم تغییرنمای تجربی باقی مانده داده‌های تبدیل شده در جدول (۶) ارائه شده است. بر اساس نتایج مدل نمایی بیشترین انطباق را با نیم تغییرنمای تجربی باقی مانده‌ها داشته است و ساختار مکانی باقی مانده‌های  $Silt_{air}$  قوی برآورد شد. ساختار مکانی باقی مانده‌های  $Clay_{air}$  (۴۹ درصد) متوسط است. همچنین خلاصه نتایج ارزیابی روش رگرسیون کریجینگ برای داده‌های آزمون در جدول (۷) نشان داده شده است. مقدار  $RMSE$  جزء شن برابر ۱۶/۵۶ درصد برآورد شده است. همچنین مقادیر  $ME$  و  $MAE$  برابر ۱-۱/۳۳ و ۱۳/۶۰ درصد برآورد شده است. بررسی مقادیر ضریب خطا داده‌های پیش‌بینی نشان می‌دهد که این روش در پیش‌بینی مقادیر شن بیش برازش داشته است. مقدار

$RMSE$  سیلت خاک به ترتیب برابر ۱۵/۸۱ درصد است. مقادیر ضریب خطا داده‌های پیش‌بینی نشان می‌دهد که این روش در پیش‌بینی مقادیر سیلت بیش برازش داشته است. نتایج مقدار  $RMSE$  جزء رس خاک برابر ۷/۴۳ برآورد شده است. همچنین مقدار  $ME$  و  $MAE$  برابر ۰/۵۸ و ۹/۱۱ درصد است. مقادیر ضریب خطا داده‌های پیش‌بینی نشان می‌دهد که این روش برای پیش‌بینی مقادیر رس کم برازش داشته است. در بررسی انجام شده توسط Akpa و همکاران در سال ۲۰۱۴ مقدار رس و سیلت در همه لایه‌ها بیش برازش و مقدار شن کم برازش داشته است. در مطالعه Adhikari و همکاران در سال ۲۰۱۳ مقدار رس را در همه لایه‌ها به جز لایه چهارم بیش برازش و در سه لایه خاک کم برازش، مقدار شن درشت در همه لایه‌ها و مقدار شن ریز در همه لایه‌ها به جز لایه سوم بیش برازش داشته است.

جدول ۷- نتایج ارزیابی روش رگرسیون کریجینگ

متغیر	RMSE	MAE	ME
Sand	۱۶/۵۶	۱۳/۶۰	-۱/۳۳
Silt	۱۵/۸۱	۱۲/۸۱	۱/۳۹
Clay	۷/۴۳	۹/۱۱	-۰/۵۸

## ارزیابی روش رگرسیون کریجینگ و کریجینگ

### باقی مانده شبکه عصبی

مشخصات بهترین نیم تغییرنمای تجربی برای داده‌های باقی مانده‌ها در جدول (۶) نشان داده شده است. ساختار مکانی مقادیر باقی مانده‌ها در این روش برای هر دو جزء  $Silt_{air}$  و  $Clay_{air}$  قوی برآورد شده است. بر اساس نتایج مدل کروی بیشترین انطباق را با نیم تغییرنمای تجربی باقی مانده‌ها داشته است. این روش به دلیل در نظر گرفتن تعداد بیشتری از داده‌ها برای درون‌یابی و مدل‌سازی روندها، دقت مناسبی برای پیش‌بینی اجزاء بافت خاک داشته است بطوریکه ضریب  $R^2$  مدل برای دو جزء  $Silt_{air}$  و  $Clay_{air}$  به ۰/۹۹ افزایش یافته و همچنین مقدار  $RSS$  برای هر دو جزء مذکور کاهش محسوس (۰/۰۰۳)

