

پایش توزیع مکانی-زمانی شوری خاک در دشت اشتهارد کرج با تکیه بر سنجش از دور

لیلا اسماعیل‌نژاد*^۱، سعید سعادت^۲، فاطمه سیاوشی^۳



چکیده

شور و سدیمی شدن خاک‌ها، با تخریب ساختمان خاک‌ها، پفکی شدن سطح خاک و تجمع نمک در سطح خاک باعث افزایش حساسیت اراضی به انواع فرسایش به‌ویژه فرسایش بادی نیز می‌شوند. شهرستان اشتهارد، یکی از کانون‌های بحرانی گرد و غبار در استان البرز است که حدود ۲۴ هزار و ۵۰۰ هکتار از مجموع اراضی کشاورزی و منابع طبیعی شهرستان، از جمله همین کانون‌های گرد و غبار است. بنابراین ضروری است تا روند شوری خاک پیش‌بینی و پایش شود تا بتوان اقدامات حفاظتی در مقابل تخریب بیشتر اراضی اتخاذ شود. پیشرفت‌های اخیر در فناوری سنجش از دور امکان شناسایی دقیق و پایش مؤثر شوری خاک را فراهم کرده است. از این‌رو، در این مطالعه، سطوح شوری خاک‌های سطحی و احتمال وقوع طوفان‌های نمکی منطقه در اثر شور شدن اراضی در ۷۱۱۸ هکتار اراضی کشاورزی واقع در منطقه خشک اشتهارد کرج در بازه زمانی ۱۴۰۰-۱۳۹۰ با استفاده از الگوریتم‌های یادگیری ماشین در محیط گوگل ارث انجین بررسی شد. نتایج نشان داد که سطح شوری خاک‌های کشاورزی به‌میزان حدود ۱۸ درصد افزایش و کلاس شوری خاک، از خاک‌های غیر شور به شوری‌های کم تا متوسط تغییر یافته است. این امر می‌تواند نتیجه همزمان عوامل اقلیمی از جمله کاهش بارندگی و افزایش تبخیر از سطح خاک و همچنین عوامل انسانی شامل استفاده مداوم از آب‌های زیرزمینی با کیفیت پایین، فقدان سیستم‌های زهکشی مؤثر و مدیریت نادرست آبیاری باشد. همچنین کلاس احتمال وقوع بسیار کم طوفان‌های نمکی ۱۶۰ درصد و کلاس‌های کم و متوسط وقوع طوفان به‌ترتیب ۴۷ و حدود ۵۰۰ درصد در سال‌های ۱۳۹۰ تا ۱۴۰۰ افزایش داشته است. افزایش شوری موجب کاهش رشد پوشش گیاهی و تخریب ساختار خاک شده و در نتیجه مقاومت سطح خاک در برابر فرسایش بادی کاهش یافته و باعث افزایش طوفان‌های نمکی می‌شود.

واژگان کلیدی:

جنگل تصادفی، شاخص شوری، گوگل ارث انجین، لندست، یادگیری ماشین.

مقاله پژوهشی

۱. استادیار، بخش تحقیقات پایش و بهسازی منابع خاک و آب، موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران.

esmaeelnejad.leila@gmail.com

* نویسنده مسئول

۲. دانشیار، بخش تحقیقات پایش و بهسازی منابع خاک و آب، موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران.

saeed_saadat@yahoo.com

۳. کارشناس، بخش تحقیقات پایش و بهسازی منابع خاک و آب، موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران.

siavashfateme20@gmail.com

شناسه مقاله: ۱۱۶۶-۲۶۰۵

شماره صفحه پایایی: ۱۲۵۹-۱۲۴۹

تاریخ دریافت: ۱۴۰۵/۰۲/۱۹

تاریخ پذیرش: ۱۴۰۵/۰۳/۰۹

انتشار آنلاین: ۱۴۰۵/۰۳/۱۶

زمان پذیرش: ۲۲ روز

استناددهی:

اسماعیل‌نژاد، ل.، سعادت، س.، و سیاوشی، ف. (۱۴۰۴). پایش توزیع مکانی-زمانی شوری خاک در دشت اشتهارد کرج با تکیه بر سنجش از دور. مدیریت اکوسیستم‌های طبیعی، ۵(۴)، ۵۶-۶۶.

۱- مقدمه

شوری یکی از مهم‌ترین عوامل تخریب خاک بوده که به‌شدت بر بهره‌وری و پایداری اراضی تأثیر می‌گذارد. شوری یک پدیده پویا است که تحت فرآیندهای طبیعی و انسان‌زاد به‌ویژه در مناطق خشک و نیمه‌خشک به‌دلیل بارش کم، تبخیر آب‌های سطحی و عملیات کشت و کار گسترش می‌یابد (Singh, 2021). افزون بر این، نمک‌های محلول در نزدیکی عمق ریشه به‌دلیل استفاده از آب آبیاری نامتعارف و کاربرد بیش از حد کود، تجمع می‌یابند (Rengasamy, 2016).

سطح جهانی خاک‌های متأثر از نمک حدود ۱۰۳۰ میلیون هکتار است (FAO, 2018). طبق آخرین نقشه شوری خاک‌های کشاورزی ایران (سعادت و همکاران، ۱۴۰۲)، سطح کل اراضی کشاورزی شور کشور (با هدایت الکتریکی بیش از ۲ دسی‌زیمنس بر متر) ۱۰/۵ میلیون هکتار است که به‌نظر می‌رسد با توجه به شرایط تغییر اقلیم و افزایش استفاده از اراضی برای تولید غذا، این مقادیر در سال‌های آینده افزایش داشته باشند. از آنجا که حفظ پایدار امنیت غذایی در گرو حفظ منابع خاک و آب است، لذا پیشگیری از شور شدن و احیاء اراضی تحت تأثیر نمک برای استفاده مؤثر و پایدار از منابع خاک ضروری است که این امر مستلزم پایش مستمر وضعیت شوری خاک کشاورزی است. پایش تغییرات مکانی شوری خاک در فواصل کوتاه مدت، نیازمند جمع‌آوری تعداد زیادی نمونه خاک است. بنابراین، تعیین و پایش شوری خاک با روش‌های کلاسیک پرهزینه و زمان‌بر است. برخلاف روش‌های مرسوم، فن‌آوری‌های سنجش از دور اطلاعات مهمی در تعیین شوری خاک برای مناطق وسیع با دقت بالا ارائه می‌کنند. شاخص‌های زیادی برای تشخیص شوری خاک با استفاده از داده‌های ماهواره‌ای توسعه یافته‌اند (Khan et al., 2005). بازتاب طیفی یک عامل کلیدی در نقشه‌برداری شوری خاک است (Yahiaoui et al., 2015). با این حال، باید عوامل مختلفی که می‌توانند بر بازتاب طیفی تصاویر ماهواره‌ای تأثیر بگذارند، هنگام تحلیل شوری خاک در نظر گرفته شوند. ویژگی‌های فیزیکی و شیمیایی، رنگ خاک، مقدار رطوبت و زبری سطح از جمله عواملی هستند که می‌توانند بر بازتاب طیفی تأثیر بگذارند (Meier et al., 2018; Jafari et al., 2014). افزون بر این، خاک‌های شور یا سدیمی با پوسته‌ای تیره و پفی معمولاً بازتاب طیفی کمتری را نشان می‌دهند (Shahabi et al., 2017).

