

The Matching Rate of Maps Obtained by Machine Learning Methods and Kriging Estimator in Salinity Monitoring of a Part of the Marginal Lands of Sirjan Playa, Kerman Province

Mojdeh Golestani¹, Zohreh Mosleh Ghahfarokhi^{2*}, Isa Esfandiarpour-Boroujeni³, Hossein Shirani⁴

(Received: August, 2023

Accepted: December, 2023)

Abstract

Satellite images and remote sensing approaches are important tools for evaluating, mapping, and managing saline lands in different world regions. The main aim of the present study was to investigate the degree of concordance between maps obtained by machine learning methods and kriging estimator about salinity monitoring of a part of the soils of marginal lands of Sirjan Playa in two seasons, i.e., winter and summer, using two remote sensing data sources, i.e., Landsat 8 and Sentinel 2. Ninety surface soil samples (zero to 30 cm) were collected as a regular grid sampling pattern with 750 meters intervals. Some of their most important physical and chemical characteristics were determined using standard measurement methods. After performing radiometric and atmospheric corrections on mentioned satellite images, in addition to the main bands, 13 salinity indices were used to estimate soil salinity using artificial neural network, decision tree, random forest, and support vector machine models. Besides, kriging maps of soil salinity were drawn for both mentioned times. Results showed a higher performance ($R^2 = 0.87$ versus 0.72) of Sentinel-2 than Landsat-8 in predicting soil salinity. Moreover, results confirmed that the ANN model developed by Sentinel-2A image had the highest performance ($R^2 = 0.77$, $RMSE\% = 27.1$) to predict EC_e in the winter season. Furthermore, RF presents the lowest error ($R^2 = 0.87$, $RMSE\% = 17.4$) for prediction EC_e during the summer season. Among the studied salinity indices, VSSI index was also selected as the most effective index to estimate soil salinity of region. The results also showed that EC_e maps obtained by two methods had a high level of concordance and an overall accuracy of over 80%; however, the change of season and type of satellite affected the compatibility of the maps.

Keywords: Sentinel 2, Salinity index, Kriging, Landsat 8, Modeling

Golestani M, Mosleh Ghahfarokhi Z, Esfandiarpour-Boroujeni I, Shirani H. 2024. The matching rate of maps obtained by machine learning methods and kriging estimator in salinity monitoring of a part of the marginal lands of Sirjan playa, Kerman province. *Applied Soil Research*, 12(3): 47-66.

¹- MSc Student of Soil Science Department, College of Agriculture, Vali-e-Asr University of Rafsanjan, Rafsanjan

¹- Assistant Prof. of Soil and Water Research Department, Chaharmahal and Bakhtiari Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Shahrekord, Iran

¹- Professor of Soil Science Department, Faculty of Agriculture, Vali-e-Asr University of Rafsanjan, Rafsanjan

¹- Professor of Soil Science Department, Faculty of Agriculture, Vali-e-Asr University of Rafsanjan, Rafsanjan

* Corresponding Author Email: Z.mosleh@areeo.ac.ir

میزان همخوانی نقشه‌های حاصل از روش‌های یادگیری ماشین و تخمینگر کریجینگ در پایش شوری بخشی از اراضی حاشیه‌ای پلایای سیرجان، استان کرمان

مژده گلستانی^۱، زهره مصلح قهفرخی^{۲*}، عیسی اسفندیارپور بروجنی^۳، حسین شیرانی^۴

(تاریخ دریافت: ۱۴۰۲/۰۶/۰۲ تاریخ پذیرش: ۱۴۰۲/۰۹/۲۸)

چکیده

تصاویر ماهواره‌ای و رویکردهای سنجش از دور، ابزار مهمی برای ارزیابی، نقشه‌برداری و مدیریت اراضی شور در مناطق مختلف جهان به‌شمار می‌آیند. هدف اصلی از مطالعه حاضر، بررسی میزان همخوانی نقشه‌های حاصل از روش‌های یادگیری ماشین و تخمینگر کریجینگ برای پایش شوری بخشی از خاک‌های حاشیه‌ای پلایای سیرجان در دو فصل زمستان و تابستان با استفاده از دو منبع داده سنجش از دور (لندست ۸ و سنتینل ۲) می‌باشد. ۹۰ نمونه خاک سطحی (صفر تا ۳۰ سانتی‌متر) در قالب یک الگوی نمونه‌برداری شبکه‌ای منظم با فواصل ۷۵۰ متر برداشت شد. برخی از مهمترین ویژگی‌های فیزیکی و شیمیایی آن‌ها با استفاده از روش‌های استاندارد اندازه‌گیری شد. همچنین پس از انجام تصحیح‌های رادیومتریک و اتمسفری بر روی تصاویر ماهواره‌ای مزبور، علاوه بر باندهای اصلی، از ۱۳ شاخص طیفی (شاخص شوری) به‌منظور تخمین شوری خاک با استفاده از مدل‌های شبکه عصبی مصنوعی، درخت تصمیم، جنگل تصادفی و ماشین بردار پشتیبان استفاده شد. به‌علاوه، نقشه‌های کریجینگ شوری خاک برای هر دو زمان گفته‌شده ترسیم شدند. نتایج نشان داد که ماهواره سنتینل ۲ نسبت به داده‌های ماهواره لندست ۸، از صحت بالاتری (ضریب تبیین ۰/۸۷ در مقابل ۰/۷۲) برای پیش‌بینی تغییرات شوری در منطقه مورد مطالعه برخوردار بود. علاوه بر این، بهترین نتایج برای برآورد قابلیت هدایت الکتریکی عصاره اشباع خاک در فصل زمستان با استفاده از تصاویر سنتینل ۲ و مدل شبکه عصبی مصنوعی ($R^2=0.77$, $RMSE\%=27.1$) و در فصل تابستان بر اساس تصاویر ماهواره سنتینل ۲ و مدل جنگل تصادفی ($R^2=0.87$, $RMSE\%=17.4$) برای منطقه مطالعاتی به دست آمدند. از بین شاخص‌های شوری مورد مطالعه، شاخص VSSI به‌عنوان مؤثرترین شاخص برای برآورد شوری خاک منطقه انتخاب شد. نتایج همچنین نشان داد که نقشه‌های قابلیت هدایت الکتریکی عصاره اشباع خاک حاصل از دو روش از میزان همخوانی زیاد و صحت عمومی بالای ۸۰ درصد برخوردار بودند؛ با این حال، تغییر فصل و نوع ماهواره بر میزان تطابق‌پذیری نقشه‌های به‌دست آمده اثرگذار بود.

واژه‌های کلیدی: سنتینل ۲، شاخص شوری، کریجینگ، لندست ۸، مدل‌سازی

گلستانی م.، مصلح قهفرخی ز.، اسفندیارپور بروجنی ع.، شیرانی ح. ۱۴۰۳ میزان همخوانی نقشه‌های حاصل از روش‌های یادگیری ماشین و تخمینگر کریجینگ در پایش شوری بخشی از اراضی حاشیه‌ای پلایای سیرجان، استان کرمان. تحقیقات کاربردی خاک. جلد ۱۲، شماره ۳. صفحه: ۴۷-۶۶

۱- دانش‌آموخته کارشناسی‌ارشد، گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه ولی‌عصر رفسنجان

۲- استادیار بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان چهارمحال و بختیاری، سازمان تحقیقات، آموزش و ترویج کشاورزی، شهرکرد، ایران

۳- استاد گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه ولی‌عصر رفسنجان

۴- استاد گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه ولی‌عصر رفسنجان

* پست الکترونیک: Z.mosleh@areeo.ac.ir

مقدمه

شور شدن خاک، یک مسأله زیست‌محیطی جهانی است که باعث تخریب یا بیابان‌زایی شدید خاک، به‌ویژه در مناطق خشک و نیمه‌خشک (مانند ایران) می‌شود (Ding & Yu, 2014; Sidike *et al.*, 2014; Ivushkin *et al.*, 2019b; Wang *et al.*, 2019). تجمع نمک در سطح خاک و یا در منطقه توسعه ریشه گیاه، ویژگی‌های فیزیکی و شیمیایی خاک را تغییر می‌دهد و بر عملکردهای اکولوژیکی خاک تأثیر منفی می‌گذارد (Mohamed *et al.*, 2018). بنابراین، ترمیم خاک و احیای زمین‌های تحت تأثیر نمک برای بهبود کیفیت زیست‌محیطی و توسعه پایدار منطقه‌ای ضروری است (Gorji *et al.*, 2017; Peng *et al.*, 2019). در این راستا، مدیریت کارآمد خاک با نظارت بر شوری خاک، از اهمیت ویژه‌ای، به‌خصوص در زمین‌های قابل کشت، برخوردار است (Afrasinei *et al.*, 2017). اولین گام در این راستا، ارائه اطلاعات دقیق در مورد وسعت مکانی و شدت شوری در مناطق دارای خاک‌های متأثر از نمک است. یکی از راه‌های رسیدن به این هدف، ترسیم نقشه قابلیت هدایت الکتریکی است.

امروزه استفاده از روش‌های سنتی برای تهیه نقشه شوری خاک در مقیاس منطقه‌ای با انجام بررسی‌های میدانی و اندازه‌گیری مقادیر قابلیت هدایت الکتریکی خاک، پرهزینه و زمان‌بر است. به‌عبارت دیگر، تغییرات گسترده مکانی و زمانی شوری خاک، منجر به مشکل شدن و پرهزینه شدن فرایند نظارت بر آن، به‌ویژه در مقیاس منطقه‌ای می‌شود. وجود مشکلات متعدد در فرایند تهیه نقشه‌های سنتی خاک و نیاز مبرم به ارائه اطلاعات مورد اطمینان، منطقی و به‌نگام در ارتباط با خاک‌ها همراه با مخارج اقتصادی‌تر و افزایش فهم تفسیر نتایج به‌گونه‌ای که برای افراد غیرمتخصص و کارشناسان خاک قابل درک باشد، ضرورت توجه به شیوه‌های مدرن تهیه نقشه‌های خاک را بیش از پیش آشکار ساخته است (Grunwald, 2009; Rossiter & Loza, 2010). در این راستا، توسعه روش‌هایی برای استخراج اطلاعات سنجش از دور به‌منظور بهبود دقت و کارایی نقشه‌های شوری خاک، همواره از اهمیت بالایی برخوردار بوده است (Huang *et al.*, 2020). در دهه‌های اخیر، فناوری سنجش از دور به‌عنوان یک روش امیدوارکننده برای نظارت و ارزیابی مؤثر شوری خاک در مناطق وسیع، توجه پژوهشگران و متخصصان مختلف را به خود جلب نموده

است. تشخیص سریع و غیرمخرب، پوشش منطقه‌ای گسترده و امکان نظارت طولانی‌مدت نسبتاً ارزان را می‌توان از مزایای فناوری سنجش از دور به‌حساب آورد (Allbed & Kumar, 2013; Kumar *et al.*, 2015). به‌طور کلی، تصاویر ماهواره‌ای و تکنیک‌های سنجش از دور، ابزار مناسبی برای نقشه‌برداری شوری خاک و نظارت بر تغییرات پویای آن در کنار اندازه‌گیری‌های صحرائی در مقیاس‌های منطقه‌ای، ملی و حتی جهانی را فراهم آورده‌اند (Fan *et al.*, 2016; Gorji *et al.*, 2017; Ivushkin *et al.*, 2019a).

در میان سنجنده‌های ماهواره‌ای مختلف که برای نقشه‌برداری شوری و تولید نقشه‌های EC استفاده می‌شوند، تصاویر ماهواره‌ای چندطیفی به‌طور گسترده در پژوهش‌های پیشین مورد مطالعه قرار گرفته‌اند و به‌عنوان ابزاری بسیار امیدوارکننده برای این کار شناخته شده‌اند. در این ارتباط، حسگرهای چندطیفی مورد استفاده در ماهواره‌های مختلف (مانند لندست، اسپات، آستر، ایگنوس، مودیس و آی.آر.اس) از سال ۱۹۹۰ تا کنون امکانات زیادی را برای نظارت و نقشه‌برداری شوری خاک در دسترس پژوهشگران قرار داده‌اند (Allbed & Kumar, 2013). تصویربرداری عملیاتی زمین موجود در ماهواره لندست ۸، یکی از حسگرهایی است که به‌طور گسترده برای بهبود و نظارت بر امنیت محیط زیست جهانی در قدرت تفکیک مکانی (۳۰ متر)، به‌ویژه برای ارزیابی شوری خاک، مورد استفاده قرار گرفته است (Tran *et al.*, 2019; Wulder *et al.*, 2019). در این حال، دقت تجزیه و تحلیل حسگرهای OLI، اغلب به‌دلیل قدرت تفکیک مکانی متوسط و پهنای باند گسترده، محدود می‌باشد (Peng *et al.*, 2019). ماهواره سنتینل ۲، یکی دیگر از ماهواره‌هایی است که مجهز به سنجنده چندطیفی می‌باشد و تصاویری با قدرت تفکیک مکانی (۱۰ تا ۶۰ متر) و زمانی (۵ روز) بالا ارائه می‌دهد. در واقع، دو ماهواره سنتینل ۲ (با نام‌های S2A و S2B)، به‌ترتیب در ۲۳ ژوئن ۲۰۱۵ و ۷ مارس ۲۰۱۷ در مدار زمین قرار گرفته‌اند که MSI موجود در آن‌ها دارای ۱۳ باند طیفی با وضوح خوب (تا ۱۰ متر) است. این تصاویر ماهواره‌ای می‌توانند به‌طور بالقوه دقت تشخیص شوری خاک را بهبود بخشند. به‌علاوه، در سال‌های اخیر، شاخص‌های شوری مختلفی برای تشخیص مناطق متأثر از نمک از تصاویر ماهواره‌ای توسعه یافته‌اند که بیشتر بر اساس رفتارهای طیفی خاک‌های شور در باندهای مختلف تصاویر ماهواره‌ای می‌باشند (Allbed & Kumar, 2013).