تا ۰/۰۰۰۴) داشته است. نتایج ارزیابی این روش در جدول (۸) نشان می‌دهد که مقدار  $RMSE$  برای اجزاء شن، سیلت و رس خاک برای داده‌های آزمون به ترتیب برابر ۱۵/۰۴، ۱۴/۳۰ و ۷/۱۸ درصد می‌باشد و مقادیر  $RMSE$  برای داده‌های پیش‌بینی ۸/۸۶، ۶/۰۳ و ۴/۸۹ برآورد شده است. پهلوان راد و اکبری مقدم (۲۰۱۸) مقدار  $RMSE$  را برای اجزاء شن، سیلت و رس خاک با استفاده از روش جنگل تصادفی به ترتیب ۲۱/۴، ۱۷/۴۵ و ۶/۰۲ درصد برآورد کردند. مقایسه مقادیر  $RMSE$  داده‌های پیش‌بینی و اعتبارسنجی نشان دهنده تفاوت این مقادیر با هم می‌باشد این تفاوت به دلیل تغییرات زیاد اجزاء بافت خاک در منطقه مورد مطالعه می‌باشد. محققین دیگر نیز در مطالعات خود نتایج مشابهی گزارش کردند. (پهلوان راد و همکاران، ۲۰۱۸؛ walder و همکاران ۲۰۰۸). بررسی

مقادیر ضریب ME بیانگر این است که این مدل در پیش‌بینی مقادیر شن و سیلت خاک بیش‌برازش و در پیش‌بینی رس کم‌برازش داشته است.

جدول شماره ۸- خلاصه نتایج ارزیابی روش RKNNRK

متغیر	داده‌های پیش‌بینی			داده‌های آزمون		
	RMSE	ME	MAE	RMSE	ME	MAE
Clay	۴/۸۹	-۰/۰۳	۳/۲۱	۷/۱۸	۰/۱۵	۸/۷۷
Silt	۶/۰۳	۰/۰۵	۴/۲۳	۱۴/۳۰	۱/۰۷	۱۱/۲۴
Sand	۸/۸۶	۰/۰۵	۵/۴۴	۱۵/۰۴	۱/۹۶	۱۲/۸۱

### مقایسه مدل‌ها

نتایج نشان داد که روش رگرسیون کریجینگ در مقایسه با روش هیبریدی RKNNRK از دقت کمتری در پیش‌بینی اجزاء بافت خاک برخوردار است. در روش رگرسیون کریجینگ مقادیر معیار ارزیابی RMSE نسبتاً بالا می‌باشد. قابلیت اطمینان کمتر این روش می‌تواند به دلیل عواملی از قبیل مسطح بودن منطقه، بزرگ بودن مقیاس مورد مطالعه (Knotters و همکاران ۱۹۹۵) ناهمگنی و غیر یکنواختی زیاد اجزاء بافت خاک در منطقه مورد مطالعه باشد (پهلوان راد و اکبری مقدم ۲۰۱۸؛ Walder و همکاران ۲۰۰۸). همچنین تعداد کم نمونه‌های برداشت شده نیز می‌تواند از جمله عوامل دیگر کمی دقت پیش‌بینی‌ها در این روش باشد. در این ارتباط Carvahو Junior و همکاران در سال ۲۰۱۴ نیز در رابطه با تعداد و تراکم نمونه‌ها، نتایج مشابهی را گزارش دادند؛ بنابراین توصیه می‌شود برای افزایش دقت مدل‌ها و در نتیجه با بردن دقت نقشه‌های تولیدی ویژگی‌های خاک، تعداد نمونه‌برداری‌های خاک در این مناطق باتوجه به مقیاس مورد مطالعه افزایش یابد و همچنین مطالعاتی در خصوص تعیین تعداد نقاط بهینه انجام گردد (پهلوان راد و همکاران ۲۰۲۰). باتوجه به اینکه در این تحقیق در روش رگرسیون کریجینگ از رابطه رگرسیون درختی و در روش RKNNRK از شبکه عصبی مصنوعی برای ارتباط بین متغیرهای کمکی و اجزاء بافت خاک استفاده شده است لذا می‌توان نتیجه گرفت که شبکه عصبی مصنوعی عملکرد بهتری در روندیابی و پیش‌بینی اجزاء بافت خاک