اگرچه شاخص‌های طیفی برای نقشه‌برداری شوری خاک با استفاده از سنجش از دور در حوزه علوم خاک به‌کار گرفته شده‌اند، لیکن مهم است که پلتفرم‌های جدیدی مانند گوگل ارث انجین نیز به‌کار گرفته شوند تا این رویکردها به‌روز شوند. گوگل ارث انجین قابلیت‌های بهبود یافته‌ای برای تحلیل و نقشه‌برداری توزیع شوری خاک ارائه می‌دهد و فرصت‌هایی برای افزایش دقت و کارایی نقشه‌های خاک فراهم می‌آورد. این کار از طریق تمرکز بر روی محاسبات ابری بوده و از زیرساخت محاسباتی گوگل و مجموعه وسیعی از تصاویر سنجش از دور رایگان با دقت‌های مختلف استفاده می‌کند. این پلتفرم قدرتمند در زمینه‌های مختلف علوم زمین کاربردهای مؤثری یافته است. یکی از ویژگی‌های کلیدی گوگل ارث انجین توانایی آن در انجام پردازش موازی خودکار است که از پلتفرم محاسبات سریع گوگل بهره می‌برد. این امر به‌طور قابل توجهی زمان پردازش را کاهش می‌دهد و چالش‌های مرتبط با مدیریت حجم‌های بزرگ داده را برطرف می‌کند. این پلتفرم دسترسی به حجم وسیعی از اطلاعات تصویری رایگان در بازه زمانی ۴۰ ساله را ارائه می‌دهد. این اطلاعات شامل تصاویری از سری سنجنده‌های مختلف شامل لندست، مودیس، سنتینل و موارد دیگر است (Feizizadeh et al., 2021). با توجه به اهمیت گسترده تکنیک‌های یادگیری ماشین در سنجش از دور، گوگل ارث انجین پیاده‌سازی الگوریتم‌های مختلف یادگیری ماشین را تسهیل می‌کند. این الگوریتم‌ها به‌طور کلی به چهار گروه اصلی تقسیم می‌شوند (Mahdianpari et al., 2022): (الف) الگوریتم‌های یادگیری آماری؛ این گروه شامل روش‌هایی مانند نایو بایس سریع است که از اصول آماری برای پیش‌بینی استفاده می‌کنند. (ب) روش‌های مبتنی بر پرسپترون؛ این دسته شامل الگوریتم‌هایی مانند وین‌نو و پرسپترون است که بر اساس اصول شبکه‌های عصبی و شناسایی الگو عمل می‌کنند. (ج) الگوریتم‌های مبتنی بر منطق؛ الگوریتم‌هایی مانند جنگل‌های تصادفی، درختان طبقه‌بندی و رگرسیون و جمومکس آنتروپی در این گروه قرار می‌گیرند. این الگوریتم‌ها از رویکردهای منطقی و مبتنی بر درخت تصمیم برای تحلیل و طبقه‌بندی داده‌های سنجش از دور استفاده می‌کنند و (د) الگوریتم‌های مبتنی بر ماشین بردار پشتیبان؛ این گروه شامل الگوریتم‌هایی مانند مارچین‌ها، ووتینگ‌ها، پگاسوس، آی‌کی پامیر هستند. ماش‌بردار پشتیبان یک تکنیک محبوب یادگیری ماشین است که از اصول هندسی برای جدا سازی و طبقه‌بندی داده‌ها استفاده می‌کند (Chen et al., 2022; Waleed et al., 2023; El Imanni et al., 2023). گوگل ارث انجین با استفاده از الگوریتم‌های یادگیری ماشین قصد دارد قابلیت‌های تحلیل و تفسیر داده‌های سنجش از دور را افزایش دهد (Zurqani et al., 2018). به‌طور خاص، در زمینه شناسایی اراضی شور با استفاده از گوگل ارث انجین و الگوریتم‌های یادگیری ماشین همراه با تحلیل مکانی، یک شکاف تحقیقاتی وجود دارد. عدم وجود مطالعات جامع در این حوزه فرصتی برای ارائه‌ی کمک‌های قابل توجه به حوزه سنجش از دور فراهم می‌آورد و نمایانگر یک جهت‌گیری پیشرفته تحقیقاتی است. این مطالعه سعی دارد علاوه بر پایش روند شور شدن اراضی کشاورزی

1. Google Earth Engine (GEE)
2. Fast Naïve Baye
3. Winnow and Perceptron
4. Random Forest (RF)
5. Classification and Regression Trees (CART)
6. Gmo Max Entropy

7. Support Vector Machines (SVM)
8. Margin SVM
9. Voting SVM
10. Pegasos
11. IKPamir

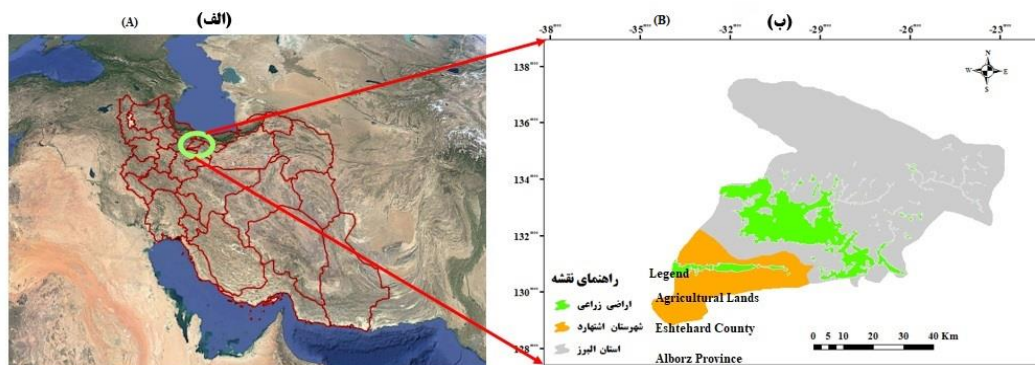
و بررسی تخریب خاک از لحاظ شوری، به اثرات شور شدن و تخریب خاک بر تغییرات حساسیت به فرسایش بادی و وقوع طوفان‌های گرد و غبار و نمک از اراضی کشاورزی نیز بپردازد و هشدارهای کشاورزی و زیست محیطی را به صورت یکجا ارائه نماید. بدین منظور، تصاویر سری لندست و همچنین عمق اپتیکی آئروسل مودیس (MCD19A2.061: Terra & Aqua MAIAC Land Aerosol Optical Depth Daily 1 km) از سال ۱۳۹۰ تا ۱۴۰۰ مورد استفاده قرار گرفتند.

شهرستان اشتهارد، یکی از کانون‌های بحرانی گرد و غبار در استان البرز است که حدود ۲۴ هزار و ۵۰۰ هکتار از مجموع اراضی کشاورزی و منابع طبیعی شهرستان، از جمله همین کانون‌های گرد و غبار است. بنابراین ضروری است تا روند شوری خاک پیش‌بینی و پایش شود تا بتوان اقدامات حفاظتی در مقابل تخریب بیشتر اراضی اتخاذ شود. پیشرفت‌های اخیر در فناوری سنجش از دور امکان شناسایی دقیق و پایش مؤثر شوری خاک را فراهم کرده است. از این‌رو، در این مطالعه، سطوح شوری خاک‌های سطحی و احتمال وقوع طوفان‌های نمکی منطقه در اثر شور شدن اراضی در ۷۱۱۸ هکتار اراضی کشاورزی واقع در منطقه خشک اشتهارد کرج در بازه زمانی ۱۴۰۰-۱۳۹۰ با استفاده از الگوریتم‌های یادگیری ماشین در محیط گوگل ارث انجین بررسی شد. شایان ذکر است منظور از طوفان نمکی، به جابجایی ذرات حاوی نمک‌های محلول مانند کلرید سدیم، سولفات سدیم و سایر املاح از سطوح شور، دریاچه‌های خشک شده، اراضی شور و خاک‌های دارای تجمع نمک اطلاق می‌شود. در این پدیده، علاوه بر ذرات خاک، کریستال‌ها و آئروسول‌های نمکی نیز در هوا منتشر می‌شوند.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

شهرستان اشتهارد در ۵۰ درجه و ۲۲ دقیقه طول جغرافیایی و ۳۵ درجه و ۴۳ دقیقه عرض جغرافیایی، در ارتفاع ۱۲۰۰ متری از سطح دریا واقع است. وسعت اراضی کشاورزی این شهرستان حدود ۷۱۱۸ هکتار بوده و بیشتر خاک‌های متأثر از نمک را شامل می‌شوند (شکل ۱). متوسط درجه حرارت در تابستان ۲۴/۸ درجه سانتی‌گراد و بیشینه آن ۳۶ درجه سانتی‌گراد است. آمارها نشان می‌دهد که در فصل بهار و تابستان درجه حرارت به تدریج افزایش یافته و این باعث تشدید تبخیر و کمبود رطوبت زمین شده که تلفات آب در این منطقه در این دو فصل به‌طور محسوس افزایش می‌یابد. مقدار متوسط باران سالیانه در دشت اشتهارد در حدود ۲۳۸/۴ میلی‌متر است. اشتهارد، براساس تقسیم‌بندی اقلیمی دومارتن در اقلیم خشک قرار می‌گیرد. شوری خاک در منطقه مورد مطالعه از کم تا بسیار شور متغیر است و کلرور سدیم، نمک غالب خاک است. شیب منطقه مورد مطالعه بسیار کم است که زهکشی آب‌های سطحی از مناطق کوهستانی اطراف را محدود می‌کند.