تغییرپذیری مکانی و زمانی شوری خاک در منطقه مورد مطالعه زیاد باشد. به دیگر سخن، تغییرات خصوصیات خاک اغلب از روابط غیرخطی تبعیت می‌کنند. در نتیجه قابلیت‌های مدل‌های رگرسیون خطی در این راستا محدود می‌شوند. برای رفع این مشکل، می‌توان از روش‌های نوین یادگیری ماشین (مانند شبکه عصبی مصنوعی، جنگل تصادفی، درخت تصمیم و ماشین بردار پشتیبان) مبتنی بر روابط غیرخطی استفاده نمود. هی و همکاران (He et al., 2023) از تصاویر سنتینل ۱ و ۲ برای پایش شوری خاک منطقه هتائو در چین بهره گرفتند و اذعان داشتند که مدل جنگل تصادفی، رضایت‌بخش‌ترین نتایج ($R^2=0/80$) را در بین سایر مدل‌های یادگیری ماشین مورد استفاده، در بر داشت. علمدار و همکاران (Alamdar et al., 2023) نیز ضمن استفاده از تصاویر لندست ۸ و بررسی کارایی الگوریتم‌های یادگیری ماشین (جنگل تصادفی، ماشین تقویت گرادیان، پرسپترون چند لایه) در پایش شوری خاک دریاچه مهارلو، نتیجه گرفتند که بهترین عملکرد را الگوریتم ماشین تقویت گرادیان ($R^2=0/89$) به ارمغان آورد. ایشان همچنین اظهار داشتند با انتخاب الگوریتم بهینه و داده‌های مکانی مناسب می‌توان میزان شوری خاک را تا حد بسیار خوبی توسط داده‌های ماهواره‌ای تخمین زد.

سیرجان دارای یکی از مهم‌ترین پلایاهای استان کرمان است. پلایای سیرجان با مساحت ۱۶۲۵ کیلومتر مربع از بزرگترین پلایاهای حوضه آبخیز اصفهان محسوب می‌شود که به شکل یک مثلث گود در جنوب غربی شهر سیرجان قرار گرفته است (Krinsley, 1970). این پلایا دارای اراضی مختلفی از جهت نوع، میزان و عمق تجمع املاح و بافت خاک است که باعث شده شاهد پهنه‌های شور و غیرشور در این منطقه باشیم (Neyestani & Farpoor, 2014). در سال‌های اخیر در نواحی حاشیه‌ای این پلایا به دلیل معکوس شدن شیب هیدرولیکی و به دنبال آن افزایش شوری آب، بیشترین میزان شوری خاک گزارش شده است. به عبارت بهتر، برداشت بی‌رویه آب‌های زیرزمینی برای استفاده در آبیاری باغ‌های پسته موجود در منطقه، به مرور زمان باعث ایجاد خاک‌های شور و سدیمی در این اراضی حاشیه‌ای شده است که در نتیجه آن، سلامت اکوسیستم طبیعی منطقه همراه با کاهش کمی و کیفی آب‌های زیرزمینی، با چالش

خالقی و همکاران (Khaleghi et al., 2017) بیان کردند که بین قابلیت هدایت الکتریکی خاک سطحی در دشت ارومیه با شاخص‌های استخراج شده از تصاویر لندست ۸ شامل معکوس شاخص شوری و نسبت شاخص روشنایی به پوشش گیاهی همبستگی معنی‌داری وجود دارد. ییمر و همکاران (Yimer et al., 2022) از پنج شاخص شوری و پوشش گیاهی شامل NDVI، NDSI، EVI، SAVI و SI برای ارزیابی و مدل‌سازی شوری خاک منطقه آفاریاتیوپی با استفاده از تصاویر سنتینل ۲ و لندست ۸ استفاده کردند و نتیجه گرفتند که مدل‌های رگرسیون دارای ضریب همبستگی معنی‌داری بین مقدار EC به دست آمده از اندازه‌گیری میدانی و مقادیر EC حاصل از داده‌های سنسجش از راه دور برای تمامی شاخص‌ها (به جز شاخص EVI) بودند. به علاوه، بالاترین ضریب همبستگی ($r = 0/78$)، مربوط به داده‌های تصاویر لندست ۸ و برای شاخص SII به دست آمد. آودان و همکاران (۲۰۲۱) نیز همبستگی قابل قبولی ($r = 0/68$) بین داده‌های لندست ۸ با شاخص‌های شوری SI و SII به دست آوردند. همچنین، سیفی و همکاران (Seifi et al., 2020) شاخص SII را کارآمدترین و شاخص‌های SI3 و BI را کم‌اثرترین شاخص‌ها برای ارزیابی شوری خاک دریاچه ارومیه بیان کردند.

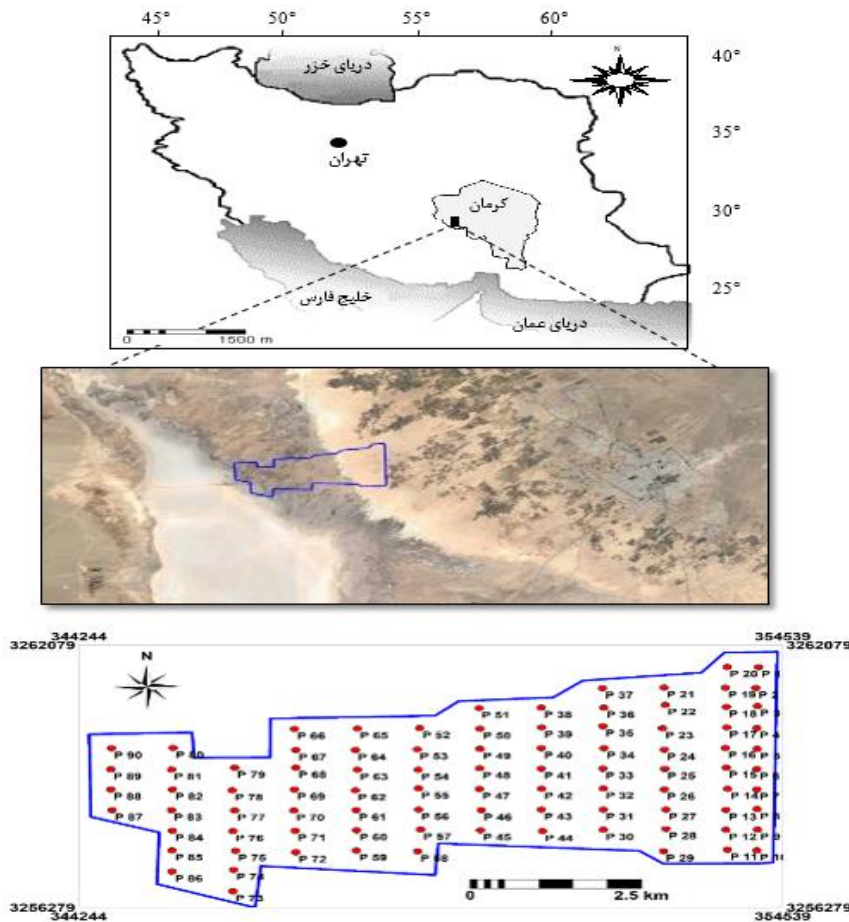
اگرچه ارزیابی سریع و دقیق شوری خاک از طریق داده‌های سنسجش از دور در دهه‌های اخیر، بهبود قابل توجهی یافته است؛ لیکن گسترش روزافزون شوری خاک تحت تأثیر ویژگی‌ها و فرایندهای مختلف، پژوهشگران را به سمت تسریع در مدل‌سازی این ویژگی خاک هدایت نموده است (Akramkhanov, 2005; Vasques et al., 2010). در این ارتباط، بسیاری از روش‌های رگرسیون، از جمله رگرسیون خطی چند متغیره^۱ و رگرسیون حداقل مربعات جزئی^۲، به طور گسترده‌ای برای استنباط روابط بالقوه بین داده‌های سنسجش از دور (بازتاب و شاخص‌های طیفی) و خصوصیات خاک (مانند شوری خاک) استفاده شده‌اند. با این حال، اجرای موفقیت‌آمیز این مدل‌ها باید مفروضات خاصی (مانند وجود روابط خطی واضح بین متغیرها) را برآورده کند. در نتیجه، استفاده از این رویکردهای خطی ممکن است منجر به ایجاد خطای بزرگی شود، به ویژه در مناطقی که

معرفی منطقه مورد مطالعه

منطقه مورد مطالعه در بخشی از اراضی حاشیه‌ای پلاپای سیرجان واقع در طول‌های جغرافیایی ۵۵ درجه و ۲۳ دقیقه تا ۵۵ درجه و ۳۰ دقیقه شرقی و عرض‌های جغرافیایی ۲۹ درجه و ۲۴ دقیقه تا ۲۹ درجه و ۲۹ دقیقه شمالی با میانگین ارتفاع ۱۷۰۰ متر از سطح دریا و با مساحتی حدود ۶۲۰۰ هکتار در غرب و جنوب‌غربی شهر سیرجان قرار گرفته است (شکل ۱). میانگین دما و بارش سالانه منطقه، به ترتیب ۱۵ درجه سلسیوس و ۱۷۲ میلی‌متر در یک دوره آماری ده ساله (۱۳۸۹ تا ۱۳۹۹) است. در ضمن، منطقه مورد مطالعه، عاری از هرگونه پوشش گیاهی و به صورت بکر می‌باشد.

جدی مواجه شده است (Abbasnejad & Shahidasht, 2013). بنابراین اهداف اصلی پژوهش حاضر عبارتند از: (۱) مقایسه کارایی دو منبع داده سنجنش از دور (لندست ۸ و سنتینل ۲) در رابطه با پایش شوری بخشی از خاک‌های اراضی حاشیه‌ای پلاپای سیرجان با استفاده از شاخص‌های شوری مختلف؛ (۲) مقایسه الگوی تغییرپذیری شوری خاک سطحی منطقه در دو فصل زمستان و تابستان؛ (۳) بررسی میزان همخوانی نقشه‌های حاصل از روش‌های یادگیری ماشین و تخمینگر کریجینگ در بیان تغییرپذیری شوری خاک سطحی منطقه در دو فصل زمستان و تابستان.

مواد و روش‌ها



شکل ۱- موقعیت منطقه مورد مطالعه به همراه ۹۰ نقطه مشاهداتی

Figure 1. Location of the study area with 90 sampling points

آن در دو فصل زمستان و تابستان استفاده شد. برای این منظور، ابتدا با استفاده از تصاویر گوگل ارث، محدوده منطقه مورد مطالعه تعیین گردید. سپس، با بارگذاری تصویر منطقه در نرم‌افزار ایلویس^۱ نسخه ۳٫۸، موقعیت ۹۰ نقطه

مطالعات ستادی

در این پژوهش، از دو مجموعه داده مختلف شامل تصاویر ماهواره‌ای و اندازه‌گیری‌های صحرایی به منظور تعیین، بررسی و تهیه نقشه‌های شوری خاک و روند تغییرات زمانی

۱. ILWIS

بارگیری تصاویر ماهواره‌ای لندست ۸ و سنتینل ۲ در این زمان به ترتیب از وبسایت‌های سازمان زمین‌شناسی ایالات متحده^۱ و کوپرنیکوس وجود داشته باشد. مشخصات تصاویر استفاده‌شده در جدول ۱ ارایه شده است.

مشاهداتی در قالب یک الگوی شبکه‌ای منظم با فواصل ۷۵۰ متر تعیین شد (شکل ۱) و در نهایت مختصات جغرافیایی این نقاط به دست آمد. به علاوه، تلاش گردید که تاریخ نمونه‌برداری صحرائی طوری تنظیم گردد که امکان

جدول ۱- مشخصات تصاویر استفاده‌شده

Table 1- Characteristics of imagery data used

Satellite	Season	Resolution (m)	Image date
Landsat8	Winter	30	21.02.2021
	Summer		24.07.2021
Sentinel2	Winter	10	22.02.2021
	Summer		25.07.2021

$$SAR = \frac{Na^+}{\sqrt{\frac{Ca^{2+} + Mg^{2+}}{2}}}$$

که واحد تمامی عناصر برحسب میلی‌اکی‌والان بر لیتر می‌باشد. قابلیت هدایت الکتریکی عصاره اشباع با استفاده از دستگاه هدایت‌سنج الکتریکی (Richards, 1954) اندازه‌گیری شد.