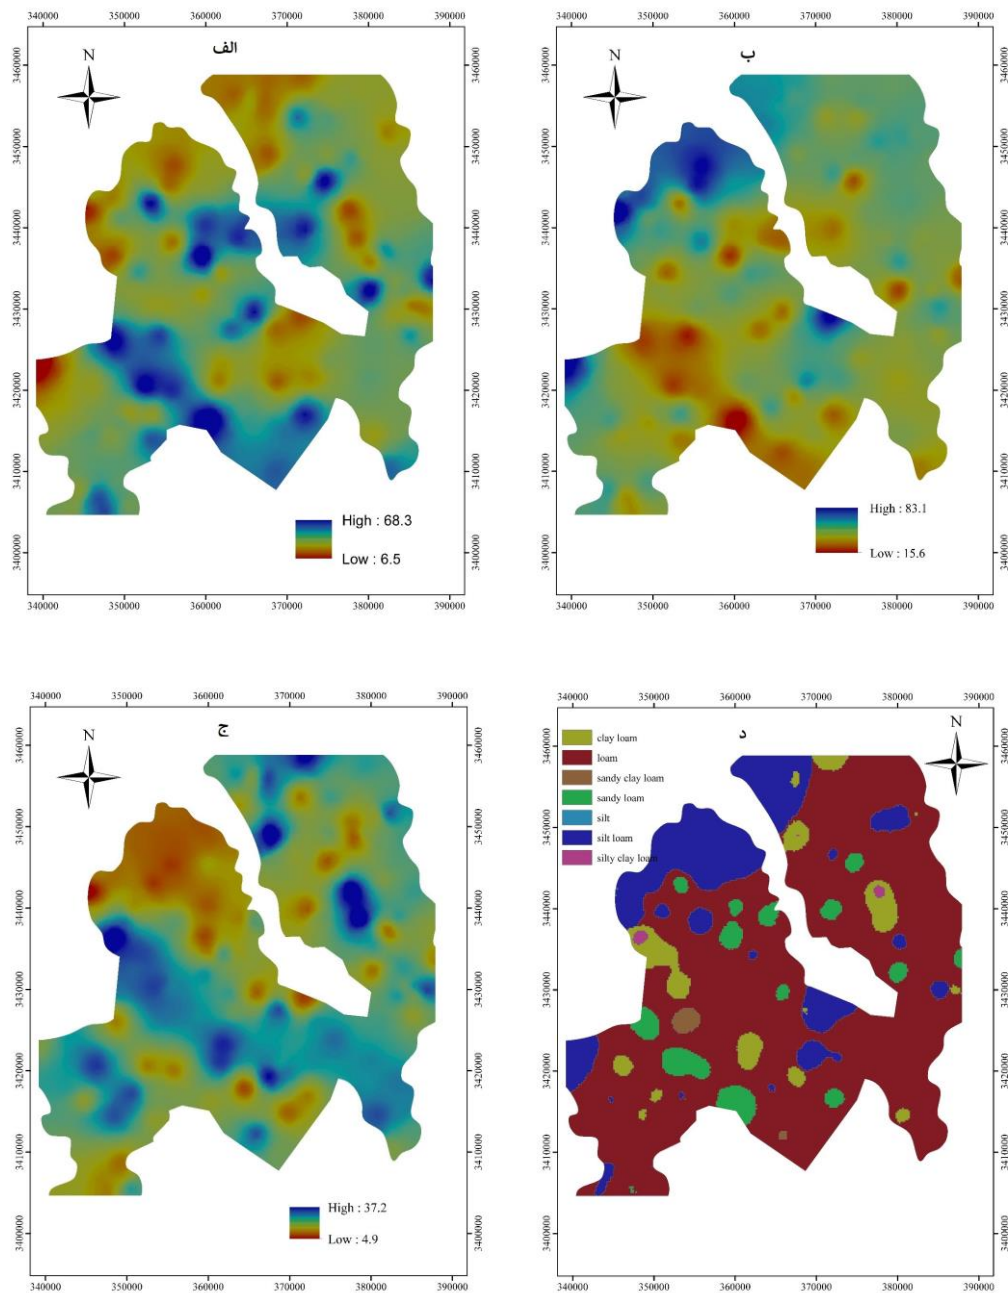
داشته است. به‌طور کلی نتایج بیانگر این است که روش RKNNRK بهترین عملکرد را در پیش‌بینی اجزاء بافت خاک منطقه مورد مطالعه داشته است؛ بنابراین مدل ترکیبی رگرسیون کریجینگ و کریجینگ باقی‌مانده شبکه عصبی مصنوعی در تلفیق با داده‌های سنجش‌ازدور به‌عنوان داده‌های کمکی، نقشه‌های مکانی اجزاء بافت خاک یک دشت آبرفتی را در مقیاس بزرگ با دقت قابل‌قبولی پیش‌بینی کرده است. Tarasov و همکاران (۲۰۱۷) در مطالعه خود دقت بیشتر مدل‌های هیبریدی را در پیش‌بینی آلودگی خاک‌های سطحی کشور روسیه گزارش دادند. همچنین shen و همکاران (۲۰۰۴) سودمند بودن روش باقی‌مانده کریجینگ شبکه عصبی برای پیش‌بینی خصوصیات خاک را در مقیاس بزرگ تأیید کرده‌اند. همچنین Dai و همکاران (۲۰۱۴) گزارش دادند که مدل هیبریدی ANN-kriging در مقایسه با روش‌های روش وزن‌دهی عکس فاصله و UK دقت بالایی در پیش‌بینی توزیع مکانی محتوی کربن آلی خاک دارد به دلیل اینکه خصوصیات فیزیکی خاک در دشت‌های سیلابی تابع وضعیت رسوب‌گذاری است (پهلوان راد و همکاران، ۲۰۲۰) پیشنهاد می‌شود در مطالعات آتی از شاخص‌های که به نحوی به این موضوع مرتبط است نظیر فاصله تا رودخانه‌ها، شبکه انهار و کانال‌ها، نقشه کاربری اراضی به‌عنوان متغیرهای کمکی برای درونیابی و ارزیابی مدل‌ها کمک گرفته شود.