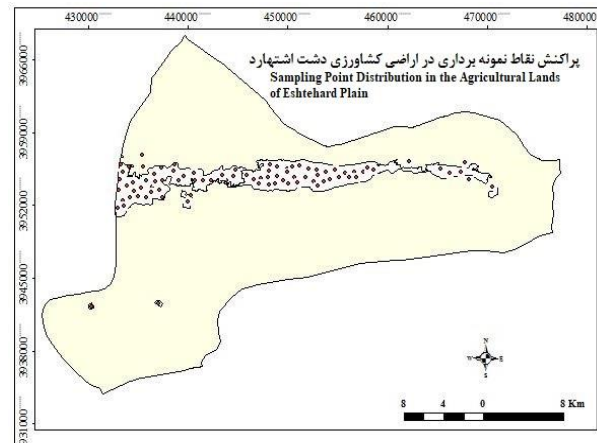


شکل (۱): موقعیت منطقه مورد مطالعه، موقعیت استان البرز در کشور (الف) و موقعیت شهرستان اشتهارد در استان البرز (ب).

۲-۲- تصاویر ماهواره‌ای و شاخص‌های به‌کار رفته در تهیه نقشه شوری خاک‌های کشاورزی دشت اشتهارد

به‌منظور پایش شوری خاک در اراضی کشاورزی اشتهارد، تصاویر ماهواره‌ای لندست ETM7 برای سال ۹۰ و OLI8 برای سال‌های ۱۳۹۲ تا ۱۴۰۰ و در فصل تابستان (مرداد ماه) و تقریباً هم‌زمان با نمونه‌برداری‌های خاک (با حداکثر یک هفته اختلاف زمانی) استفاده شد. برای هر سال یک تصویر ماهواره‌ای مربوط به زمان نمونه‌برداری با حداقل پوشش ابر انتخاب شد. همه مراحل پردازش تصویر در محیط گوگل ارث انجین انجام شد. بر اساس شبکه‌بندی، مشاهدات میدانی، نوع خاک و نقشه‌های کاربری/پوشش، ۱۰۰ نقطه نمونه‌برداری از خاک انتخاب و در سال‌های ۱۳۹۰ تا ۱۴۰۰ بررسی شد (شکل ۲). نمونه‌های خاک شامل ترکیب چهار نمونه خاک سطحی (از صفر تا ۳۰ سانتی‌متر) برای هر نقطه نمونه‌برداری بود. لایه صفر تا ۳۰ سانتی‌متری بخش فعال و سطحی خاک محسوب می‌شود که بیشترین تأثیر را از تبخیر، تجمع املاح، تغییرات رطوبتی و فرآیندهای فرسایش بادی می‌پذیرد. علاوه بر این، اغلب شاخص‌های طیفی ماهواره‌ای عمدتاً بازتاب ویژگی‌های لایه سطحی خاک را ثبت می‌کنند. نمونه‌های خاک از الک ۲ میلی‌متری عبور داده شده و در نهایت، هدایت الکتریکی خاک در عصاره اشباع اندازه‌گیری شد. عملیات آماده‌سازی خاک و انجام آزمایشات در مؤسسه تحقیقات خاک و آب

کرج انجام شد.



شکل (۲): موقعیت نقاط نمونه برداری و استفاده شده برای تهیه نقشه‌های شوری منطقه اشتهارد

با استفاده از روش K-Fold cross validation نقاط زمینی به دو گروه (۷۰ درصد برای آموزش الگوریتم‌ها و ۳۰ درصد برای اعتبارسنجی نتایج مدل سازی) تقسیم و با استفاده از شاخص‌های مختلف شوری خاک (جدول ۱) برای تهیه نقشه شوری خاک‌های کشاورزی دشت اشتهارد استفاده شدند. شاخص‌های شوری حاصل از سنجش از دور، به طور مستقیم شوری خاک را اندازه‌گیری نمی‌کنند بلکه بیانگر تغییرات طیفی مرتبط با تجمع نمک در سطح خاک هستند. این شاخص‌ها معمولاً از طریق کالیبراسیون با داده‌های زمینی به مقادیر شوری تخمینی تبدیل شده و یا برای طبقه‌بندی خاک به کلاس‌های مختلف شوری مورد استفاده قرار می‌گیرند.

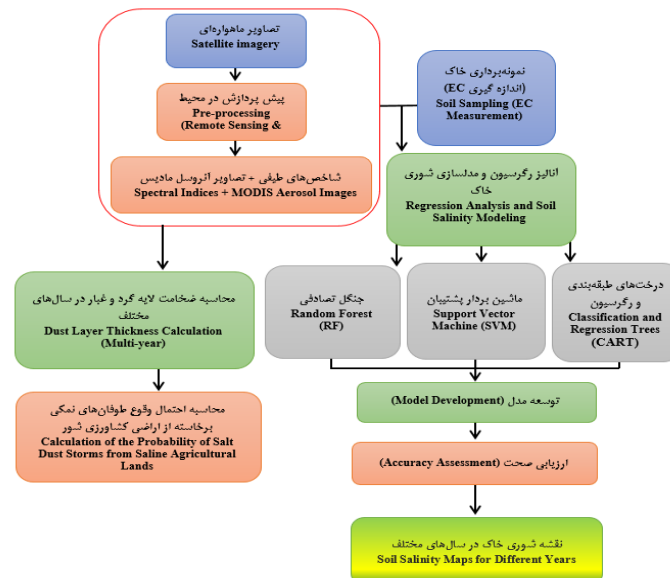
جدول (۱): شاخص‌های طیفی مختلف به کار رفته برای تهیه نقشه شوری خاک دشت اشتهارد

منبع	فرمول	مخفف	نام لاتین	شاخص طیفی
Khan et al., (2005)	$(R-NIR)/(R+NIR)$	NDSI	Normalized difference in salinity	تفاوت نرمال شده شوری
Khan et al., (2005)	$(G \times R) \cdot 0.5$	SI1	Salinity Index 1	شاخص شوری ۱
Abbas and Khan, (2007)	$[(G)^2 + (R)^2 + (NIR)^2] \cdot 0.5$	SI2	Salinity Index 2	شاخص شوری ۲
Douaoui et al., (2006)	$[(G)^2 + (R)^2] \cdot 0.5$	SI3	Salinity Index 3	شاخص شوری ۳
Khan et al., (2005)	B/R	S1	Salinity Index I	شاخص شوری I
Douaoui et al., (2006)	$(B-R)/(B+R)$	S2	Salinity Index II	شاخص شوری II
Douaoui et al., (2006)	$(G \times R)/B$	S3	Salinity Index III	شاخص شوری III
Khan et al., (2005)	$(B \times R)/G$	S5	Salinity Index V	شاخص شوری V
Khan et al., (2005)	$(R \times NIR)/G$	S6	Salinity Index VI	شاخص شوری VI

در ادامه، برای شناسایی شدت و فراوانی طوفان‌های نمکی، داده‌های مربوط به شاخص عمق نوری آئروسل مادیس (Terra & MCD19A2.061: AquaMAIAC Land Aerosol Optical Depth Daily 1 km) نیز در این مطالعه در محیط گوگل ارث انجین گنجانده شد. باندهای مرئی، مادون قرمز نزدیک و مادون قرمز کوتاه موج که > ساسیت بیشتری به تغییرات رطوبت، نمک سطحی و ویژگی‌های خاک دارند در تحلیل مورد استفاده قرار گرفت. در این مطالعه از یک رویکرد یکپارچه ترکیب سنجش از دور و گوگل ارث انجین برای نظارت و پایش شوری خاک استفاده شده است.