بایستی توجه داشت که تعیین بافت خاک‌های گچی در صحرا و از طریق لمس به دلیل حضور بلورهای گچ در اندازه‌های شن و سیلت، باعث خطا در تعیین کلاس بافتی می‌شود. از سوی دیگر، تعیین بافت خاک در آزمایشگاه، مشکلات دیگری چون انحلال ذرات گچ و هم‌آور نمودن ذرات خاک را به همراه دارد. به علاوه، در تعیین بافت خاک به روش هیدرومتری (Bouyoucos, 1951)، وجود گچ از پراکندگی کامل ذرات رس جلوگیری می‌کند و تعیین بافت خاک را بدون ایجاد سوسپانسیون پایدار، با مشکل روبه‌رو می‌سازد. بنابراین، بافت خاک در پژوهش حاضر با استفاده از روش پوشش گچ با سولفات باریم (Hesse, 1976) اندازه‌گیری شد. برای این منظور، مقدار ۱۰ گرم خاک در یک لوله فالکون ۵۰ میلی‌لیتری ریخته شد؛ ۴۰ میلی‌لیتر کلرید باریم ۰/۲ مولار به آن اضافه گردید و به مدت یک ساعت به آرامی هم زده شد. سپس به مدت ۱۰ دقیقه با دور ۲۰۰۰ دور بر دقیقه سانتریفیوژ گردید و محلول رویی دور ریخته شد. در ادامه، ۴۰ میلی‌لیتر آب مقطر به نمونه اضافه گردید و پس از این که به خوبی هم زده شد، عمل سانتریفیوژ تکرار گردید. عمل شست‌وشو با آب مقطر تا جایی که یون باریم در محلول رویی وجود نداشته باشد،

مطالعات صحرائی

ابتدا موقعیت هر یک از نقاط مشاهداتی با استفاده از سامانه موقعیت‌یاب جهانی^۲ مشخص شد. سپس، این نقطه به عنوان مرکز دایره فرضی به شعاع ۲/۵ متر لحاظ گردید و در چهار جهت متفاوت از مرکز دایره مزبور (علاوه بر خود مرکز دایره)، در هر یک از فصول زمستان و تابستان از خاک سطحی (عمق صفر تا ۳۰ سانتی‌متری) هر نقطه مشاهداتی با استفاده از مته، نمونه‌برداری انجام شد. سپس، تمامی نمونه‌های پنج‌گانه برداشت‌شده از هر نقطه مشاهداتی، با یکدیگر مخلوط شدند و یک نمونه خاک مرکب با وزن تقریبی دو کیلوگرم برداشت شد. در نهایت، نمونه‌های برداشت‌شده برای انجام تجزیه‌های فیزیکی و شیمیایی لازم به آزمایشگاه منتقل گردید.

مطالعات آزمایشگاهی

پس از هواخشک کردن نمونه‌ها و عبور آن‌ها از الک دو میلی‌متری، درصد گچ نمونه‌ها به روش استون (Nelson, 1978) و درصد کربنات کلسیم معادل آن‌ها به روش خنثی‌سازی با اسید کلریدریک (Alison, 1965) اندازه‌گیری شد. همچنین، سدیم محلول به روش شعله‌سنجی، کلسیم و منیزیم محلول به روش کمپلکسومتری و تیتراسیون با EDTA (Lanyon & Heald, 1982) اندازه‌گیری شد. سپس با استفاده از مقادیر سدیم، کلسیم و منیزیم محلول، مقدار عددی نسبت جذب سطحی سدیم^۳ توسط معادله زیر (Oster & Sposito, 1980) محاسبه گردید:

۳. Sodium Adsorption Ratio (SAR)

۱. United States Geological Survey (USGS)

۲. Global Positioning System (GPS)

با توجه به این که در این مطالعه از تصاویر سنتینل ۲ (Level 2A) استفاده گردید و این تصاویر کاملاً تصحیح شده می باشند؛ بنابراین هیچ گونه عملیات پیش پردازشی بر روی این تصاویر صورت نگرفت. پس از فراخوانی این تصاویر در نرم افزار Snap 8.0.0 و ذخیره آنها به فرمت tiff، تصاویر مزبور در نرم افزار ENVI 5.3 فراخوانی شدند و برای محاسبه شاخص های شوری، مورد استفاده قرار گرفتند. هم چنین، لازم به ذکر است که براساس آمار دریافتی از اداره کل هواشناسی استان کرمان، در فصل زمستان تا ۱۲ روز قبل و در فصل تابستان تا ۱۵ روز قبل از بارگیری تصاویر ماهواره ای، هیچگونه بارشی در منطقه صورت نگرفته بود.

شاخص های شوری مورد استفاده

به منظور تخمین شوری خاک، علاوه بر باندهای مرئی و مادون قرمز نزدیک هر کدام از تصاویر ماهواره ای، از شاخص های طیفی استخراج شده از باندهای اصلی سنجنده های هر کدام از ماهواره های لندست ۸ و سنتینل ۲ که تحت عنوان "شاخص های شوری" نامگذاری شده اند، استفاده گردید. شاخص های شوری مورد استفاده در پژوهش حاضر شامل شاخص شوری استاندارد شده^۲، شاخص روشنایی^۳، شاخص شوری خاک گیاهی^۴، شاخص نسبت طیفی^۵، شاخص نسبت ساده^۶، شاخص شدت^۷، شاخص شدت^۸، شاخص شوری^۹، شاخص شوری^{۱۰}، شاخص شوری^{۱۱}، شاخص شوری^{۱۲}، شاخص شوری^{۱۳} و شاخص شوری^{۱۴} می باشند (Sahbeni, 2021) که توضیحات آنها در جدول شماره ۲ بیان شده است.

مدل سازی شوری خاک

برای تخمین مقادیر شوری در نقاط نمونه برداری نشده از دو شیوه یادگیری ماشین و زمین آمار استفاده شد. در روش زمین آمار، میان یابی نقاط نمونه برداری نشده با استفاده از نقاط نمونه برداری شده در منطقه و توسط تخمین گر کریجینگ معمولی در محیط نرم افزار Arc-GIS 10.4.1 انجام گرفت. در روش یادگیری ماشین، از نقاط

ادامه یافت. عدم حضور باریم با یک قطره کرومات پتاسیم که به محلول اضافه شد، مشخص گردید. نمونه به دست آمده با ۱۵ میلی لیتر هگزامتافسفات سدیم به مدت ۳۰ دقیقه هم زده شد و از الک ۰/۰۵ میلی متر (۲۷۰ مش) عبور داده شد (Hesse, 1976). شن روی الک، پس از شست و شو و خشک کردن، توزین گردید. سوسپانسیون زیر الک نیز درون یک مزور یک لیتری ریخته شد و پس از به حجم رساندن با آب مقطر، درصد سیلت و رس آن به روش پیپت (Klute, 1986) اندازه گیری گردید.

تصحیح های انجام شده بر روی تصاویر ماهواره ای

استفاده از تصاویر ماهواره ای به منظور تخمین شوری خاک، مستلزم انجام پیش پردازش هایی بر روی این تصاویر است. پس از بارگیری تصاویر ماهواره ای لندست ۸ و سنتینل ۲ در تاریخ های مورد نظر (۲ اسفند ۱۳۹۹ و ۸ مرداد ۱۴۰۰)، تصحیح های رادیومتریکی و اتمسفری لازم بر روی آنها انجام شد. تصحیح رادیومتریکی شامل تصحیح تمامی خطاهای موجود (ناشی از سنجنده، زمین و اتمسفر) در امواج رسیده به سنجنده می باشد. هدف اصلی در فرایند تصحیح رادیومتریکی، محاسبه مؤلفه های رادیومتریکی (مانند میزان انرژی بازتابش، انعکاس و دمای درخشندگی) است. تصحیح رادیومتریکی تصاویر لندست ۸ با استفاده از دستور Radiometric calibration در نرم افزار ENVI 5.3 صورت گرفت. تصحیح اتمسفری شامل تصحیح اثرات اتمسفر (پخش و جذب) از روی امواج رسیده به سنجنده است. در واقع، هدف از تصحیح اتمسفری، تعیین ارزش واقعی بازتاب سطح با از بین بردن اثرات جوی از تصاویر ماهواره ای می باشد. تصحیح اتمسفری معمولاً در راستای تصحیح رادیومتریکی است. تصحیحات اتمسفری تصاویر ماهواره ای لندست ۸ با تبدیل ارزش رقومی^۱ به میزان انرژی بازتابش و سپس انعکاس با استفاده از الگوریتم FLASH در نرم افزار ENVI 5.3 انجام شد.

۸..Intensity Index 2 (Int2)

۹..Salinity Index (SI)

۱۰..Salinity Index1 (SI1)

۱۱..Salinity Index2 (SI2)

۱۲..Salinity Index3 (SI3)

۱۳..Salinity Index4 (SI4)

۱۴..Salinity Index5 (SI5)

۱. Digital Number (DN)

۲. Normalized Difference Salinity Index (NDSI)

۳. Brightness Index (BI)

۴. Vegetation Soil Salinity Index (VSSI)

۵..Ratio Spectral Index (RSI)

۶..Simple Ratio (SR)

۷..Intensity Index 1 (Int1)

ماشین بردار پشتیبان انجام شد. مدل شبکه عصبی مصنوعی پرسپترون با استفاده از بسته‌های caret و nnet در نرم‌افزار R 3.1.1 اجرا شد. همچنین، برای اجرای مدل درخت تصمیم از بسته rpart (package) استفاده شد.

نمونه‌برداری شده و نیز متغیرهای کمکی شامل تمامی باندهای هر کدام از ماهواره‌های لندست ۸ و سنتینل ۲ و شاخص‌های مذکور استفاده شد و برآورد شوری خاک عصاره اشباع در دو فصل زمستان و تابستان با استفاده از مدل‌های شبکه عصبی مصنوعی، درخت تصمیم، جنگل تصادفی و

جدول ۲- شاخص‌های شوری مورد استفاده برای مدل‌سازی

Table 2. Salinity indices used for modeling

Salinity index (SI)	Abbreviation	Formula
Normalized Difference Salinity Index	NDSI	$(R - NIR)/(R + NIR)$
Vegetation Soil Salinity Index	VSSI	$2 \times G - 5 \times (R + NIR)$
Brightness Index	BI	$\sqrt{(R^2 + NIR^2)}$
Salinity Index	SI	$(R \times G)/B$
Salinity Index1	SI1	$\sqrt{(G \times R)}$
Salinity Index2	SI2	$\sqrt{(R \times NIR)}$
Salinity Index3	SI3	$\sqrt{(G^2 + R^2 + NIR^2)}$
Salinity Index4	SI4	$\sqrt{(G^2 + R^2)}$
Salinity Index5	SI5	B/R
Ratio Spectral Index	RSI	R/NIR
Intensity Index1	Int1	$(G + R)/2$
Intensity Index2	Int2	$(G + R + NIR)/2$
Simple Ratio	SR	$(R - NIR)/(G + NIR)$

پس از آن، الگوی تغییرپذیری مقادیر شوری خاک با توجه به بهترین مدل انتخاب‌شده در محیط نرم‌افزار R 3.1.1 ترسیم گردید.

علاوه بر موارد بالا، به‌منظور تعیین میزان هم‌خوانی نقشه حاصل از تخمین گر کریجینگ با نقشه حاصل از بهترین مدل، با روی هم‌اندازی این نقشه‌ها در محیط نرم‌افزار R 3.1.1 و محاسبه ماتریس خطا، مقدار صحت عمومی و ضریب کاپای اصلاح‌شده آن‌ها محاسبه و مورد مقایسه قرار گرفت. شاخص‌های صحت عمومی^۲ و کاپای اصلاح‌شده^۳ با استفاده از روابط زیر تعیین گردیدند (Byrt et al., 1993):

$$(1)$$

$$OA = \sum_{i=1}^n X_{ii} / N$$

$$(2)$$

$$K = 2(OA) - 1$$

که در این روابط، n تعداد سطر یا ستون‌های ماتریس خطا، X_{ii} تعداد پیکسل‌هایی که به‌درستی پیش‌بینی

مدل جنگل تصادفی نیز با استفاده از بسته randomforest اجرا شد. به‌علاوه، از بسته‌های kernlab و caret موجود در نرم‌افزار R 3.1.1 برای اجرای مدل ماشین بردار پشتیبان استفاده شد.