## نقشه‌های پیش‌بینی اجزاء بافت خاک

نقشه پراکنش مکانی اجزاء شن، سیلت و رس و بافت خاک در شکل (۴) نشان داده شده است. نقشه رقومی شن نشان می‌دهد که بیشتر اراضی منطقه مورد مطالعه بین ۲۴ تا ۵۶ درصد شن دارند. توزیع مکانی شن خاک (شکل ۳ الف) نشان می‌دهد که بیشترین مقدار شن در نیمه مرکزی و جنوبی منطقه مورد مطالعه دیده می‌شود. این اراضی به دلیل قرار گرفتن در حاشیه رودخانه سیستان و رسوب ذرات درشت‌تر شن در آنها سبب شده مقدار شن در آنها بیشتر باشد. پراکنش مکانی سیلت خاک در شکل ۳ (ب) نشان داده شده است. حدود ۵۱/۱ درصد از سطح مورد مطالعه دارای سیلت ۴۰-۵۰ درصد است. بیشترین مقدار سیلت در بخش‌های شمال شرقی، شرقی و بخش‌های کمی از قسمت غربی منطقه مورد مطالعه را

شامل می‌شود. شکل ۳ (ج) نقشه توزیع مکانی رس خاک را نشان می‌دهد. مقدار رس خاک‌های اراضی مورد مطالعه پایین است بطوریکه ۵۶/۴ درصد اراضی بین ۱۶ تا ۲۴ درصد رس دارند. بیشترین مقدار رس خاک در اراضی نیمه شمالی منطقه مورد مطالعه مشاهده می‌شود. بافت خاک Loam مساحت عمده‌ای از منطقه مورد مطالعه را شامل می‌شود (شکل ۳ د) به‌طوریکه در مرکز، شمال شرق و جنوب منطقه به مقدار زیاد مشاهده می‌شود. بافت خاک غالب در شمال غرب منطقه بافت Silt Loam بوده که به صورت پراکنده در سایر نقاط نیز به مقدار کم مشاهده می‌شود بافت‌های دیگر مشاهده شده در منطقه شامل Sandy Loam، Clay Loam و Sandy Clay Loam بوده که به صورت پراکنده و محدود در بخش‌های مختلف محدوده مورد نظر یافت می‌شود.