۲-۳- مدل سازی تهیه نقشه‌های شوری

کاتالوگ داده‌های گوگل ارث انجین شامل مجموعه داده‌های متعددی از جمله تصاویر سری Landsat و Sentinel و MODIS است. افزون بر این، مجموعه داده‌های کمتر شناخته شده‌ای مانند داده‌های فراطیفی، نور شب، آب و هوا و بیش از ۹۰۰ مجموعه داده دیگر وجود دارد (You and Dong, 2020). نکته قابل توجه این است که سرعت پردازش بالای ارائه شده توسط پلت فرم، نمونه سازی سریع الگوریتم‌های جدید را امکان پذیر می‌کند، که امکان آزمایش کارآمد و توسعه رویکردهای جدید را فراهم می‌کند (Sulova et al., 2020). همچنین، چندین الگوریتم یادگیری ماشینی در گوگل ارث انجین موجود است که در زیر اشاره شده است (شکل ۳):



شکل (۳): فلوجارت مراحل مدل‌سازی تهیه نقشه‌های شوری خاک‌های اشتهارد

۲-۳-۱- ماشین بردار پشتیبان

در واقع، ماشین بردار پشتیبان یک رویکرد نظارت شده و غیرپارامتری است و یکی از نقاط قوت مهم آن توانایی آن در تولید نتایج خوب حتی با تعداد محدودی از نمونه‌های آموزشی است. ماشین بردار پشتیبان از توابع هسته‌های مختلفی از جمله خطی، چند جمله‌ای، تابع شعاع محور (RBF) و سیگموئید استفاده می‌کند. در مطالعه حاضر، هسته توابع شعاع محور به دلیل برتری نشان داده شده آن نسبت به سایر هسته‌ها و استفاده گسترده از آن انتخاب شد. در این روش از پارامترهای بهینه شده $C=100$ و $\text{Gamma}=0.1$ استفاده شد که با روش Grid search در گوگل ارث انجین تنظیم شدند.

۲-۳-۲- جنگل تصادفی

جنگل تصادفی، یک روش طبقه‌بندی مبتنی بر یادگیری جمعی است که هدف آن بهبود عملکرد طبقه‌بندی با ساخت چندین طبقه‌بند به جای یک طبقه‌بند واحد است (Stumpf and Kerle, 2011). جنگل تصادفی چندین درخت تصمیم را که مستقل از یکدیگر هستند ترکیب می‌کند تا یک مدل قوی ایجاد کند. هر درخت تصمیم فرآیند ارزیابی خاص خود را طی می‌کند و نتایج این درخت‌ها برای تولید خروجی نهایی RF میانگین‌گیری می‌شود. درختان تصمیم، به‌عنوان یادگیرنده‌های ضعیف، ترکیب می‌شوند تا یک مدل قوی ایجاد کنند (Zhao et al., 2023). برای این الگوریتم، تعداد درخت‌های تصمیم (ntree) برابر با ۵۰۰ و تعداد متغیرهای تصادفی در هر گره (mtry) برابر با \sqrt{n} که n تعداد شاخص‌های ورودی است تنظیم شد.

۲-۳-۳- درخت‌های طبقه‌بندی و رگرسیون

درخت‌های طبقه‌بندی و رگرسیون یک تکنیک یادگیری ماشین است که برای اهداف رگرسیون و طبقه‌بندی استفاده می‌شود (Bittencourt and Clarke, 2003). این روش می‌تواند داده‌های عددی را برای رگرسیون و داده‌های دسته‌ای را برای طبقه‌بندی مدیریت کند. طبقه‌بندی این مدل یک درخت تصمیم را با تقسیم داده‌ها به‌طور مکرر در هر گره از ریشه می‌سازد. داده‌های آموزشی از طریق این تقسیمات به سمت پایین درخت منتقل می‌شوند و در هر گره، تصمیمی گرفته می‌شود تا جهت بعدی داده‌ها تعیین شود. فرآیند تقسیم ادامه می‌یابد تا زمانی که تنها یک نمونه باقی بماند و تصمیم نهایی در گره پایانی گرفته می‌شود که نمایانگر کلاس پیش‌بینی شده یا مقدار رگرسیون است. در زمینه پیاده‌سازی طبقه‌بند CART، ورودی‌ها معمولاً شامل مجموعه‌ای از ویژگی‌ها هستند که داده‌های آموزشی (۷۰٪ از داده‌ها) را نمایندگی می‌کنند. در این راستا، پلنفرم گوگل ارث انجین الگوریتم‌های طبقه‌بندی و رگرسیون CART را ارائه می‌دهد. این الگوریتم‌ها نیاز به تعریف دو پارامتر دارند. پارامتر اول maxNodes است که حداکثر تعداد گره‌های برگ در درخت تصمیم را تعیین می‌کند. به‌طور پیش‌فرض، هیچ محدودیتی برای حداکثر تعداد گره‌های برگ وجود ندارد. پارامتر دوم minLeafPopulation است که حداقل تعداد نقاط داده مورد نیاز برای ایجاد گره‌های جدید در حین ساخت درخت تصمیم را مشخص می‌کند. مقدار پیش‌فرض این پارامتر یک است (Arabameri et al., 2019; Bai et al., 2008). در مطالعه مذکور، تمام پارامترهای طبقه‌بندی و رگرسیون CART به مقادیر پیش‌فرض خود باقی ماندند، به این معنی که پارامتر maxNodes دارای مقدار نامحدود بود و پارامتر minLeafPopulation بر روی یک تنظیم شده بود.

۲-۴- بهبود دقت پیش‌بینی طوفان‌های نمکی با داده‌های AOD مودیس^۱

برای افزایش دقت پیش‌بینی احتمال وقوع طوفان‌های نمکی، داده‌های عمق نوری آئروسول مودیس برای تابستان سال‌های ۱۳۹۰ تا ۱۴۰۰ به دلیل همزمانی با برداشت نمونه‌های خاک از دشت اشتهارد از گوگل ارث انجین استخراج شد. میانگین ماهانه AOD برای هر پیکسل محاسبه و با نقشه‌های شوری خاک همپوشانی داده شد تا ارتباط بین سطوح مختلف شوری و ضخامت آئروسول بررسی شود. استفاده از میانگین ماهانه برای هر پیکسل باعث می‌شود نوسانات کوتاه مدت ناشی از شرایط جوی، تغییرات روزانه باد، ابرناکی و خطاهای لحظه‌ای سنجنده کاهش یابد. همچنین باعث افزایش پایداری زمانی داده‌ها و استخراج الگوی غالب آئروسول در منطقه خواهد شد.

۲-۵- ارزیابی دقت

در این مطالعه، از روش اعتبارسنجی متقابل^۲ استفاده شد. این روش شامل تقسیم نمونه‌ها به k دسته با اندازه‌های یکسان است. در هر تکرار، از $(k-1)$ دسته برای آموزش مدل استفاده می‌شود، در حالی که دسته باقی‌مانده برای اعتبارسنجی به کار می‌رود. این فرآیند k بار تکرار شده، به طوری که هر دسته به عنوان مجموعه‌ای برای اعتبارسنجی و همچنین مجموعه‌ای برای آموزش عمل کرد. پس از k تکرار، نتایج رگرسیون میانگین‌گیری شد تا نتیجه نهایی به دست آید (Kazemi Garajeh et al., 2022). در این مطالعه از $k=10$ استفاده شد.

برای ارزیابی عملکرد مدل، از دو معیار استفاده شد: ریشه میانگین مربعات خطانرمال شده (NRMSE) و ضریب تبیین (R^2). این معیارها در هر تکرار محاسبه شدند و میانگین همه نتایج تکرار برای تعیین دقت مدل استفاده شد [۷۰]. معادلات (۱)، (۲) و (۳) نحوه محاسبه معیارهای ارزیابی را نشان می‌دهند:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2} \quad \text{رابطه (۱)}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - Y_i)^2}{\sum_{i=1}^n (X_i - \bar{X}_i)^2} \quad \text{رابطه (۲)}$$

$$NRMSE = \frac{RMSE}{Mean} * 100 \quad \text{رابطه (۳)}$$

که n تعداد نمونه، X_i و Y_i به ترتیب مقادیر اندازه‌گیری و پیش‌بینی شده شوری خاک، و \bar{X}_i میانگین مقادیر اندازه‌گیری شده شوری خاک است.