لازم به ذکر است که برای اجرای هر مدل، ابتدا تمامی متغیرهای ورودی (تمامی باندهای هر ماهواره و شاخص‌های شوری مزبور) به مدل مورد نظر داده شد و اهمیت نسبی این متغیرها در تخمین قابلیت هدایت الکتریکی خاک بر اساس هر مدل و با دستور varImp در نرم‌افزار R 3.1.1 تعیین گردید. سپس، مؤثرترین متغیرها انتخاب شدند و مجدداً هر کدام از مدل‌ها با توجه به اثرگذارترین متغیرها اجرا شدند. فرایند مدل‌سازی، زمانی پایان پذیرفت که کمترین شاخص خطا و بالاترین ضریب تبیین^۱ برای هر مدل با توجه به متغیرهای اثرگذار به‌دست آمد. در نهایت، با مقایسه شاخص‌های خطا و ضرایب تبیین چهار مدل مزبور، بهترین مدل در تخمین مقادیر قابلیت هدایت الکتریکی عصاره اشباع، به‌طور جداگانه برای هر کدام از تاریخ‌های نمونه‌برداری و هر ماهواره تعیین شد.

۳. Adjusted Kappa

۱. Coefficient of determination (R2)

۲. Overall Accuracy (OA)

نشان می‌دهد. با توجه به مقادیر میانگین شوری و نسبت جذب سطحی سدیم در عصاره اشباع، خاک‌های منطقه مطالعاتی در زمره خاک‌های شور و سدیمی ($EC > 4 \text{ dS/m}$) و $SAR > 13$) قرار گرفته‌اند. به‌علاوه، مقدار میانگین شوری-های اندازه‌گیری شده در عصاره اشباع تابستان، بسیار بیشتر از عصاره اشباع در فصل زمستان می‌باشند.

میانگین ذرات رس، سیلت و شن در منطقه، به‌ترتیب، $32/08$ ، $32/82$ و $35/09$ درصد است. هرچند میانگین درصد شن، اندکی بیشتر از دو ذره دیگر است؛ لیکن تفاوت چندانی بین میانگین دو ذره رس و سیلت موجود نمی‌باشد. در هر حال، بافت خاک غالب در منطقه مورد مطالعه، لوم رسی است. همچنین، وجود گچ نسبتاً زیاد در منطقه با میانگین $8/63$ درصد، یکی از ویژگی‌های بارز خاک‌های مطالعاتی می‌باشد؛ به‌گونه‌ای که در نزدیکی این منطقه، وجود کارگاه‌های تولید گچ را می‌توان شاهد بود. در مقابل، کربنات‌های خاک بین ۲ تا $25/5$ درصد تغییرپذیری دارند (جدول ۳). دی (Day, 1983) خاک‌های مناطق خشک و نیمه‌خشک را از لحاظ مقدار کربنات کلسیم معادل به پنج گروه مختلف طبقه‌بندی کرد. وی اظهار داشت اگر درصد کربنات کلسیم معادل کمتر از ۵ درصد، بین ۵ تا ۱۵ درصد، ۱۵ تا ۲۵ درصد، ۲۵ تا ۴۰ درصد و بزرگ‌تر یا مساوی ۴۰ درصد باشد؛ آن‌گاه کلاس‌های آهکی خاک به‌ترتیب در گروه ضعیف، متوسط، قوی، خیلی قوی و فوق‌العاده قوی قرار خواهند گرفت. بر این اساس و با توجه به میانگین کربنات کلسیم معادل اندازه‌گیری شده (جدول ۳)، خاک‌های منطقه در کلاس آهکی متوسط قرار دارند.

نگاهی به مقادیر ضریب تغییرپذیری^۳ محاسبه شده نشان می‌دهد که به‌غیر از رس و کل کربنات‌ها، مابقی متغیرها از ضریب تغییرپذیری بیش از ۳۵ درصد برخوردار هستند (جدول ۳). وایلدینگ (Wilding, 1985) اظهار داشت که مقادیر بالاتر از ۳۵ درصد برای ضریب تغییرپذیری، نشان‌دهنده وجود تغییرات زیاد برای متغیر مورد نظر می‌باشد. با توجه به بکر بودن منطقه، دلیل اصلی این تغییرپذیری زیاد را می‌توان به ویژگی‌های ذاتی خاک نسبت داد.

هرچند بررسی ضریب چولگی، یکی از مرسوم‌ترین روش‌های مطالعه انحراف از توزیع نرمال یک متغیر است (Robinson & Metternicht, 2006)؛ لیکن استفاده از

شده‌اند، X_{i0} تعداد کل سطرها، X_{0i} تعداد کل ستون‌ها و N تعداد کل مشاهدات می‌باشد.

شاخص‌های ارزیابی مدل

هر کدام از مدل‌های مورد نظر، با استفاده از ۸۰ درصد داده‌ها (۷۲ نمونه) آموزش داده شد و اعتبارسنجی آن با استفاده از ۲۰ درصد داده‌ها (۱۸ نمونه) انجام گرفت. انتخاب داده‌های آموزشی و اعتبارسنجی به‌صورت تصادفی انجام گرفت. به‌منظور اعتبارسنجی مدل‌های مورد استفاده در پژوهش حاضر از شاخص‌های ضریب تبیین، جذر میانگین مربعات خطا^۱ و جذر میانگین مربعات خطای نسبی (استاندارد) استفاده شد که معادله آن‌ها به شرح زیر می‌باشند:

$$R^2 = 1 - \frac{\sum_{i=1}^n [P_i - O_i]^2}{\sum_{i=1}^n [O_i - \bar{O}]^2} \quad (3)$$

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

$$\%RMSE = \frac{RMSE}{\bar{X}} \times 100 \quad (5)$$

که در این روابط، O_i ، \bar{O} و P_i به‌ترتیب بیانگر مقادیر مشاهده‌ای، میانگین مقادیر مشاهده‌ای و مقادیر برآوردشده؛ n تعداد کل مشاهدات و \bar{X} میانگین مقادیر واقعی مشاهدات است.

تجزیه و تحلیل‌های آماری داده‌ها

به‌منظور بررسی اولیه و کسب نخستین اطلاعات از داده‌های مربوط به مقادیر قابلیت هدایت الکتریکی عصاره اشباع، خلاصه آماری آن‌ها شامل میانگین، میانه، انحراف معیار، کمینه، بیشینه و ضریب چولگی محاسبه شد. همچنین، برای تعیین میزان همبستگی مقادیر طیفی باندهای اصلی تصاویر ماهواره‌ای و شاخص‌های شوری با مقادیر قابلیت هدایت الکتریکی اندازه‌گیری شده در عصاره اشباع، از ضریب همبستگی پیرسون استفاده شد. لازم به ذکر است که تمامی تجزیه و تحلیل‌های مزبور در محیط نرم‌افزار R 3.1.1 انجام گرفت.

نتایج و بحث

جدول ۳ خلاصه آماری ویژگی‌های خاک‌های مورد مطالعه (شامل میانگین، میانه، کمینه، بیشینه، واریانس، چولگی و ضریب تغییرپذیری) را برای دو فصل زمستان و تابستان

3. Coefficient of variation (CV)

1. Root Mean Squared Error (RMSE)

2. Normalized Root Mean Square Error (NRMSE)

آخر، سطح معنی‌داری کمتر از ۰/۰۵، فرض نرمال بودن داده‌ها را رد می‌کند. بر این اساس، کلسیم محلول در هر دو فصل، نسبت جذب سطحی سدیم در فصل تابستان، سیلت، رس، گچ و کربنات کلسیم معادل از توزیع نرمال برخوردار هستند (جدول ۳).

آزمون کولموگروف-اسمیرنوف، یکی از معتبرترین روش‌های نظارت بر نرمال بودن یا نبودن توزیع داده‌های یک متغیر می‌باشد. در واقع، حساسیت بالای این آزمون به تغییر کرانه‌های توزیع در وضعیت فراوانی‌های کم، این روش را نسبت به سایر شیوه‌های بررسی توزیع نرمال داده‌های یک متغیر خاص، متفاوت ساخته است (Park, 2008). در آزمون

جدول ۳- خلاصه آماری برخی از ویژگی‌های فیزیکی و شیمیایی خاک‌های منطقه مورد مطالعه

Table 3. Summary statistics of some physical & chemical soil properties in the study area

Variable	Unit	season	Mean	Median	Variance	Min	Max	Skewness	Coefficient of variation	P-value*
EC _e	(dSm ⁻¹)	Winter	59.4	67.4	998.4	3	104.3	-0.77	53.2	0.018*
		Summer	69.5	83.3	1043.6	5.6	112.6	-1.28	46.5	0.004*
Ca		Winter	109.0	88.5	4598.4	19.5	400	0.91	62.2	0.109
		Summer	110.2	106.5	3386.14	28	278	0.19	52.8	0.63
Mg	(meqL ⁻¹)	Winter	125.0	91	1518.1	4.5	664	0.83	98.6	0.001*
		Summer	122.9	90.5	12729.6	5	751	0.86	91.8	0.004*
Na		Winter	1057.0	1302.4	545727.6	12.9	2543.2	-0.99	69.89	0.028*
		Summer	1329.7	1577.5	734439.5	18.6	2884.2	-0.87	64.5	0.042*
SAR	(meqL ⁻¹) ^{0.5}	Winter	131.4	157.5	5972.6	4.1	281.7	-1.05	58.82	0.038*
		Summer	168.8	184.2	9571.1	5.7	401	-0.87	64.4	0.446
Sand			35.0	31.0	174.9	17.6	68.8	0.94	37.7	0.012*
Silt			32.8	32.9	154.2	7.2	58.8	-0.03	37.8	0.449
Clay			32.0	32	112.7	12	55.5	-0.02	33.0	0.344
Gypsum	%		8.6	9.1	9.3	1.5	15.5	-0.46	35.3	0.24
Carbonate calcium equivalent			12.5	13	15.0	2	25.5	-0.38	31.0	0.186

*Shows the results of the Kolmogorov-Smirnov test and statistical signification at 95% confidence level

مدل‌سازی شوری خاک (Morgan *et al.*, 2018) و تقی‌زاده مهرجردی و همکاران (Taghizadeh Mehrjardi *et al.*, 2022) نیز به پتانسیل بالای مدل شبکه عصبی مصنوعی در تخمین شوری خاک با استفاده از داده‌های سنجش از دور اذعان نموده‌اند. برخلاف نتایج حاصل از پژوهش حاضر، جیانگ و همکاران (Jiang *et al.*, 2019) و وانگ و همکاران (Wang *et al.*, 2021) در پژوهش‌های خود به این نتیجه رسیدند که مدل ماشین بردار پشتیبان نسبت به مدل‌های شبکه عصبی مصنوعی و جنگل تصادفی، از کارایی بهتری در تخمین شوری خاک‌های مناطق مطالعاتی ایشان برخوردار بود. بنابراین شاید بتوان گفت که کارایی مدل‌های مختلف بسته به شرایط منطقه (از جمله، دامنه تغییرات شوری خاک منطقه و یا تعداد نقاط مطالعاتی) می‌تواند متفاوت باشد.

نتایج میزان کارایی مدل‌های شبکه عصبی مصنوعی، درخت تصمیم، جنگل تصادفی و ماشین بردار پشتیبان در پیش‌بینی قابلیت هدایت الکتریکی عصاره اشباع خاک برای تصاویر لندست ۸ و سنتینل ۲ در دو فصل زمستان و تابستان در جدول ۴ آورده شده‌اند. اطلاعات موجود در این جدول نشان می‌دهد که به ترتیب مدل‌های درخت تصمیم و جنگل تصادفی، دارای بهترین نتایج برای برآورد قابلیت هدایت الکتریکی عصاره اشباع خاک در فصل‌های زمستان و تابستان براساس تصاویر ماهواره لندست ۸ می‌باشند. همچنین، به ترتیب مدل‌های شبکه عصبی مصنوعی و جنگل تصادفی، بهترین نتایج را برای برآورد قابلیت هدایت الکتریکی عصاره اشباع خاک در فصل‌های زمستان و تابستان براساس تصاویر ماهواره سنتینل ۲ برای منطقه مطالعاتی به ارمغان آورده‌اند. مورگان و همکاران

و همکاران (Yahiaoui *et al.*, 2021) به منظور پیش‌بینی شوری خاک با استفاده از تصاویر سنتینل ۲ در الجزایر پژوهشی را انجام دادند.

چن و همکاران (Chen *et al.*, 2020) عملکرد بهتر مدل جنگل تصادفی را نسبت به مدل ماشین بردار پشتیبان در مطالعه‌ای که برای پیش‌بینی شوری خاک با استفاده از داده‌های سنتینل ۲ در منطقه هتائو چین انجام دادند، به اثبات رساندند. یحیی

جدول ۴- نتایج مدل‌سازی قابلیت هدایت الکتریکی عصاره اشباع خاک بر اساس شاخص‌های محاسبه‌شده

برای تصاویر لندست ۸ و سنتینل ۲ در دو فصل زمستان و تابستان

Table 4. Performance of different models to predict ECe based on the indices extracted from Landsat-8 and Sentinel-2 images in the winter and summer seasons.