شکل ۴- نقشه رقومی شن (الف)، سیلت (ب)، رس (ج) و بافت خاک (د)

## نتیجه‌گیری

مقادیر RMSE نسبتاً بالا می‌باشد که می‌تواند به دلیل عواملی از قبیل مسطح بودن منطقه، بزرگ بودن مقیاس مورد مطالعه، کم بودن تعداد نقاط نمونه‌برداری، ناهمگنی و غیر یکنواختی اجزاء بافت خاک در منطقه مورد مطالعه و همچنین نوع متغیرهای کمکی مورد استفاده باشد. با توجه به اینکه خصوصیات خاک در دشت‌های سیلابی تابع وضعیت رسوب‌گذاری می‌باشد، پیشنهاد می‌شود در مطالعات آبی از شاخص‌های که به نحوی به این موضوع مرتبط است نظیر فاصله تا رودخانه‌ها، شبکه انهار منطقه، نقشه کاربری اراضی به‌عنوان متغیرهای کمکی نیز استفاده شود. همچنین توصیه می‌شود مطالعاتی در خصوص تعیین تعداد نمونه بهینه در این مناطق انجام گردد.

در این مطالعه نقشه رقومی اجزاء بافت خاک در اراضی کشاورزی دشت سیستان با استفاده از مدل ترکیبی رگرسیون کریجینگ و کریجینگ باقی‌مانده شبکه عصبی (RKNNRK) انجام شد. از داده‌های سنجش‌ازدور ماهواره لندست ۸ به‌عنوان متغیرهای کمکی در مدل‌سازی‌ها استفاده شد. نتایج نشان داد که اجزاء شن و سیلت خاک در منطقه مورد مطالعه وابستگی مکانی قوی و رس خاک وابستگی مکانی متوسطی دارند. تحلیل‌های هم‌بستگی نشان داد که جزء شن خاک با متغیرهای کمکی باند‌های ۲ تا ۸ تصاویر ماهواره لندست ۸ و شاخص اندازه ذرات خاک، شاخص روشنایی و نسبت باند ۴ به باند ۳ تصویر ماهواره لندست ۸ رابطه هم‌بستگی معنی‌دار منفی و با شاخص پوشش گیاهی و شاخص رس رابطه هم‌بستگی معنی‌دار مثبت دارد. همچنین سیلت خاک با متغیرهای کمکی شامل باند ۱ تا باند ۸ شاخص پوشش گیاهی، شاخص اندازه ذرات خاک و شاخص روشنایی تصویر ماهواره لندست ۸ رابطه هم‌بستگی معنی‌دار مثبت و با شاخص رس رابطه هم‌بستگی معنی‌دار منفی دارد. همچنین رس خاک با متغیرهای کمکی باندهای ۱ تا ۵، باند ۸ شاخص اندازه ذرات خاک و شاخص روشنایی رابطه هم‌بستگی معنی‌دار مثبت و با شاخص رس رابطه هم‌بستگی معنی‌دار منفی دارد. روش هیبریدی RKNNRK توانسته است، نقشه‌های رقومی اجزاء بافت خاک را با دقت مناسبی پیش‌بینی کند بطوریکه مقدار RMSE برآورد شده در مقایسه با روش رگرسیون کریجینگ مقادیر کمتری دارد.