۳- نتایج

۳-۱- اعتبارسنجی روش‌های مختلف برای تهیه نقشه شوری خاک‌های کشاورزی اشتهارد

این مطالعه با هدف نظارت بر توزیع شوری در خاک‌های کشاورزی دشت اشتهارد کرج، پایش روند شور شدن این خاک‌ها در یک دهه گذشته و شناسایی مناطق بالقوه برای تشدید شوری با استفاده از الگوریتم‌های یادگیری ماشین در محیط GEE با سه الگوریتم یادگیری ماشین، به نام‌های SVM، RF و CART، انجام شد. نتایج روش اعتبارسنجی متقابل K-fold نشان داد که SVM در نظارت و پایش شوری خاک نسبت به RF و CART با R^2 برابر با ۹۰/۲۶، ۸۹/۲۱، ۹۰/۱۲، ۹۱/۲۷، ۹۲/۳۶ و ۹۰/۸۹ درصد به ترتیب برای سال‌های ۱۳۹۰، ۱۳۹۲، ۱۳۹۴، ۱۳۹۶، ۱۳۹۸ و ۱۴۰۰ عملکرد بهتری داشته است و این تفاوت عملکرد از نظر آماری هم معنادار بوده است ($P < 0.05$) (جدول ۲).

جدول (۲): نتایج اعتبارسنجی مقاطع K-fold برای روش‌های مختلف ذکر شده در تهیه نقشه شوری اشتهارد

سال	SVM		RF		CART	
	R^2	NRMSE	R^2	NRMSE	R^2	NRMSE
۱۳۹۰	۹۰/۲۶	۱۰/۵	۸۳/۲	۱۲/۳	۸۲/۵	۱۲/۵
۱۳۹۲	۸۹/۲۱	۸۹	۸۵/۶	۱۵/۵	۸۲/۸	۱۵/۶
۱۳۹۴	۹۰/۱۲	۱۱/۳	۸۳/۷	۱۴/۳	۸۱/۵	۱۶/۳
۱۳۹۶	۹۱/۲۷	۱۳/۲	۸۱/۸	۲۱/۲	۸۱/۲	۲۰/۹
۱۳۹۸	۹۲/۳۶	۹/۷	۸۰/۲	۱۲/۹	۷۳/۷	۱۳/۳
۱۴۰۰	۹۰/۸۹	۱۲/۵	۸۷/۴	۱۹/۳	۷۹/۶	۱۶/۶

۳-۲- نقشه شوری خاک‌های کشاورزی دشت اشتهارد در سال‌های ۱۴۰۰-۱۳۹۰

بر پایه نتایج همبستگی بین شاخص‌های مختلف طیفی شوری (جدول ۳)، بهترین شاخص برای هر سال که بیشترین همبستگی را با داده‌های شوری زمینی داشت انتخاب و با توجه به نتایج حاصل از اعتبارسنجی (جدول ۲)، نقشه‌های شوری خاک در سال‌های متوالی بر اساس روش ماشین بردار پشتیبان تهیه شدند (شکل ۴). بدین ترتیب برای سال‌های ۱۳۹۰، ۱۳۹۲، ۱۳۹۴، ۱۳۹۶، شاخص شوری ۳ و سال‌های ۱۳۹۸ و ۱۴۰۰ شاخص شوری ۱ انتخاب و

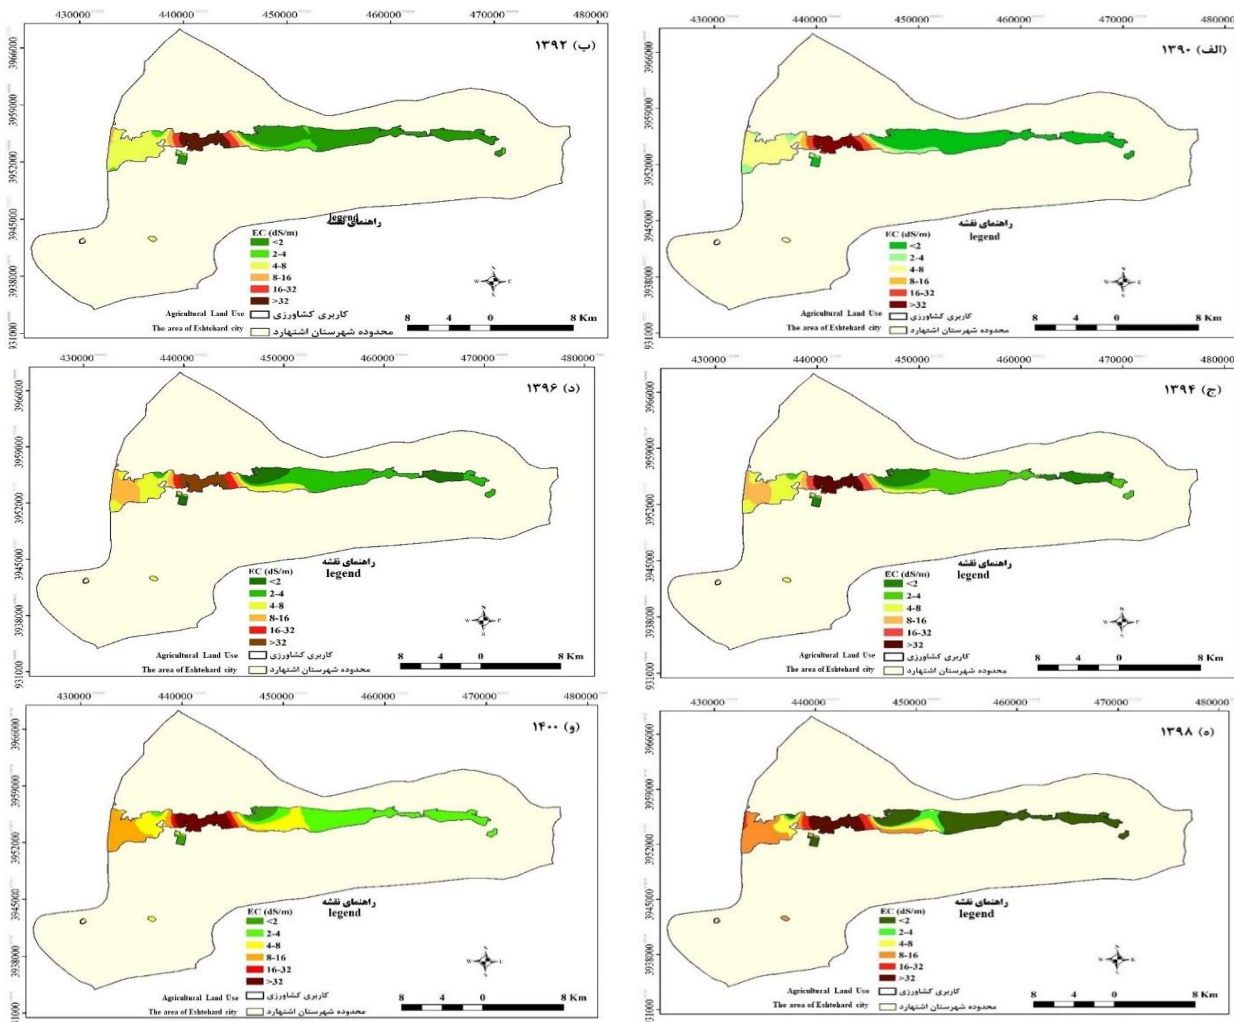
1. Aerosol Optical Depth (AOD)

2. K-fold cross-validation method

در تهیه نقشه شوری مورد استفاده قرار گرفت. بر پایه شکل (۲)، روند شور شدن اراضی کشاورزی از سال ۱۳۹۰ تا ۱۴۰۰ افزایشی بوده و با گذشت زمان از غرب به شرق اراضی دشت اشتهارد توسعه یافته است. تعاریف مربوط به هر شاخص شوری و باندهای طیفی مرتبط، در جدول (۱) ارائه شده است.