Model	Satellite	Season	Selected indices	R ²	RMSE	%RMSE
ANN	Landsat-8	Winter	VSSI+SI3	0.4	25.4	42.7
		Summer	VSSI+ RSI+ SI5	0.72	17.1	24.6
	Sentinel-2	Winter	VSSI+ RSI	0.77	16.1	27.1
		Summer	SI3+SI4+BI	0.66	19.4	27.9
DT	Landsat-8	Winter	NDSI+RSI+SR+VSSI	0.47	23.2	39.0
		Summer	NDSI+RSI +VSSI	0.69	18.5	26.6
	Sentinel-2	Winter	SI+ VSSI	0.6	21.5	36.2
		Summer	RSI+ SI4	0.73	17.3	24.9
RF	Landsat-8	Winter	SI5+ SR+ RSI	0.4	25.1	42.2
		Summer	NIR+RSI+NDSI	0.73	17.0	24.4
	Sentinel-2	Winter	SI+ NIR	0.63	19.7	33.1
		Summer	NIR+ VSSI	0.87	12.1	17.4
SVM	Landsat-8	Winter	SR+NDSI+RSI	0.44	25.8	43.4
		Summer	NDSI+RSI+ NIR	0.63	20	28.8
	Sentinel-2	Winter	SI1+ SI4+ SI3	0.6	21.7	36.5
		Summer	NDSI+RSI+SR+G	0.64	19.9	28.6

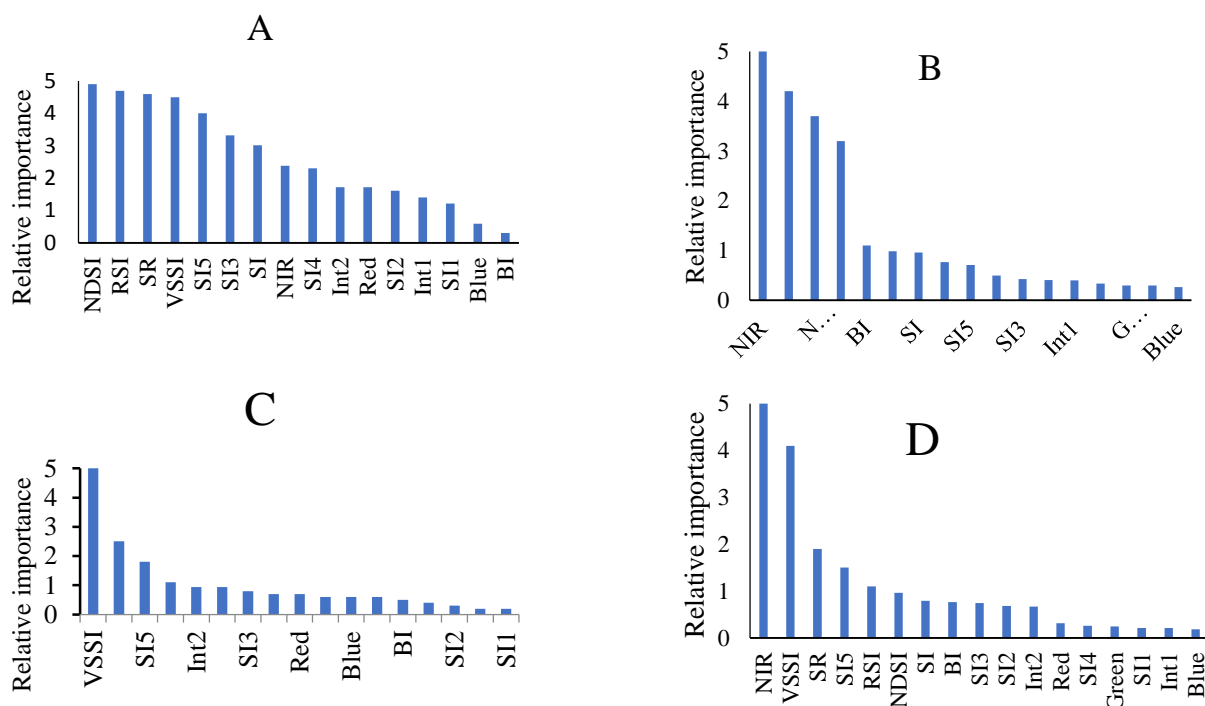
ANN: artificial neural network, DT: decision tree, RF: random forest, SVM: support vector machine

رگرسیون برای تخمین شوری خاک ارائه کرد. همچنین، تقی‌زاده مهرجردی و همکاران (Taghizadeh Mehrjardi *et al.*, 2022) در پژوهشی به مقایسه روش‌های مختلف مدل‌سازی با استفاده از تصاویر ماهواره لندست ۸، برای ارزیابی توزیع مکانی ویژگی‌های خاک در اصفهان پرداختند. نتایج نشان داد که از میان تمامی مدل‌ها، مدل جنگل تصادفی در پیش‌بینی قابلیت هدایت الکتریکی خاک مؤثرتر بوده است. فتحی‌زاده و همکاران (Fathizadeh *et al.*, 2020) با استفاده از تصاویر ماهواره‌های لندست و مدل جنگل تصادفی به بررسی تغییرات مکانی و زمانی شوری خاک در دشت اردکان یزد پرداختند و نتیجه گرفتند که مدل جنگل تصادفی قادر است ۷۳ درصد از تغییرات شوری منطقه را پیش‌بینی کند. وانگ و همکاران (Wang *et al.*, 2019) در پژوهشی به بررسی قابلیت داده‌های ماهواره سنتینل ۲ برای نظارت و پهنه‌بندی شوری خاک در فصول خشک و مرطوب در دریاچه ابینور چین پرداختند. نتایج حاکی از آن بود که مدل جنگل تصادفی با همبستگی بالایی ($r=0.92$)، بهترین عملکرد را به همراه داشت.

آن‌ها بیان نمودند که مدل جنگل تصادفی از عملکرد بهتری نسبت به مدل‌های رگرسیون حداقل مربعات جزئی و رگرسیون خطی چند متغیره برخوردار است. وانگ و همکاران (Wang *et al.*, 2020) نیز ضمن مقایسه دقت مدل‌های گوناگون برای پیش‌بینی شوری خاک در اعماق مختلف خاک، اظهار داشتند که مدل‌های جنگل تصادفی و رگرسیون بردار پشتیبان، نتایج بهتری را در این ارتباط رقم زدند؛ اما با توجه به بالاتر بودن ضریب تبیین محاسبه‌شده برای مدل جنگل تصادفی ($R^2 = 0.87$)، مدل اخیر گوی سبقت را در این پیش‌بینی ربوده بود. برخلاف نتایج حاصل از پژوهش حاضر، زارعی و همکاران (Zarei *et al.*, 2021) در مطالعه خود برای تخمین شوری خاک با استفاده از داده‌های سنتینل نتیجه گرفتند که مدل جنگل تصادفی با کمترین میزان همبستگی ($R^2 = 0.69$) و درصد خطای بالا ($RMSE = 92\%$)، مدل مناسبی برای تخمین شوری خاک دریاچه نمک اشتهارد واقع در استان البرز نیست. آکسوی و همکاران (Aksoy *et al.*, 2022) اذعان کردند که مدل جنگل تصادفی نتایج قابل اعتمادتری نسبت به مدل‌های درخت رگرسیون، درخت طبقه‌بندی و بردار پشتیبان

کمترین اهمیت نسبی به شاخص BI اختصاص یافته است. به‌علاوه، با مشاهده شکل (۲-ب) متوجه اهمیت بارز چهار شاخص NIR، RSI، NDSI و VSSI در تخمین قابلیت هدایت الکتریکی عصاره اشباع خاک با استفاده از مدل جنگل تصادفی و تصاویر لندست ۸ در فصل تابستان خواهیم شد. به دیگر سخن، در بین تمامی شاخص‌ها و باندهای اصلی مورد استفاده برای فصل تابستان، مؤثرترین شاخص، NIR و کمترین اهمیت مربوط به باند آبی است.

شکل ۲ اهمیت نسبی باندهای اصلی و شاخص‌های شوری در تخمین قابلیت هدایت الکتریکی عصاره اشباع خاک با استفاده از بهترین مدل انتخابی برای هر کدام از تصاویر لندست ۸ و سنتینل ۲ در فصول زمستان و تابستان را نشان می‌دهد. همان‌طور که در شکل (۲-الف) نمایان است؛ اگرچه شاخص‌های NDSI، RSI، SR و VSSI از نظر میزان اهمیت نسبی، به یکدیگر نزدیک هستند؛ اما شاخص NDSI با کمی اختلاف، بالاتر از بقیه شاخص‌ها قرار گرفته است. در مقابل،



شکل ۲- اهمیت نسبی باندهای اصلی و شاخص‌های شوری در تخمین قابلیت هدایت الکتریکی عصاره اشباع خاک با استفاده از: (الف) مدل درخت تصمیم و تصاویر لندست ۸ در فصل زمستان؛ (ب) مدل جنگل تصادفی و تصاویر لندست ۸ در فصل تابستان؛ (ج) مدل شبکه عصبی مصنوعی و تصاویر سنتینل ۲ در فصل زمستان؛ (د) مدل جنگل تصادفی و تصاویر سنتینل ۲ در فصل تابستان

Figure 2. Relative importance of satellite bands and salinity indices for prediction of EC_e based on decision tree using Landsat-8 in the winter season (a) random forest model using Landsat-8 in the summer season (b) artificial neural network model using Sentinel-2 in the winter season (c) random forest model using Sentinel-28 in the summer season

اهمیت نسبی شاخص NDSI از بقیه شاخص‌ها در فصل زمستان بیشتر بوده است. همچنین، نوروزی و همکاران (Noroozi *et al.*, 2018) نیز به تخمین شوری خاک با استفاده از تصاویر ماهواره لندست ۵ در استان‌های سمنان، فارس و هرمزگان پرداختند. نتایج ایشان نیز نشان داد که در استان فارس، شاخص NDSI بیشترین همبستگی (۶۶ درصد) و در استان هرمزگان، شاخص SI3 بیشترین همبستگی (۷۲ درصد) را داشت. شاه مرادی و همکاران (Shahmoradi *et al.*, 2021) با مطالعه خاک‌های قسمت غرب دریاچه ارومیه بیان کردند که شاخص شوری با با

اختری و اسدی (Akhzari & Asadi, 2016) نیز به‌منظور تهیه نقشه شوری خاک با استفاده از تصاویر لندست ۸ و داده‌های صحرایی در جنوب دشت ملایر مطالعه‌ای انجام دادند. نتایج نشان داد هرچند از تمامی شاخص‌های مورد استفاده (شامل NDSI، SI، SI-T، SI-A، M-SI، S1، S2، S3، S5 و S6) می‌توان برای تفکیک اراضی استفاده کرد؛ اما میزان صحت و دقت تفکیکی آن‌ها متفاوت است. در این مطالعه، شاخص NDSI با ضریب همبستگی برابر با ۰/۸۸، مؤثرترین شاخص شوری برای تفکیک اراضی منطقه مورد نظر شناخته شد. براساس نتایج حاصل از پژوهش حاضر نیز

اشاره کرده‌اند. برخلاف نتایج حاصل از پژوهش حاضر، وانگ و همکاران (Wang *et al.*, 2020) براساس نتایج حاصل از مطالعه خود بیان داشتند که شاخص SII برای داده‌های ماهواره سنتینل ۲، با ضریب تبیین برابر با ۸۱/۵ درصد، برترین شاخص در پیش‌بینی شوری خاک‌های منطقه مطالعاتی ایشان بوده است.