## Reference

1. Aitchison, J., 1986. *The Statistical Analysis of Compositional Data*. Chapman and Hall, London, UK, pp. 416.
2. Akpa, S.I.C., Odeh, I.O.A., Bishop, T.F.A., Hartemink, A.E., 2014. Digital mapping of soil particle size fractions for Nigeria. *Soil Sci. Soc. Am. J.* 78, 1953–1966.
3. Azizi, K., Garosi, Y., Ayoubi, S., and Tajik, S. 2023. Integration of Sentinel-1/2 and topographic attributes to predict the spatial distribution of soil texture fractions in some agricultural soils of western Iran. *Soil Tillage Res.* 229, 105681.
4. Amirian-Chakan, A., Minasny, B., Taghizadeh-Mehrjardi, R., Akbarifazli, R., Darvishpasand, Z., Khordehbin, S., Some practical aspects of predicting texture data in digital soil mapping.
5. Ben-Dor, E., Taylor, R.G., Hill, J., Demattê, J.A.M., Whiting, M.L., Chabrilat, S., Sommer, S., Donald, L.S., 2008. Imaging spectrometry for soil applications. *Adv. Agron.* 97, 321–392.
6. Boettinger, J.L., Ramsey, R.D., Bodily, J.M., Cole, N.J., Kienast\_Brown, S., Nield, S.J., Saundes, A.M., Stum, A.K., 2008. Landsat spectral data for digital soil mapping. In: Hartemink, A.E., McBratney, A.B., Mendonca Santos, M.L. (Eds.), *Digital Soil Mapping With Limited Data*. Springer science, Australia, pp. 193–203.
7. Carvalho Junior, W., Lagacherie, P., Chagas, C.S., Calderano Filho, B., Bhering, S.B., 2014. A regional-scale assessment of digital mapping of soil attributes in a tropical hillslope environment. *Geoderma* 232, 479–486.
8. Chagas, C.S., Junior, W.C., Bhering, S.B and Filho, B.C. 2016. Spatial prediction of soil surface texture in a semiarid region using random forest and multiple linear regressions. *Catena*, 139: 232–240
9. Dobarco, M.R., Orton, T.G., Arrouays, D., Lemerrier, B., Paroissien, J.B., Walter, C., Saby, N.P., 2016. Prediction of soil texture using descriptive statistics and area-to-point kriging in Region Centre (France). *Geoderma Regional*, 7, 279-292.
10. Dai, F., Zhou, Q., Lv, Z., Wang, X., Liu, G., 2014. Spatial prediction of soil organic matter content integrating artificial neural network and ordinary kriging in Tibetan Plateau, *Ecological Indicators*, 45, 184–194.
11. Dhiman, G., Bhattacharya, J., and Roy, S. 2023. Soil textures and nutrients estimation using remote sensing data in north India - Punjab region. *Procedia Comput. Sci.* 218, 2041–2048.
12. Dornik, A., Chețan, M. A., Drăguț, L., Dicu, D. D., and Iliuță, A. (2022). Optimal scaling of predictors for digital mapping of soil properties. *Geoderma* 405, 115453.
13. Dunkl, I., Ließ, M. 2022. On the benefits of clustering approaches in digital soil mapping: An application example concerning soil texture regionalization. 8, 541–558.
14. FAO. 2022. *The state of the world's land and water resources for food and agriculture 2021 – systems at breaking point*. Rome, Italy: FAO.
15. He, W., Xiao, Z., Lu, Q., Wei, L., Liu, X. Digital Mapping of Soil Particle Size Fractions in the Loess Plateau, China, Using Environmental Variables and Multivariate Random Forest. *Remote Sens.* 2024, 16, 785.
16. Huang, J., Subasinghe, R., Triantafyllis, J., 2014. Mapping particle-size fractions as a composition using additive log-ratio transformation and ancillary data. *Soil Science Society of America Journal* 78 (6), 1967-1976.
17. Islam, K., Singh, B., McBratney, A., 2003. Simultaneous estimation of several soil properties by ultra-violet, visible, and near infrared reflectance spectroscopy. *Aust. J. Soil Res.* 41, 1101–1114.
18. Keshavarzi, A., del Árbol, M. Á. S., Kaya, F., Gyasi-Agyei, Y., and Rodrigo-Comino, J. 2022. Digital mapping of soil texture classes for efficient land management in the Piedmont plain of Iran. *Soil Use Manag.* 38 (4), 1705–1735.