جدول (۳): همبستگی شاخص‌های طیفی به کار رفته برای تهیه نقشه شوری خاک اشتهارد با داده‌های زمینی

شاخص طیفی	نام لاتین	(۱۳۹۰)	(۱۳۹۲)	(۱۳۹۴)	(۱۳۹۶)	(۱۳۹۸)	(۱۴۰۰)
تفاوت نرمال شده شوری	Normalized difference in salinity	۰/۴۸	۰/۶۶	۰/۵۵	۰/۴۹	۰/۳۳	۰/۴۹
شاخص شوری ۱	Salinity Index 1	۰/۶۳	۰/۴۹	۰/۵۶	۰/۵۸	۰/۷۶	۰/۷۸
شاخص شوری ۲	Salinity Index 2	۰/۶۶	۰/۶۸	۰/۴۷	۰/۵۵	۰/۷	۰/۶۵
شاخص شوری ۳	Salinity Index 3	۰/۷۸	۰/۸۳	۰/۸۲	۰/۷۱	۰/۶۹	۰/۶۶
شاخص شوری I	Salinity Index I	۰/۳۳	۰/۷۵	۰/۸	۰/۷	۰/۵۳	۰/۵۹
شاخص شوری II	Salinity Index II	۰/۳۲	۰/۷۷	۰/۷۵	۰/۶۸	۰/۵۱	۰/۷
شاخص شوری III	Salinity Index III	۰/۵۵	۰/۷۵	۰/۶۹	۰/۵۲	۰/۴۸	۰/۵۷
شاخص شوری V	Salinity Index V	۰/۶۳	۰/۷۹	۰/۳۹	۰/۵۹	۰/۳۹	۰/۳۷
شاخص شوری VI	Salinity Index VI	۰/۵۱	۰/۲۲	۰/۵۲	۰/۶۶	۰/۵۵	۰/۴۲



شکل (۴): نقشه شوری خاک‌های کشاورزی دشت اشتهارد در سال‌های ۱۳۹۰ (الف)، ۱۳۹۲ (ب)، ۱۳۹۴ (ج)، ۱۳۹۶ (د)، ۱۳۹۸ (ه)، و ۱۴۰۰ (و).

شکل (۵)، توزیع شوری خاک در دشت اشتهارد را در سال‌های ۱۳۹۰ تا ۱۴۰۰ نشان می‌دهد. بر این اساس، در سال ۱۳۹۰، سطح کلاس خاک‌های غیر شور ($EC < 2 \text{ dS/m}$) حدود ۳۵/۵ درصد بوده که در سال ۱۴۰۰ این مقدار به ۱۷/۸ درصد رسیده است. این امر می‌تواند نتیجه همزمان عوامل اقلیمی و انسانی باشد. کاهش بارندگی و افزایش دما موجب تشدید تبخیر و کاهش شستشوی نمک‌ها از سطح خاک شده و در نتیجه املاح محلول در لایه‌های بالایی تجمع یافته‌اند. از سوی دیگر، استفاده مداوم از آب‌های زیرزمینی با کیفیت پایین، فقدان سیستم‌های زهکشی موثر، و مدیریت نادرست آبیاری سبب بالا آمدن سطح ایستایی و انتقال نمک از اعماق به سطح خاک شده است. تغییر کاربری اراضی، تخریب پوشش گیاهی و مصرف بی‌رویه کودهای شیمیایی نیز روند تجمع نمک‌ها را تسریع کرده‌اند (Arabameri et al., 2019). این سطح از اراضی، به درجات مختلفی تحت تأثیر شوری قرار گرفته‌اند. بدین ترتیب که تنها دو درصد از این اراضی غیر شور وارد کلاس با شوری کم (۴-۲ دسی‌زیمنس بر متر) شده ولی به سطح کلاس شوری متوسط (۸-۴ دسی‌زیمنس بر متر) ۱۵/۵ درصد افزوده شده است. همچنین درصد افزایش سطح کلاس شوری زیاد (۱۶-۸ دسی‌زیمنس بر متر) حدود ۰/۳۸ درصد بوده است. کلاس‌های شوری نسبتاً زیاد و خیلی زیاد تغییر چندانی نداشته و تقریباً ثابت بوده‌اند. این تغییرات حاکی از روند افزایشی شوری خاک در این منطقه بوده و نکته قابل توجه و هشدار دهنده این است که افزایش شوری بیشتر در مسیری در جریان است که خاک‌های غیر شور تبدیل به خاک‌هایی با شوری متوسط و زیاد می‌شوند.



شکل (۵): تغییرات سطح اراضی با شوری خاک مختلف در سال‌های ۱۳۹۰ تا ۱۴۰۰ در دشت اشتهارد

در این مطالعه، با استفاده از محصول AOD MODIS، سری‌های زمانی طوفان‌های گرد و غبار در منطقه مورد مطالعه از سال ۱۳۹۰ تا ۱۴۰۰ پایش شده است. جدول (۴) تغییرات مشاهده شده در ضخامت گرد و غبار در منطقه اشتهارد در این دوره را نشان می‌دهد. بر این اساس، ضخامت لایه گرد و غبار در منطقه اشتهارد در تابستان ۱۳۹۰ به میزان ۰/۲۱۲ ثبت شده است. در طول سال‌های بررسی شده، افزایش در ضخامت لایه گرد و غبار مشاهده شد و این مقدار در تابستان ۱۳۹۲ به ۰/۲۴۲ رسید. به دنبال آن، در تابستان ۱۳۹۴، ضخامت AOD به ۰/۲۴۹ افزایش یافت. مقدار ضخامت لایه گرد و غبار در تابستان ۱۳۹۶، ۱۳۹۸ و ۱۴۰۰ به ترتیب به ۰/۲۵۶، ۰/۲۷۸ و ۰/۳۲۱ افزایش داشته است.

جدول (۴): ضخامت لایه گرد و غبار (AOD) منطقه اشتهارد در سال‌های ۱۳۹۰-۱۴۰۰

نام لایه طیفی	۱۳۹۰	۱۳۹۲	۱۳۹۴	۱۳۹۶	۱۳۹۸	۱۴۰۰
ضخامت گرد و غبار	۰/۲۱۲	۰/۲۴۲	۰/۲۴۹	۰/۲۵۶	۰/۲۷۸	۰/۳۲۱

برای تعیین احتمال وقوع طوفان‌های نمکی، مناطقی که دارای شوری متوسط تا خیلی زیاد ($EC > 4 \text{ dS/m}$) و همزمان AOD بالا (> 0.25) بودند، به‌عنوان مناطق پرخطر شناسایی شدند (Zhang, 2024). سپس، با استفاده از آنالیز Overlay در گوگل ارث انجین، احتمال وقوع طوفان در پنج کلاس بسیار کم <math>< 5</math> درصد، کم: ۵ تا ۱۵ درصد، متوسط: ۱۵ تا ۳۰ درصد، زیاد: ۳۰ تا ۵۰ درصد، خیلی زیاد: بیشتر از ۵۰ درصد طبقه‌بندی شد. نتایج ارائه شده در جدول (۵)، نشان‌دهنده یک روند افزایشی در احتمال وقوع طوفان‌های نمکی بر خاسته از اراضی کشاورزی شور از سال ۱۳۹۰ تا ۱۴۰۰ می‌باشد. نتایج حاصل از الگوریتم‌های یادگیری ماشین به‌طور مداوم افزایش این احتمال را در مناطق با درجات مختلف شوری خاک در طول این دوره نشان می‌دهند. به‌عبارتی، مناطق با سطوح شوری خاک کم (۴-۲ دسی‌زیمنس بر متر) و متوسط (۸-۴ دسی‌زیمنس بر متر) در دوره ۱۳۹۰-۱۴۰۰ افزایش یافته‌اند و در نتیجه، پتانسیل طوفان‌های نمکی در آن مناطق افزایش یافته است. شایان ذکر است نتایج حاصل از الگوریتم‌های یادگیری ماشین، به‌طور مستقیم وقوع طوفان‌های نمکی را پیش‌بینی نکردند، بلکه از طریق تحلیل روابط بین شوری خاک، مقادیر AOD و سایر متغیرهای محیطی روند افزایش شرایط مستعد وقوع طوفان‌های نمکی را در مناطق با درجات مختلف شوری نشان دادند. بنابراین خروجی مدل‌ها بیشتر بیانگر افزایش پتانسیل یا احتمال نسبی بروز طوفان‌های نمکی به‌صورت غیر مستقیم است نه پیش‌بینی مستقیم رخداد طوفان.