به‌طور کلی، نتایج حاصل از فرایند مدل‌سازی انجام‌گرفته در پژوهش حاضر (جدول ۴) نشان داد که داده‌های حاصل از ماهواره سنتینل ۲ (MSI)، با درجه اعتبار بالاتری نسبت به داده‌های ماهواره لندست ۸ (OLI)، قادر به پیش‌بینی تغییرات شوری در منطقه مورد مطالعه می‌باشند. کاظمی گرچه و همکاران (Kazemi Garajeh *et al.*, 2022) ضمن نقشه‌برداری توزیع شوری در دریاچه نمک موجود در بخش ایران مرکزی، اظهار داشتند که تصاویر سنتینل ۲ برای شناسایی و پهنه‌بندی توزیع شوری خاک نسبت به تصاویر لندست ۸، مناسب‌تر هستند که این نتایج با یافته‌های دیویس و همکاران (Davis *et al.*, 2019) همخوانی داشت. ایشان دلیل برتری نتایج حاصل از ماهواره سنتینل ۲ نسبت به ماهواره لندست ۸ را وضوح مکانی ۱۰ متری و زمان بازگشت پنج روزه سنجنده MSI در مقابل وضوح مکانی ۳۰ متری و زمان بازگشت ۱۶ روزه سنجنده OLI دانستند. در واقع، دقت مکانی کمتر سنجنده OLI باعث شد که مناطق غیرشور (مانند جاده‌ها) نیز در برآورد مناطق شور لحاظ شوند و کیفیت نقشه نهایی کاهش یابد. به دیگر سخن، وضوح مکانی بالاتر سنجنده MSI به آن اجازه می‌دهد تا نقاط باریک‌تری از خاک برهنه شور را شناسایی کند که این موضوع می‌تواند تا حدودی پهنه‌بندی شوری خاک را بهبود بخشد (Davis *et al.*, 2019). آودان و همکاران (Avdan *et al.*, 2021) نیز پژوهشی در راستای ارزیابی تأثیر تصحیح اتمسفر بر داده‌های سنتینل ۲ و لندست ۸ برای تعیین شوری خاک انجام دادند. این پژوهشگران اظهار داشتند که به‌دلیل همبستگی بیشتر داده‌های سنتینل ۲ با شاخص‌های شوری SI و SI3، کارایی داده‌های ماهواره سنتینل ۲ نسبت به داده‌های ماهواره لندست ۸ در برآورد شوری خاک منطقه مطالعاتی ایشان بهتر بوده است. همچنین، خواجه‌زاده و همکاران (Khajehzadeh *et al.*, 2022) به‌منظور پهنه‌بندی شوری خاک در یکی از مناطق نیمه‌خشک جنوب ایران (خوزستان) نشان دادند که داده‌های سنتینل ۲ با بیشترین

ضریب ۰/۹۶ شاخص بهینه برای برآورد مقادیر شوری خاک می‌باشد. کیم‌آنه و همکاران (Kim-Anh *et al.*, 2020) ضمن مقایسه نتایج شوری خاک برآوردشده از طریق داده‌های ماهواره لندست ۸ با داده‌های میدانی، اظهار داشتند که شاخص‌های NIR و VSSI، دارای بیشترین همبستگی (به ترتیب، ۰/۸ و ۰/۷) و شاخص‌های SI4، SI1 و SI5، دارای همبستگی ضعیف (به ترتیب، ۰/۳۵، ۰/۳۲ و ۰/۲۸) بودند. دوان و همکاران (Duan *et al.*, 2022) در مطالعه‌ای به پایش و نقشه‌برداری شوری خاک با استفاده از تصاویر لندست ۸ در بستر دریای آرال (آسیای مرکزی) پرداختند و دریافتند که شوری خاک با شاخص‌های شوری SI2 و NDSI همبستگی مثبت و معنی‌داری داشت. در مقابل، وانگ و همکاران (Wang *et al.*, 2020) ضمن انجام پژوهش خود در منطقه ابینور اظهار داشتند که شاخص Int2 دارای بیشترین همبستگی بین متغیرهای کمکی و شوری خاک بود و شاخص‌های NDSI و SI5 در این راستا معنی‌دار نبودند.

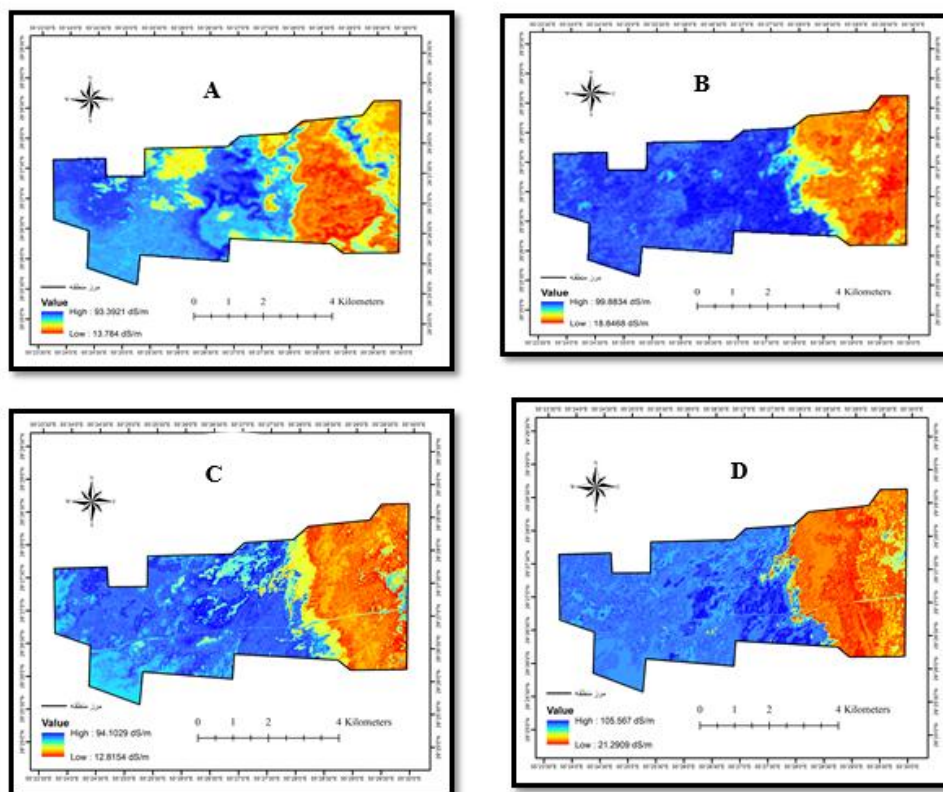
با نگاه اجمالی به شکل (۲-ج)، متوجه تأثیرگذاری بیشتر شاخص VSSI نسبت به مابقی شاخص‌ها در این ارتباط خواهیم شد. همچنین، آخرین درجه اهمیت، متعلق به شاخص SII است. شکل (۲-د) نیز نشانگر آن است که در فصل تابستان، همانند فصل زمستان (شکل ۲-ج)، شاخص VSSI از درجه اهمیت بالایی در تخمین شوری خاک برخوردار بوده است. البته در فصل تابستان، درجه اهمیت باند مادون قرمز نزدیک (NIR)، بیش از همه شاخص‌ها و باندهای اصلی بوده است. در مقابل، کمترین اهمیت مربوط به باند آبی می‌باشد. یحیی و همکاران (Yahiaoui *et al.*, 2021) ضمن استفاده از داده‌های ماهواره سنتینل ۲ برای مدل‌سازی شوری خاک در الجزایر، به اهمیت شاخص‌های SI4، CRSI و VSSI در این خصوص اشاره نمودند. ایشان همچنین اظهار داشتند که باندهای موجود در طیف مرئی نیز در بازیابی شوری خاک مفید به‌نظر می‌رسند و به‌طور قابل توجهی در تخمین قابلیت هدایت الکتریکی خاک کمک می‌کنند. فرهمند و صادقی (Farahmand & Sadeghi, 2020) شاخص‌های SI، NIR و BI را به‌عنوان برترین شاخص‌ها در برآورد شوری خاک‌های حاشیه دریاچه ارومیه بیان نمودند. عبدالقدیر و بنی (Abdul-Qadir & Benni, 2010) نیز به پتانسیل بالای باند مادون قرمز نزدیک (NIR) برای تشخیص نفوذ شوری در دشت بین‌النهرین

می‌باشند. همچنین، شکل ۴ نشانگر نقشه‌های کریجینگ قابلیت هدایت الکتریکی عصاره‌های اشباع خاک در فصول زمستان و تابستان هستند. روند کلی موجود در تمامی نقشه‌های مزبور، حاکی از افزایش میزان شوری خاک از سمت شرق به غرب منطقه می‌باشد. در قسمت شرق منطقه به دلیل وجود باغ‌های پسته و آبیاری آن‌ها طی سالیان متمادی، شسته شدن املاح از سطح خاک و انتقال آن‌ها به لایه‌های زیرین صورت گرفته است.

میزان همبستگی ($r = 0.93$) و درصد خطای کم ($9/2 = RMSE$)، بهتر از داده‌های لندست ۸ عمل می‌کنند.

مقایسه نتایج روش‌های زمین‌آمار و یادگیری ماشین

شکل ۳ نشان‌دهنده نقشه‌های رقومی قابلیت هدایت الکتریکی عصاره‌های اشباع خاک براساس داده‌های حاصل از تصاویر ماهواره‌های لندست ۸ و سنتینل ۲ در فصول زمستان و تابستان با استفاده از بهترین مدل انتخابی

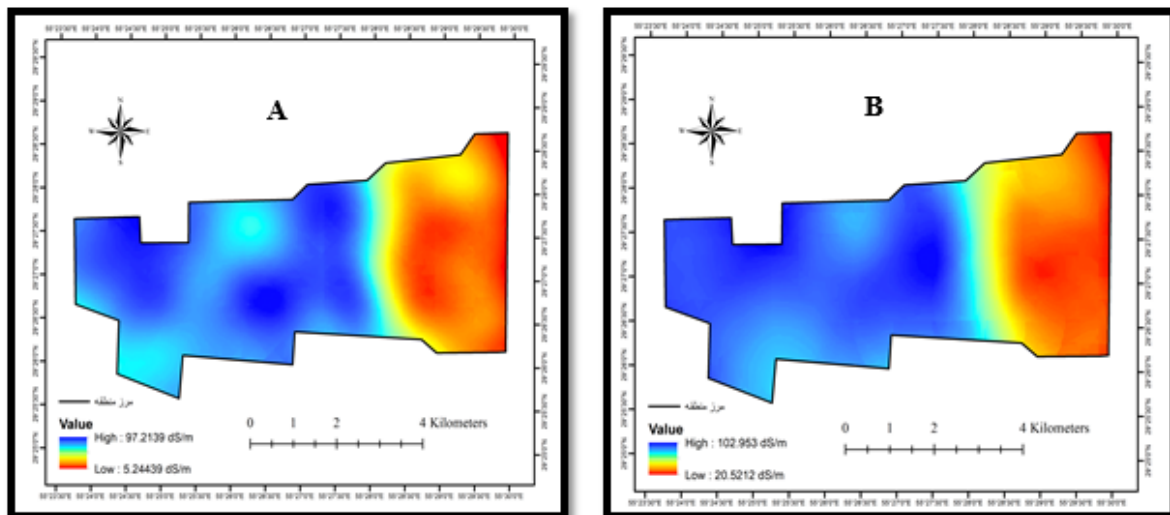


شکل ۳- نقشه رقومی شوری عصاره اشباع خاک حاصل از: مدل درخت تصمیم بر اساس تصاویر لندست ۸ در فصل زمستان (الف)؛ مدل جنگل تصادفی براساس تصاویر لندست ۸ در فصل تابستان (ب)؛ مدل شبکه عصبی مصنوعی براساس تصاویر سنتینل ۲ در فصل زمستان (ج)؛ مدل جنگل تصادفی براساس تصاویر سنتینل ۲ در فصل تابستان (د)

Figure 3. Spatiotemporal maps of EC_e using decision tree model- Landsat-8 in winter season (a), random forest model- Landsat-8 in the summer season (b), artificial neural network model- Sentinel-2 in winter season (c) and random forest model- Sentinel-2 in summer season

سیرجان (غرب منطقه مطالعاتی)، میزان شوری به‌طور مکرر افزایش می‌یابد. گود و کاسه‌ای شکل بودن مرکز پلایا، موجبات تجمع روان‌آب‌های حاصل از مناطق بالادست موجود در اطراف پلایای سیرجان را فراهم نموده است و از طرفی، به دلیل خشک بودن اقلیم منطقه، میزان بارندگی کمتر از تبخیر و تعرق است و بنابراین شرایط برای تجمع املاح در این منطقه فراهم است.

از طرفی، با توجه به اینکه براساس بررسی‌های انجام‌شده در منابع مختلف (از جمله: Masoud et al., Gorji et al., 2020)، حداکثر عمق حدود ۳۰ سانتی‌متر برای استفاده از داده‌های تصاویر ماهواره‌ای مد نظر قرار گرفته است؛ در نتیجه میزان شوری برآورده شده (و نیز اندازه‌گیری شده از طریق نمونه‌های سطحی برداشت‌شده) در این قسمت از منطقه مطالعاتی کم می‌باشد. از سوی دیگر، با حرکت به سمت مرکز پلایای



شکل ۴- نقشه کریجینگ شوری عصاره اشباع خاک در فصول زمستان (الف) و تابستان (ب)

Figure 4. Spatial distribution of EC_e in winter (a) and summer (b) seasons

مزبور مشاهده نمی‌شود. عدم وجود بارش کافی در فصل زمستان منتهی به نمونه‌برداری‌های انجام‌شده در پژوهش حاضر، شاید دلیلی برای این اختلاف کم شوری‌های خاک اندازه‌گیری‌شده در دو فصل زمستان و تابستان باشد.

جدول ۵ نشان‌دهنده مدل‌های واریوگرامی و ویژگی‌های میان‌یابی انجام‌شده توسط تخمین‌گر کریجینگ معمولی در رابطه با قابلیت هدایت الکتریکی عصاره‌های اشباع در فصل‌های زمستان و تابستان به همراه شاخص‌های اعتبارسنجی محاسبه‌شده برای هر مدل می‌باشد. با توجه به اطلاعات این جدول، مشاهده می‌شود که دامنه مزبور برای فصل زمستان، کمتر از فصل تابستان است. با توجه به نسبت اثر قطعه‌ای به حد آستانه (سقف) محاسبه‌شده، می‌توان دریافت که وابستگی مکانی برای EC_e در کلاس متوسط (بین ۰/۲۵ تا ۰/۷۵) قرار گرفته است (Cambardella et al., 1994). شاخص‌های اعتبارسنجی موجود در جدول ۵ نیز به خوبی نمایانگر قابل قبول بودن فرایند مدل‌سازی انجام‌گرفته با تخمین‌گر کریجینگ می‌باشد.