19. Lark, R.M., Bishop, T.F.A., 2007. Cokriging particle size fractions of the soil. *Eur. J. Soil Sci.* 58, 763-774.
20. Liao, K., Xu, S., Wu, J., Zhu, Q., 2013. Spatial estimation of surface soil texture using remote sensing data. *Soil Sci. Plant Nutr.* 59, 488-500.
21. Li, Q., Hu, Z., Zhang, F., Song, D., Liang, Y., and Yu, Y. 2023. Multispectral remote sensing monitoring of soil particle-size distribution in arid and semi-arid mining areas in the middle and upper reaches of the yellow river basin: a case study of wuhai city, Inner Mongolia autonomous region. *Remote Sens.* 15 (8), 2137.
22. Mgohele R.N., Massawe B.H.J., Shitindi M.J., Sanga HG and Omar M.M. 2024. Prediction of soil texture using remote sensing data. A systematic review. *Front. Remote Sens.* 5:1461537.
23. Mirzaee, S.; Ghorbani-Dashtaki, S.; Mohammadi, J.; Asadi, H.; Asadzadeh, F. Spatial variability of soil organic matter using remote sensing data. *Catena* 2016, 145, 118-127.
24. Odeh, I.O., Todd, A.J., Triantafyllis, J., 2003. Spatial prediction of soil particle-size fractions as compositional data. *Soil Sci.* 168, 501-515.
25. Mallah, S., Delsouz Khaki, B., Davatgar, N., Scholten, T., Amirian-Chakan, A., Emadi, M., et al. (2022). Predicting soil textural classes using random forest models: learning from imbalanced dataset. *Agronomy* 12 (Issue 11), 2613.
26. Padarian, J., Pérez-Quesada, J. and Seguel, O., 2012. Modelling the distribution of organic carbon in the soils of Chile. In: Minasny B, Malone BP, McBratney AB (eds), *Digital Soil Assessments and Beyond Proceedings of the 5th Global Workshop on Digital Soil Mapping* Taylor and Francis Group, London, pp 329-333
27. Pahlavan-Rad, M.R., K.H. Dahmardeh, M. Hadizadeh, G. Keykha, N. Mohammadnia, M. Gangali, M. Keikha, N. Davatgar, C. Brungard. 2020. Prediction of soil water infiltration using multiple linear regression and random forest in a dry flood plain, eastern Iran. *Catena*, 194(2020) 104715
28. Pahlavan-Rad, M.R., Akbarimoghaddam, A., 2018. Spatial variability of soil texture fractions and pH in a flood plain (case study from eastern Iran). *Catena* 160, 275-281.
29. Poggio, L., Gimona, A. 3D mapping of soil texture in Scotland. *Geoderma Reg.* 2017, 9, 5-16.
30. Robertson, G.P. 2000. *GS+: Geostatistics for the environment sciences. GS+ User's Guide Version 5: Plainwell, Gamma design software*, 200 p.
31. Song, Y.Q., yang, L.A., li, B., Hu, Y.M., wang, A.L., Zho, W., Cui, X.S. and liu, Y.L., 2017. Spatial Prediction of Soil Organic Matter Using a Hybrid Geostatistical Model of an Extreme Learning Machine and Ordinary Kriging. *Sustainability*, 754, 1-17
32. Tarasov, D.A., Buevich, A.G., Sergeev, A.P., Shichkin, A.V., 2017. High variation topsoil pollution forecasting in the Russian Subarctic: Using artificial neural networks combined with residual kriging, *Applied Geochemistry*, xxx, 1-10
33. Vaudour, E., Gomez, C., Fouad, Y., Lagacherie, P. Sentinel-2 image capacities to predict common topsoil properties of temperate and Mediterranean agroecosystems. *Remote Sens. Environ.* 2019, 223, 21-33.
34. Wang, Z., Shi, W., 2017. Mapping soil particle-size fractions: a comparison of compositional kriging and log-ratio kriging. *J. Hydrol.* 546, 526-541.
35. Wu, W., Yang, Q., Lv, J., Li, A., Liu, H. Investigation of remote sensing imageries for identifying soil texture classes using classification methods. *IEEE Trans. Geosci. Remote Sens.* 2019, 57, 1653-1663.
36. Xiao, J., Shen, Y., Tateishi, R., Bayaer, W., 2006. Development of topsoil grain size index for monitoring desertification in arid land using remote sensing. *Int. J. Remote Sens.* 12, 2411-2422.

37. Zeraatpisheh, M., Ayoubi, S., Jafari, A., Tajik, S., and Finke, P. 2019. Digital mapping of soil properties using multiple machine learning in a semi-arid region, central Iran. *Geoderma* 338, 445–452.
38. Zhang, SW., Shen, C.Y., Chen, X.Y., Ye, H.C., Huang, Y.F. and Lai, S. 2013. Spatial Interpolation of Soil Texture Using Compositional Kriging and Regression Kriging with Consideration of the Characteristics of Compositional Data and Environment Variables. *Journal of Integrative Agriculture*, 12(9): 1673-1683.
39. Zheng, M., Wang, X., Li, S., Zhu, B., Hou, J., Song, K. Soil Texture Mapping in Songnen Plain of China Using Sentinel-2 Imagery. *Remote Sens.* 2023, 15, 5351.
40. Zhou, Y., Wu, W., Liu, H. Exploring the Influencing Factors in Identifying Soil Texture Classes Using Multitemporal Landsat-8 and Sentinel-2 Data. *Remote Sens.* 2022, 14, 5571.