جدول (۵): احتمال وقوع طوفان‌های نمکی (درصد) با استفاده از الگوریتم ماشین‌بردار پشتیبان در گوگل ارث انجین برای بازه ۱۴۰۰-۱۳۹۰

کلاس احتمال وقوع	۱۳۹۰	۱۳۹۲	۱۳۹۴	۱۳۹۶	۱۳۹۸	۱۴۰۰
بسیار کم	۱۲	۱۲/۹۵	۲۶/۶۴	۲۸/۵۳	۲۹/۲	۳۱/۲
کم	۴۷/۴	۴۹/۱	۵۴/۰۸	۵۹/۳۵	۶۸/۲	۶۹/۷
متوسط	۵/۱	۱۶/۱۷	۲۵/۵۱	۲۹/۹۷	۳۲/۵	۳۳/۱
زیاد	۱/۵۴	۳/۷۱	۲/۴۴	۱/۸۶	۱/۵	۱/۶
خیلی زیاد	۱/۰۷	۱/۰۹	۱/۳۳	۱/۲۹	۱/۵۱	۱/۸۱

این نتایج نشان می‌دهند که از سال ۱۳۹۰ تا ۱۴۰۰، روند کلی افزایش ضخامت طوفان‌های گرد و غبار در منطقه مورد مطالعه وجود داشته است. داده‌ها نشان‌دهنده‌ی افزایش تدریجی ضخامت AOD هستند که بیانگر افزایش شدت یا فراوانی طوفان‌های گرد و غبار در منطقه در طول زمان است. احتمال وقوع طوفان‌های نمکی در منطقه اشتهارد به‌ویژه در کلاس‌های احتمال وقوع بسیار کم، کم و متوسط به طور چشمگیری افزایش داشته است. کلاس احتمال وقوع بسیار کم طوفان‌های نمکی ۱۶۰ در صد، و کلاس‌های کم و متوسط وقوع طوفان به ترتیب ۴۷ در صد و حدود ۵۰۰ در صد در سال‌های ۱۳۹۰ تا ۱۴۰۰ افزایش داشته‌اند.

برای بررسی ارتباط بین شوری خاک و ضخامت آئروسول، مساحت کلاس متوسط شوری و میانگین AOD سالانه برای هر سال استخراج شد. ضریب تبیین (R^2) بین این دو متغیر برای سه الگوریتم محاسبه شد. جدول (۶) نشان می‌دهد که همبستگی زیادی بین کلاس متوسط شوری خاک و ضخامت آئروسول از سال ۱۳۹۰ تا ۱۴۰۰ وجود دارد که مقادیر ضریب تبیین برای روش‌های ماشین‌بردار پشتیبان، جنگل تصادفی و درخت‌های طبقه‌بندی و رگرسیون به ترتیب برابر با ۰/۶۹، ۰/۷۳ و ۰/۷۳ می‌باشد. نتایج همبستگی نشان می‌دهد که افزایش شوری خاک، ضخامت آئروسول را افزایش داده که به نوبه خود، فراوانی یا شدت و احتمال وقوع طوفان‌های نمکی را افزایش می‌دهد.

جدول (۶): ضریب همبستگی بین کلاس‌های شوری خاک و ضخامت لایه گرد و خاک در سال‌های ۱۴۰۰-۱۳۹۰			
روش‌ها	درخت‌های طبقه‌بندی و رگرسیون	جنگل تصادفی	ماشین‌بردار پشتیبان
ضریب همبستگی	۰/۷۳	۰/۶۹	۰/۶۹

بر این اساس، همزمان با افزایش شوری خاک، ضخامت لایه گرد و غبار نیز در منطقه به‌طور قابل توجهی افزایش یافته است. این همزمانی بیانگر وجود یک چرخه بازخورد مثبت میان شور شدن خاک و افزایش فرسایش بادی است. افزایش شوری موجب کاهش رشد پوشش گیاهی و تخریب ساختار خاک شده و در نتیجه مقاومت سطح خاک در برابر فرسایش بادی کاهش می‌یابد. از سوی دیگر تجمع لایه‌های گرد و غبار بر سطح خاک باعث تغییر ویژگی‌های فیزیکی و شیمیایی آن، کاهش نفوذپذیری و افزایش تخییر سطحی می‌شود که خود به تشدید شوری منجر می‌شود (You and Dong, 2020). بنابراین افزایش ضخامت گرد و خاک نه تنها نتیجه فرسایش بادی ناشی از خاک شور و خشک است، بلکه به صورت متقابل می‌تواند روند شور شدن خاک را تسریع کند. این رابطه دو طرفه، نقش مهمی در تداوم و گسترش بیابان زایی در مناطق خشک و نیمه خشک دارد و تاکید می‌کند که پایش همزمان تغییرات شوری و گرد و غبار برای مدیریت پایدار منابع خاک و آب ضروری است.

۴- نتیجه‌گیری کلی

در این مطالعه، از الگوریتم‌های یادگیری ماشین مانند ماشین‌بردار پشتیبان، جنگل تصادفی و درخت‌های طبقه‌بندی و رگرسیون برای پایش مؤثر بر توزیع شوری خاک و شناسایی مناطق بالقوه برای وقوع طوفان نمک در منطقه اشتهارد استفاده شد. یافته‌ها نشان می‌دهد که روش ماشین‌بردار پشتیبان با ۹۰/۲۶، ۸۹/۲۱، ۹۰/۱۲، ۹۱/۲۷، ۹۲/۳۶ و ۹۰/۸۹ درصد به ترتیب برای سال‌های ۱۳۹۰، ۱۳۹۲، ۱۳۹۴، ۱۳۹۶، ۱۳۹۸ و ۱۴۰۰ در مقایسه با جنگل تصادفی و درخت‌های طبقه‌بندی و رگرسیون نظارت بر توزیع شوری خاک در منطقه عملکرد بهتری داشته است. افزون بر این، نتایج نشان می‌دهد که روند افزایشی در سطح مناطق بالقوه برای وقوع طوفان نمک، همچنین افزایش احتمال وقوع آن از سال ۱۳۹۰ تا ۱۴۰۰ در منطقه وجود دارد. افزایش مقادیر AOD لزوماً به معنای علت مستقیم وقوع طوفان نمکی نیست، بلکه بیشتر بیانگر افزایش غلظت ذرات معلق و فعالیت فرسایش بادی در منطقه است. در واقع، شوری خاک، افزایش AOD و وقوع طوفان‌های نمکی می‌توانند به‌طور همزمان تحت تاثیر عوامل مشترکی مانند خشک سالی، کاهش رطوبت خاک، افت پوشش گیاهی، مدیریت نامناسب منابع آب و کاربری ناپایدار اراضی قرار گیرند. این عوامل با تشدید تجمع نمک در سطح خاک و افزایش ناپایداری سطح زمین، شرایط را برای انتشار ذرات نمکی و افزایش بار آئروسول فراهم می‌کنند. این امر اهمیت نظارت مستمر و ارزیابی شوری خاک را برای درک بهتر و پیش‌بینی وقوع طوفان‌های نمک را نشان می‌دهد. نتایج همچنین افزایش تدریجی ضخامت لایه گرد و غبار را از سال ۱۳۹۰ تا ۱۴۰۰ نشان می‌دهد که حاکی از افزایش شدت یا فراوانی طوفان‌های گرد و غبار در منطقه در طول زمان است. این مطالعه نشان داد که استفاده از پلتفرم گوگل ارث انجین دسترس آسان به طیف وسیعی از مجموعه‌های داده را فراهم می‌کند و نیاز به مراحل پیش‌پردازش گسترده را از بین می‌برد. این ادغام مجموعه داده‌های سنجنش از دور با پلتفرم گوگل ارث انجین در نظارت و نقشه‌برداری ماهیت دینامیک شوری خاک در مناطق وسیع بسیار مؤثر است. به‌طور کلی، نتایج این مطالعه بینش‌ها و کاربردهای عملی را به محققان، برنامه‌ریزان و مدیران ارائه می‌دهد و آنها را قادر می‌سازد تا مناطقی که بیشتر تحت تأثیر شوری قرار دارند شناسایی کرده تا بتوانند مناطق بالقوه در معرض تخریب خاک و افزایش خطر طوفان‌های نمک را پیش‌بینی کنند.