دامنه تغییرات حاصل از مدل‌سازی قابلیت هدایت الکتریکی عصاره اشباع خاک در فصل زمستان بین ۱۴ تا ۹۳ دسی‌زیمنس بر متر و در فصل تابستان بین ۱۹ تا ۱۰۰ دسی‌زیمنس بر متر بر اساس داده‌های حاصل از ماهواره لندست ۸ متغیر می‌باشد (شکل‌های ۳-الف و ۳-ب). این دامنه بر اساس داده‌های حاصل از ماهواره سنتینل ۲ بین ۱۳ تا ۹۴ دسی‌زیمنس بر متر در زمستان و بین ۲۱ تا ۱۰۵ دسی‌زیمنس بر متر در تابستان متغیر است (شکل‌های ۳-ج و ۳-د). بررسی نقشه‌های کریجینگ شوری خاک ترسیم‌شده (شکل ۴) نیز حاکی از آن هستند که دامنه تغییرات قابلیت هدایت الکتریکی عصاره اشباع خاک در فصل زمستان، بین ۵ تا ۹۷ دسی‌زیمنس بر متر و در فصل تابستان، بین ۲۰ تا ۱۰۳ دسی‌زیمنس بر متر می‌باشد. مقایسه دامنه تغییرات مزبور در نقشه‌های رقومی و کریجینگ نشانگر آن است که هرچند دامنه تغییرات شوری در تابستان، اندکی بیشتر از زمستان می‌باشد؛ ولی اختلاف بارزی در مقادیر اندازه‌گیری‌شده و برآوردشده برای دو فصل

جدول ۵- مدل‌های واریوگرامی و ویژگی‌های میان‌یابی قابلیت هدایت الکتریکی عصاره اشباع در فصل‌های زمستان و تابستان به همراه شاخص‌های اعتبارسنجی آن‌ها

Table 5. Authorized models, interpolation parameters and cross-validation statistics of EC_e in winter and summer seasons

Variable	Season	Model	Range (m)	Nugget effect	Sill	R ²	RMSE	%RMSE
EC_e	Winter	Stable	1754	129	221	0.78	14.8	24.9
	Summer	Stable	3904	198	459	0.76	15.7	22.5

جدول ۶ نشان‌دهنده میزان همخوانی و تطابق نقشه‌های حاصل از تخمین‌گر کریجینگ معمولی و بهترین مدل یادگیری ماشین (لندست ۸ و سنتینل ۲) قابلیت هدایت الکتریکی عصاره اشباع خاک در فصل‌های مختلف است. ملاحظه می‌شود که در فصل زمستان، میزان تطابق نقشه کریجینگ با نقشه حاصل از تصاویر ماهواره سنتینل ۲، بیش از سایر موارد است. برعکس، در فصل تابستان، میزان این همخوانی با داده‌های حاصل از ماهواره لندست ۸ بیشتر می‌باشد. به دیگر سخن، تغییر فصل و نوع ماهواره، بر میزان تطابق‌پذیری نقشه‌های به‌دست آمده از روش‌های مختلف اثرگذار بوده است. کاظمی گرجه و همکاران (Kazemi

Garajeh *et al.*, 2022) نیز اعلام داشتند که تصاویر سنتینل ۲ با صحت عمومی ۹۴/۷۸ درصد، برای تشخیص و نقشه‌برداری شوری خاک، نسبت به تصاویر لندست ۸ با صحت عمومی ۹۱/۴۵ درصد، مؤثرتر می‌باشند. نتایج همچنین بازگوکننده آن است که میزان همخوانی نقشه‌های مزبور در فصل تابستان، اندکی بیشتر از فصل زمستان می‌باشد. به‌طور کلی، صحت عمومی محاسبه‌شده در هر دو فصل زمستان و تابستان، بالای ۸۰ درصد است. همچنین، ضریب کاپای اصلاح‌شده برای فصول مزبور، بیش از ۶۰ درصد می‌باشد.

جدول ۶- میزان همخوانی و تطابق نقشه‌های قابلیت هدایت الکتریکی عصاره اشباع خاک حاصل از تخمین‌گر کریجینگ معمولی و بهترین مدل یادگیری ماشین در فصل‌های مختلف

Table 6. The matching rate of ECE maps obtained by machine learning methods and kriging estimator in different seasons

Season	Type of maps	Overall accuracy (OA)	Adjusted Kappa
Winter	Landsat- kriging	0.81	0.62
	Sentinel- kriging	0.86	0.72
	Landsat- sentinel	0.81	0.62
Summer	Landsat- kriging	0.87	0.74
	Sentinel- kriging	0.84	0.68
	Landsat- sentinel	0.85	0.7

نتیجه‌گیری کلی

در پژوهش حاضر، ضمن مقایسه کارایی داده‌های دو ماهواره لندست ۸ و سنتینل ۲ در رابطه با پایش شوری بخشی از خاک‌های اراضی حاشیه‌ای پلاهای سیرجان برای دو فصل زمستان و تابستان، مشخص گردید که تغییر فصل و نوع ماهواره، هم بر کارایی شاخص‌های شوری مورد استفاده و هم بر میزان تطابق‌پذیری نقشه‌های شوری خاک حاصل از تخمین‌گر کریجینگ معمولی و یادگیری ماشین اثرگذار است. به دیگر سخن، وضوح مکانی بالاتر و دوره بازگشت کوتاه‌تر داده‌های ماهواره سنتینل ۲ (MSI)، قابلیت بالاتر این ماهواره را نسبت به داده‌های حاصل از ماهواره لندست ۸ (OLI)، برای پایش و پهنه‌بندی شوری خاک منطقه به‌همراه داشت. همچنین، نظر به حضور مؤثر شاخص VSSI در فرایند پایش و مدل‌سازی شوری خاک منطقه در هر دو فصل زمستان و تابستان، شاید بتوان شاخص مزبور را به‌عنوان کارآمدترین شاخص در این ارتباط معرفی نمود. به‌علاوه، میزان همخوانی نقشه‌های قابلیت هدایت الکتریکی عصاره اشباع حاصل از دو روش، در حد قابل قبول (صحت

پژوهشگران مختلف از جمله ابوالعیتی و همکاران (Abulaiti *et al.*, 2022)، گوپالاکریشنان و کومار (Gopalakrishnan & Kumar, 2020)، فنگ و همکاران (Feng *et al.*, 2019) و نورممت و همکاران (Nurmemet *et al.*, 2018)، صحت عمومی بالای ۷۵ درصد را به‌عنوان عاملی برای تأیید میزان همخوانی نقشه‌های شوری حاصل از روش‌ها و یا مدل‌های مختلف، بیان نموده‌اند. به‌علاوه، کنگالتون و گرین (Congalton & Green, 2009) صحت عمومی ۸۵ درصد را به‌عنوان یک آستانه قابل قبول برای ارزیابی میزان کارایی یک مدل در نظر گرفتند. این در حالی است که باقری بُداغ‌آبادی و همکاران (Bagheri *et al.*, 2015) اظهار داشتند که صحت عمومی ۷۰ درصد می‌تواند مناسب بودن تخمین‌های حاصل از یک مدل را تضمین کند. بر این اساس و با توجه به اطلاعات موجود در جدول ۶ می‌توان گفت که همخوانی داده‌های حاصل از نقشه‌برداری رقومی و سنتی برای قابلیت هدایت الکتریکی عصاره اشباع در فصول مختلف، در حد قابل قبول می‌باشد.

بنابراین کارایی مدل‌های مختلف، بسته به شرایط منطقه (از جمله، دامنه تغییرات شوری خاک منطقه و یا تعداد نقاط مطالعاتی) می‌تواند متفاوت باشد و هر منطقه، نیازمند انجام فرایند مدل‌سازی مختص به خود است. در هر حال، نظر به اینکه برآورد سریع و دقیق شوری خاک در مناطق وسیع، از تصمیم‌گیری به موقع برای حفظ پایداری خاک و احیای زمین پشتیبانی می‌کند؛ می‌توان با بکارگیری از داده‌های ماهواره‌ای مناسب، در هزینه‌ها و زمان انجام مطالعات، صرفه‌جویی نمود.

عمومی بیش از ۸۰ درصد) بود. براساس نتایج این مطالعه، بهترین مدل انتخابی برای تخمین قابلیت هدایت الکتریکی عصاره اشباع خاک در فصل تابستان، مدل جنگل تصادفی بود. در مقابل، علی‌رغم انتخاب مدل درخت تصمیم به‌عنوان کارآمدترین مدل برای فصل زمستان براساس داده‌های ماهواره لندست ۸، به‌دلیل نزدیک بودن مقدار شاخص‌های اعتبارسنجی محاسبه‌شده برای مدل‌های درخت تصمیم و شبکه عصبی مصنوعی، می‌توان از مدل شبکه عصبی مصنوعی نیز برای تخمین شوری خاک منطقه استفاده نمود.

Reference

- Abbasnejad A., Shahidasht A. 2013. Vulnerability of Sirjan plain due to aquifer over abstraction. *Geography and territorial spatial arrangement*, 3 (7): 85-96.
- Abdul-Qadir A. M. H., and Benni T. J. 2010. Monitoring and evaluation of soil salinity in term of spectral response using Landsat images and GIS in Mesopotamian plain/Iraq. *Journal of Iraqi Desert Studies*, 2 (2): 19-32.
- Abulaiti A., Nurmemet I., Muhetaer N., Xiao S. and Zhao J. 2022. Monitoring of soil salinization in the Keriya Oasis based on deep learning with PALSAR-2 and Landsat-8 datasets. *Sustainability*, 14 (5): 2666-2675.
- Afrasinei G. M., Melis M. T., Buttau C., Bradd J. M., Arras C. and Ghiglieri G. 2017. Assessment of remote sensing-based classification methods for change detection of salt-affected areas (Biskra area, Algeria). *Journal of Applied Remote Sensing*, 11(1): 160-185.
- Akhzari D., Asadi Meyabadi A. 2016. Soil salinity map preparation using spectral analysis of OLI sensor and field data (Case study: Southern parts of Malayer plain). *RS & GIS for Natural Resources*, 7 (2): 87-100.
- Alamdar S., Ghazban F. and Zarei A. 2023. Efficiency of Machine Learning Algorithms in Soil Salinity Detection Using LANDSAT-8 Oli Imagery. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 10 : 49-55.
- Alexakis D. D., Daliakopoulos I. N., Panagea I. S. and Tsanis I. K. 2018. Assessing soil salinity using World View-2 multispectral images in Timpaki, Crete, Greece. *Geocarto International*, 33(4): 321-338.
- Alison L. E. and Moodie C. D. 1965. Carbonate. In: C. A., Black et al. (Eds.), *Methods of soil analysis. Part II. Soil Science Society of America and American Society of Agronomy*, Madison, pp. 1379-1396.
- Aksoy S., Yildirim A., Gorji T., Hamzehpour N., Tanik A. and Sertel E. 2022. Assessing the performance of machine learning algorithms for soil salinity mapping in Google Earth Engine platform using Sentinel-2A and Landsat-8 OLI data. *Advances in Space Research*, 69: 1072-1086.
- Akramkhanov, A. 2005. The spatial distribution of soil salinity: detection and prediction. Ph.D dissertation, ZEF Ecology and Development, Cuvillier Verlag, Göttingen, Germany.
- Allbed A. and Kumar L. 2013. Soil salinity mapping and monitoring in arid and semi-arid regions using remote sensing technology: a review. *Advances in Remote Sensing*, 2 (4): 373-385.
- Avdan U., Kucuk Matci D., Kaplan G., Yigit Avdan Z., Erdem F., Demirtas I. and Mızık E.T. 2021. Evaluating the atmospheric correction impact on Landsat 8 and Sentinel-2 data for soil salinity determination. *Geodetski List*, 75(3): 225-240.
- Bagheri Bodaghabadi M., Martinez-Casasnovas J. A., Salehi M. H., Mohammadi J., Esfandiarpour Borujeni I., Toomanian N. and Gandomkar A. 2015. Digital soil mapping using artificial neural networks and terrain-related attributes. *Pedosphere*, 25: 580-591.
- Bouyoucos G. J. 1951. A recalibration of hydrometer method for making mechanical analysis of soil. *Agronomy*, 43: 434-438.
- Byrt T., Bishop J. and Carling J. B. 1993. Bias, prevalence and kappa. *Journal of Clinical Epidemiology*, 46: 423- 429.
- Cambardella C.A., Moorman T.B., Novak J.M., Parkin T.B., Karlen D.L., Turco R.F. and Konopka A.E. 1994. Field-scale variability of soil properties in central Iowa soils. *Soil science society of America journal*, 58(5): 1501-1511.