منابع

- سعادت، س.، رضایی، ح.، اسماعیل نژاد، ل.، میرخانی، ر.، و باقری، ی. ر. (۱۴۰۲) نقشه شوری خاک‌های کشاورزی ایران. نشریه فنی شماره ۳۰ موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی.
- Abbas, A., and Khan, S. (2007). Using remote sensing techniques for appraisal of irrigated soil salinity. In International Congress on Modelling and Simulation (MODSIM) (pp. 2632-2638). Modelling and Simulation Society of Australia and New Zealand. 2632-2638.
- Arabameri, A., Roy, J., Saha, S., Blaschke, T., Ghorbanzadeh, O., and Tien Bui, D. (2019). Application of probabilistic and machine learning models for groundwater potentiality mapping in Damghan sedimentary plain, Iran. *Remote Sensing*, 11(24), 3015.
- Bai, S.B., Wang, J., Lu, G.N., Kanevski, M., and Pozdnoukhov, A. (2008). GIS-based landslide susceptibility mapping with comparisons of results from machine learning methods process versus logistic regression in Bailongjiang river basin, China. *Geophysical Research Abstracts*. 10, 1-2.
- Bittencourt, H.R., and Clarke, R.T. (2003). Use of classification and regression trees (CART) to classify remotely-sensed digital images. *IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No. 03CH37477) (Vol. 6, pp. 3751-3753)*. IEEE.
- Chen, H., Yunus, A. P., Nukapothula, S., and Avtar, R. (2022). Modelling Arctic coastal plain lake depths using machine learning and Google Earth Engine. *Physics and Chemistry of the Earth, Parts A/B/C*, 126(3), 103138.
- Douaoui A., Nicolas, Hervé N., Christian, W. (2006). Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. *Geoderma*. 134(1). 217-230.
- FAO. 2018. Handbook for saline soil management. Editors: R. Vargas, E.I. Pankova, S.A. Balyuk, P.V. Krasilnikov and G.M. Khasankhanova. Published by the Food and Agriculture Organization of the United Nations and Lomonosov Moscow State University.
- Feizizadeh, B., Garajeh, M.K., Lakes, T., and Blaschke, T. (2021). A deep learning convolutional neural network algorithm for detecting saline flow sources and mapping the environmental impacts of the Urmia Lake drought in Iran. *Catena*, 207(1), 105585.
- El Imanni, H.S., El Harti, A., Bachaoui, E.M., Mouncif, H., Eddassouqui, F., Hasnai, M.A., and Zinelabidine, M.I. (2023). Multispectral UAV data for detection of weeds in a citrus farm using machine learning and Google Earth Engine: Case study of Morocco. *Remote Sensing Applications: Society and Environment*, 30, 100941.
- Jafari, A., Khademi, H., Finke, P. A., Van de Wauw, J., and Ayoubi, S. (2014). Spatial prediction of soil great groups by boosted regression trees using a limited point dataset in an arid region, southeastern Iran. *Geoderma*, 232(1), 148-163.
- Kazemi Garajeh, M., Li, Z., Hasanlu, S., Zare Naghadehi, S., and Hossein Haghi, V. (2022). Developing an integrated approach based on geographic object-based image analysis and convolutional neural network for volcanic and glacial landforms mapping. *Scientific Reports*, 12(1), 21396.
- Khan, N.M., Rastoskuev, V.V., Sato, Y., and Shiozawa, S. (2005). Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators. *Agricultural Water Management*, 77(1-3), 96-109.
- Mahdianpari, M., Brisco, B., Salehi, B., Granger, J., Mohammadimanesh, F., Lang, M., and Toure, S. (2022). Toward a North American continental wetland map from space: wetland classification using satellite imagery and machine learning algorithms on Google Earth Engine. In *Book: Radar Remote Sensing* (pp. 357-373), Elsevier.
- Meier, M., Souza, E.D., Francelino, M.R., Fernandes Filho, E.I., and Schaefer, C.E.G.R. (2018). Digital soil mapping using machine learning algorithms in a tropical mountainous area. *Revista Brasileira de Ciência do Solo*, 42, e0170421.
- Rengasamy, P. (2016). Soil salinization. In *Oxford Research Encyclopedia of Environmental Science*.
- Shahabi, M., Jafarzadeh, A.A., Neyshabouri, M.R., Ghorbani, M.A., and Valizadeh Kamran, K. (2017). Spatial modeling of soil salinity using multiple linear regression, ordinary kriging and artificial neural network methods. *Archives of Agronomy and Soil Science*, 63(2), 151-160.
- Singh, A. (2021). Soil salinization management for sustainable development: A review. *Journal of Environmental Management*, 277(3), 111383.
- Stumpf, A., and Kerle, N. (2011). Object-oriented mapping of landslides using Random Forests. *Remote Sensing of Environment*, 115(10), 2564-2577.
- Sulova, A., and Jokar Arsanjani, J. (2020). Exploratory analysis of driving force of wildfires in Australia: An application of machine learning within Google Earth engine. *Remote Sensing*, 13(1), 10.
- Waleed, M., Sajjad, M., Shazil, M.S., Tariq, M., and Alam, M.T. (2023). Machine learning-based spatial-temporal assessment and change transition analysis of wetlands: An application of Google Earth Engine in Sylhet, Bangladesh (1985-2022). *Ecological Informatics*, 75(2), 102075.
- Yahiaoui, I., Douaoui, A., Zhang, Q., and Ziane, A. (2015). Soil salinity prediction in the Lower Cheliff plain (Algeria) based on remote sensing and topographic feature analysis. *Journal of Arid Land*, 7(6), 794-805.
- You, N., and Dong, J. (2020). Examining earliest identifiable timing of crops using all available Sentinel 1/2 imagery and Google Earth Engine. *ISPRS Journal of Photogrammetry and Remote Sensing*, 161, 109-123.
- Zhang, F. (2023). Factors influencing the spatio-temporal variability of aerosol optical depth over the arid region of Northwest China. *Atmosphere*, 15(1), 54.
- Zhao, F., Feng, S., Xie, F., Zhu, S., and Zhang, S. (2023). Extraction of long time series wetland information based on Google Earth Engine and random forest algorithm for a plateau lake basin- A case study of Dianchi Lake, Yunnan Province, China. *Ecological Indicators*, 146(02), 109813.
- Zurqani, H.A., Post, C.J., Mikhailova, E.A., Schlautman, M.A., and Sharp, J.L. (2018). Geospatial analysis of land use change in the Savannah River Basin using Google Earth Engine. *International Journal of Applied Earth Observation and Geoinformation*, 69(5), 175-185.

Monitoring the spatial-temporal distribution of soil salinity in the Eshtehard Plain of Karaj using remote sensing

Leila Esmaeelnejad^{*1}, Saeed Saadat², Fatemeh Siavashi³



Research Article

1. Assistant professor, Monitoring and improvement of soil and water research department, Soil and water research institute (SWRI), Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran.

esmaeelnejad.leila@gmail.com

* Corresponding author

2. Associated professor, Monitoring and improvement of soil and water research department, Soil and water research institute (SWRI), Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran.

saeed_saadat@yahoo.com

3. Monitoring and improvement of soil and water research department, Soil and water research institute (SWRI), Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran.

siavashifateme20@gmail.com

Article Code: 2605-1166

Continus Pagnation: 1249-1259

Received: 09 May 2026

Accepted: 30 May 2026

Online: 06 June 2026

Review speed: 22 days

Citation:

Esmaeelnejad, L., Saadat, S., and Siavashi, F. (2026). Monitoring the spatial-temporal distribution of soil salinity in the Eshtehard Plain of Karaj using remote sensing. *Management of Natural Ecosystems*, 5(4), 56-66.

Abstract

Salinization and sodification of soils, by degrading soil structure, causing a loose surface structure, and salt accumulation at the soil surface, increase the sensitivity of lands to various types of erosion, especially wind erosion. Eshtehard County is one of the critical dust hotspots in Alborz Province, where approximately 24,500 hectares of county's agricultural and natural resources are among these dust sources. Therefore, it is essential to predict and monitor soil salinity trends in order to implement protective measures against further land degradation. Recent advancements in remote sensing technology have enabled accurate detection and effective monitoring of soil salinity. Consequently, this study examined the levels of surface soil salinity and the likelihood of saltstorm occurrences in 7,118 hectares of agricultural land in the arid region of Eshtehard, Karaj, over the period from 2011 to 2021 using machine learning algorithms in the Google Earth Engine (GEE). The results indicated that the level of salinity in agricultural soils increased by approximately 18%, and the salinity class shifted from non-saline soils to low to moderate salinity. This could be the result of a combination of climatic factors, including reduced rainfall and increased evaporation from the soil surface, as well as human factors, including the continued use of low-quality groundwater, the lack of effective drainage systems, and improper irrigation management. Additionally, the class of very low probability for saltstorm occurrences increased by 160%, while the classes for low and moderate probability increased by 47% and approximately 500%, respectively, from 2011 to 2021. Increased salinity reduces vegetation growth and destroys soil structure, resulting in a decrease in the resistance of the soil surface to wind erosion and an increase in salt storms.

Key Words:

Random forest, salinity index, Google Earth Engine, Landsat, machine learning.