- Chen Y., Qiu Y., Zhang Z., Zhang J., Chen C., Han J. and Liu D. 2020. Estimating salt content of vegetated soil at different depths with Sentinel-2 data. *PeerJ*, 8: e10585.
- Congalton R. C. and Green K. 2009. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. 3rd Ed. CRC Press, Taylor and Francis Group, London, New York, 348p.
- Davis E., Wang C. and Dow K. 2019. Comparing Sentinel-2 MSI and Landsat 8 OLI in soil salinity detection: A case study of agricultural lands in coastal North Carolina. *International Journal of Remote Sensing*, 40 (16): 6134-6153.
- Day J.H. 1983. The Canadian Soil Information System (CanSIS). Manual for Describing Soils in the Field. Agriculture Canada Expert committee on soil survey. Branch, Ottawa, Ontario, 175p.
- Ding J. and Yu D. 2014. Monitoring and evaluating spatial variability of soil salinity in dry and wet seasons in the Werigan-Kuqa Oasis, China, using remote sensing and electromagnetic induction instruments. *Geoderma*, 235: 316–322.
- Duan Z., Wang X. and Sun L. 2022. Monitoring and mapping of soil salinity on the exposed seabed of the Aral Sea, Central Asia. *Water*, 14 (9): 1438.
- Elhag M. 2016. Evaluation of different soil salinity mapping using remote sensing techniques in arid ecosystems, Saudi Arabia. *Journal of Sensors*, 2016: 1-8.
- Fan X., Weng Y. and Tao J. 2016. Towards decadal soil salinity mapping using Landsat time series data. *International Journal of Applied Earth Observation and Geoinformation*, 52: 32-41.
- Farahmand N. and Sadeghi V. 2020. Estimating soil salinity in the dried lake bed of Urmialake using optical Sentinel-2 images and nonlinear regression models. *Journal of the Indian Society of Remote Sensing*, 48 (4): 675-687.
- Fathizadeh H., Ardakani M. A. H., Sodaiezadeh H., Kerry R. and Taghizadeh-Mehrjardi R. 2020. Investigation of the spatial and temporal variation of soil salinity using random forests in the central desert of Iran. *Geoderma*, 365: 114233.
- Feng J., Ding J. and Wei W. 2019. Soil salinization monitoring based on Radar data. *Remote Sensing for Land and Resources*, 1: 195-203.
- Jiang H., Rusuli Y., Amuti T. and He Q. 2019. Quantitative assessment of soil salinity using multi-source remote sensing data based on the support vector machine and artificial neural network. *International Journal of Remote Sensing*, 40 (1): 284-306.
- Gorji T., Sertel E. and Tanik A. 2017. Monitoring soil salinity via remote sensing technology under data scarce conditions: A case study from Turkey. *Ecological Indicators*, 74: 384-391.
- Gorji T., Yildirim A., Hamzeshpour N., Tanik A. and Sertel E. 2020. Soil salinity analysis of Urmia Lake Basin using Landsat-8 OLI and Sentinel-2A based spectral indices and electrical conductivity measurements. *Ecological Indicators*, 112: 106173.
- Gopalakrishnan T. and Kumar L. 2020. Modeling and mapping of soil salinity and its impact on paddy lands in Jaffna Peninsula, Sri Lanka. *Sustainability*, 12(20): 8317.
- Grunwald S. 2009. Multi-criteria characterization of recent digital soil mapping and modeling approaches. *Geoderma*, 152(3-4): 195-207.
- He Y., Zhang Z., Xiang R., Ding B., Du R., Yin H., Chen Y. and Ba Y. 2023. Monitoring salinity in bare soil based on Sentinel-1/2 image fusion and machine learning. *Infrared Physics & Technology*, 104656.
- Hesse P. R. 1976. Particle size distribution in gypsic soils. *Plant and Soil*, 44 (1) : 241-247.
- Huang X., Cao Y. and Li J. 2020. An automatic change detection method for monitoring newly constructed building areas using time-series multi-view high-resolution optical satellite images. *Remote Sensing of Environment*, 244: 111802.
- Ivushkin K., Bartholomeus H., Bregt A. K., Pulatov A., Kempen B. and De Sousa L. 2019a. Global mapping of soil salinity change. *Remote Sensing of Environment*, 231: 111260.
- Ivushkin K., Bartholomeus H., Bregt A. K., Pulatov A., Franceschini M. H., Kramer H. and Finkers R. 2019b. UAV based soil salinity assessment of cropland. *Geoderma*, 338: 502-512.
- Kazemi Garajeh M., Blaschke T., Hossein Haghi V., Weng Q., Valizadeh Kamran K. and Li Z. 2022. A comparison between Sentinel-2 and Landsat 8 OLI satellite images for soil salinity distribution mapping using a deep learning convolutional neural network. *Canadian Journal of Remote Sensing*, 48 (3): 452-468.

- Khajehzadeh M., Afzali S. F., Honarbakhsh A. and Ingram B. 2022. Remote sensing and GIS-based modeling for predicting soil salinity at the watershed scale in a semi-arid region of southern Iran. *Arabian Journal of Geosciences*, 15 (5): 1-10.
- Khaleghi R., Behmanesh J., Azad N. 2017. Prediction of Soil Salinity Using Multivariable Regression on the Basis of Extracted Indices from Landsat 8 Satellite (Case study: Urmia). *Applied Soil Research*, 7 (1): 108-120.
- Kim-Anh N., Liou Y. A., Tran H. P., Hoang P. P. and Thanh-Hung N. 2020. Soil salinity assessment by using near-infrared channel and Vegetation Soil Salinity Index derived from Landsat 8 OLI data: a case study in the Tra Vinh Province, Mekong Delta, Vietnam. *Progress in Earth and Planetary Science*, 7 (1): 1-16.
- Klute A. 1986. Methods of soil analysis. Part I. Physical and mineralogical methods. Soil Science Society of America, Madison, WI. 687-734.
- Krinsley, D.B., 1970. A geomorphological and paleoclimatological study of the playas of Iran, first ed. Geological Survey U.S. Department of Interior, Washington D.C, 180p.
- Kumar S., Gautam G. and Saha S. K. 2015. Hyperspectral remote sensing data derived spectral indices in characterizing salt-affected soils: a case study of Indo-Gangetic plains of India. *Environmental Earth Sciences*, 73 (7): 3299–3308.
- Lanyon L. E. and Heald W. R. 1982. Magnesium, Calcium, Strontium and Barium. In: A. L., Page et al. (Eds), Methods of soil Analysis. Part II. *Soil Science Society of America and American Society of Agronomy*, Madison, pp. 247-260.
- Masoud A. A., Koike K., Atwia M. G., El-Horiny M. M. and Gemail K. S. 2019. Mapping soil salinity using spectral mixture analysis of landsat 8 OLI images to identify factors influencing salinization in an arid region. *International Journal of Applied Earth Observation and Geoinformation*, 83: 101944.
- Mehrabi M., Hamzeh S., Alavipanah S.K., Kiavarz M., Ziaee R. 2019. Estimating soil moisture using remotely sensed data and surface energy balance system. *Journal of Watershed Engineering and Management*, 11 (3): 759-770.
- Mohamed E. S., Saleh A. M., Belal A. B. and Gad A. 2018. Application of near-infrared reflectance for quantitative assessment of soil properties. *The Egyptian Journal of Remote Sensing and Space Science*, 21(1): 1-14.
- Morgan R. S., El-Hady M. A. and Rahim I. S. 2018. Soil salinity mapping utilizing sentinel-2 and neural networks. *Indian Journal of Agricultural Research*, 52 (5): 524-529.
- Nelson R. E., Klameth L. C. and Nettleton W. D. 1978. Determining soil gypsum content and expressing properties of gypsiferous soils. *Soil Science Society of America Journal*, 42 (4), 659-661.
- Neyestani M., Farpoor M.H., 2014. Genesis, clay mineralogy and micromorphology of saline-gypsiferous soils in Kheirabad playa, Sirjan. *Arid Biome Scientific and Research Journal*, 4 (1): 65- 77.
- Noroozi A.A., Abkar A., Damizadeh M., Arasto B. 2018. *Iranian Journal of Range and Desert Research*, 26 (1): 117- 130.
- Nurmemet I., Sagan V., Ding J. L., Halik Ü., Abliz A. and Yakup Z. 2018. A WFS-SVM model for soil salinity mapping in keriya oasis, Northwestern china using polarimetric decomposition and fully PolSAR data. *Remote Sensing*, 10 (4): 598-609.
- Oster J.D. and Sposito G. 1980. The Gapon coefficient and the exchangeable sodium percentage-sodium adsorption ratio relation. *Soil Science Society of America Journal*, 44 (2): 258-260.
- Park H. M. 2008. Univariate Analysis and Normality Test using SAS, Stata and SPSS. The University Information Technology Services (UITS) Center for Statistical and Mathematical Computing, Indiana University, 41.
- Peng J., Biswas A., Jiang Q., Zhao R., Hu J., Hu B. and Shi Z. 2019. Estimating soil salinity from remote sensing and terrain data in southern Xinjiang Province, China. *Geoderma*, 337: 1309-1319.
- Richards L. A. 1954. Diagnosis and Improvement of Saline-Alkali Soils. USDA Hand Book, Washington DC, USA, 166p.
- Robinson T. P. and Metternicht G. 2006. Testing the performance of spatial interpolation techniques for mapping soil properties. *Computers and Electronics in Agriculture*, 50 (2): 97-108.
- Rossiter D. G. and Loza A. V. 2010. Technical note: Analyzing land cover change with logistic regression in R. ITC, Enschede, the Netherlands.
- Sahbeni G. 2021. Soil salinity mapping using Landsat 8 OLI data and regression modeling in the Great Hungarian Plain. *SN Applied Sciences*, 3 (5): 1-13.

- Seifi M., Ahmadi A., Neyshabouri M. R., Taghizadeh-Mehrjardi R. and Bahrami H. A. 2020. Remote and Vis-NIR spectra sensing potential for soil salinization estimation in the eastern coast of Urmia hyper saline lake, Iran. *Remote Sensing Applications: Society and Environment*, 20: 100398.
- Sidike A., Zhao S. and Wen Y. 2014. Estimating soil salinity in Pingluo County of China using QuickBird data and soil reflectance spectra. *International Journal of Applied Earth Observation and Geoinformation*, 26: 156-175.
- Shahmoradi S, Ghaffarian Malmiri H.R., Sharifi Pichoon M. 2021. Modeling and Mapping of Soil Salinity and Moisture Using Spectral and Radar Remote Sensing. *Applied Soil Research*, 10 (3): 43-65.
- Taghizadeh Mehrjardi R., KhademiH, Khayamim F., Zeraatpisheh M., Heung B. and Scholten T. 2022. A Comparison of model averaging techniques to predict the spatial distribution of soil properties. *Remote Sensing*, 14 (3): 472-481.
- Tran T. V., Tran D. X., Myint S. W., Huang C. Y., Pham H. V., Luu T. H. and Vo T. M. 2019. Examining spatiotemporal salinity dynamics in the Mekong River Delta using Landsat time series imagery and a spatial regression approach. *Science of the total environment*, 687: 1087-1097.
- Vasques G. M., Grunwald S. and Harris W. G. 2010. Spectroscopic models of soil organic carbon in Florida, USA. *Journal of Environmental Quality*, 39 (3): 923-934.
- Wang J., Ding J., Yu D., Ma X., Zhang Z., Ge X., Teng D., Li X., Liang J., Lizaga I. and Chen X. 2019. Capability of Sentinel-2 MSI data for monitoring and mapping of soil salinity in dry and wet seasons in the Ebinur Lake region, Xinjiang, China. *Geoderma*, 353: 172-187.
- Wang J., Ding J., Yu D., Teng D., He B., Chen X., Ge X., Zhang Z., Wang Y., Yang X., Shi T. and Su F. 2020. Machine learning-based detection of soil salinity in an arid desert region, Northwest China: A comparison between Landsat-8 OLI and Sentinel-2 MS. *Science of the Total Environment*, 707: 136092.
- Wang J., Peng J., Li H., Yin C., Liu W., Wang T. and Zhang H. 2021. Soil salinity mapping using machine learning algorithms with the Sentinel-2 MSI in arid areas. *China. Remote Sensing*, 13 (2):305.
- Wilding L. 1985. Spatial variability: its documentation, accommodation and implication to soil surveys. In: Nielsen, D. R. and Bouma, J. (Eds.). *Soil Spatial Variability*, Proc. of a workshop of ISSS and SSA. Pudoc Wageningen, the Netherlands: Centre for Agriculture. Publishing and Documentation, pp. 166-189.
- Yahiaoui I., Bradaï A., Douaoui A. and Abdenmour M. A. 2021. Performance of random forest and buffer analysis of Sentinel-2 data for modelling soil salinity in the Lower-Cheliff plain (Algeria). *International Journal of Remote Sensing*, 42 (1): 148-171.
- Yimer A. M., Sodango T. H. and Abi Assefa S. 2022. Analysis and modeling of soil salinity using Sentinel-2A and Landsat-8 images in the Afambo irrigated area, Afar Region, Ethiopia. Search Life-Sciences Literature, *Preprints.org*; DOI: 10.20944/preprints202204.0250.v1.
- Zarei A., Hasanlou M. and Mahdianpari M. 2021. A comparison of machine learning models for soil salinity estimation using multi-spectral earth observation data. *ISPRS Annals of the Photogrammetry. Remote Sensing and Spatial Information Sciences*, 3: 257-263.