

## توسعه یک سیستم پشتیبانی تصمیم‌گیری مبتنی بر مدل‌های یادگیری ماشین برای مدیریت پایدار فرسایش بادی

جواد مؤمنی دمنه<sup>۱</sup>، هادی معماریان<sup>۲\*</sup>

دریافت: ۱۴۰۳/۱۱/۳۰

پذیرش: ۱۴۰۳/۱۲/۲۷

### چکیده

این پژوهش با هدف توسعه روشی دقیق و جامع برای ارزیابی آسیب‌پذیری خاک در برابر فرسایش بادی انجام شد. فرسایش بادی به‌عنوان یک مسئله مهم زیست‌محیطی، می‌تواند منجر به عواقب جبران‌ناپذیری مانند از دست دادن خاک، تخریب زیستگاه‌ها و آلودگی منابع آب شود. برای کاهش اثرات مخرب این پدیده، نقشه‌برداری دقیق از حساسیت اراضی به فرسایش بادی امری ضروری است. با تلفیق مدل‌سازی فضایی و یادگیری ماشین، طیف گسترده‌ای از مدل‌های آماری پیشرفته و الگوریتم‌های یادگیری ماشین مورد بررسی قرار گرفت. برای ارزیابی فرسایش بادی در منطقه مورد مطالعه، روشی چندمرحله‌ای به کار گرفته شد. نقشه‌های توپوگرافی، پوشش گیاهی، خاک و داده‌های زمین‌شناسی با استفاده از سیستم اطلاعات جغرافیایی یکپارچه شدند. در مجموع ۲۵ متغیر محیطی مورد تجزیه و تحلیل قرار گرفت که ۲۳ متغیر براساس ضریب تورم واریانس کمترین میزان هم‌خطی را دارا بودند؛ برای مدل‌سازی انتخاب شدند. طیف وسیعی از الگوریتم‌های یادگیری ماشین اعمال شد و در نهایت مدل اجماعی به‌عنوان دقیق‌ترین مدل شناخته شد و به‌طور مؤثر مناطق مستعد فرسایش بادی را پیش‌بینی کرد. متغیرهای محیطی مؤثر که اهمیت بالایی در ایجاد فرسایش داشتند شامل تراکم زهکشی، گروه‌های هیدرولوژیکی، فراوانی سنگ و قلوه‌سنگ، درصد خاک بدون پوشش گیاهی، شیب، میانگین دمای هوا و پوشش گیاهی که به ترتیب ۱۲/۲۲، ۱۱/۵۲، ۹/۹۰، ۷/۹۱، ۷/۲۵، ۶/۶۶ و ۵/۳۱ درصد بودند. نقشه‌های تولیدشده می‌توانند به‌عنوان ابزاری ارزشمند برای برنامه‌ریزی و اجرای اقدامات کنترل فرسایش مورد استفاده قرار گیرند.

**کلیدواژه‌ها:** حساسیت به فرسایش، ارزیابی خطر، داده‌های سنجنش از دور، داده‌های مکانی، مدل‌های ترکیبی، مدیریت منابع طبیعی.

۱. دانش‌آموخته دکتری بیابان‌زدایی، گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران؛

[j.momenidamaneh.phd@hormozgan.ac.ir](mailto:j.momenidamaneh.phd@hormozgan.ac.ir)

۲. دانشیار دانشکده منابع طبیعی و محیط‌زیست، دانشگاه بیرجند، ایران، نویسنده مسئول؛ [hadi\\_memarian@birjand.ac.ir](mailto:hadi_memarian@birjand.ac.ir)

## مقدمه

و همکاران، ۲۰۲۲). ترکیب هوشمندانه مدل‌سازی فضایی و یادگیری ماشین، تحولی شگرف در پیش‌بینی و تحلیل آسیب‌پذیری اجتماعی-اقتصادی خاک در برابر فرسایش ایجاد کرده است. الگوریتم‌های یادگیری ماشینی متنوعی همچون جنگل تصادفی (RF<sup>۹</sup>)، شبکه‌های عصبی مصنوعی (ANN<sup>۱۰</sup>)، ماشین‌های بردار پشتیبان (SVM<sup>۱۱</sup>)، مدل‌های خطی تعمیم‌یافته (GLM<sup>۱۲</sup>) و... قادرند روابط پیچیده و غیرخطی میان عوامل محیطی و آسیب‌پذیری خاک را به‌طور دقیق شناسایی و مدل‌سازی کنند. این درحالی است که مدل‌های سنتی در درک کامل این پیچیدگی‌ها ناتوان هستند (گاین<sup>۱۳</sup> و همکاران، ۲۰۱۹؛ الباوی<sup>۱۴</sup> و همکاران، ۲۰۲۱). با تلفیق این دو رویکرد و بهره‌گیری از قدرت سیستم اطلاعات جغرافیایی و داده‌های سنجش از دور، امکان ترسیم دقیق الگوهای مکانی آسیب‌پذیری خاک و پیش‌بینی روند فرسایش در مناطق مختلف فراهم شده است. این رویکرد مبتنی بر داده، به مدل‌ها اجازه می‌دهد تا با استفاده از حجم عظیمی از داده‌ها، خود را با شرایط مختلف جغرافیایی تطبیق دهند و دقت پیش‌بینی‌ها را به‌طور چشمگیری افزایش دهند (اولی و همکاران، ۲۰۲۴b). علاوه بر این، با استفاده از عوامل طبقه‌بندی شده و وزن‌دار که متناسب با شرایط محیطی محلی تنظیم می‌شوند، دقت پیش‌بینی‌ها به‌طور قابل توجهی بهبود می‌یابد. این هم‌افزایی قدرتمند، ابزاری ارزشمند برای مدیریت بهینه زمین و توسعه راهبردهای مؤثر در پیشگیری از فرسایش خاک در اختیار ما قرار می‌دهد. در واقع، این ترکیب نوآورانه به ما امکان می‌دهد تا با دقت بیشتری مناطق در معرض خطر فرسایش را شناسایی کرده و اقدامات پیشگیرانه مناسب را به‌موقع انجام دهیم.

اکثر مطالعات اخیر که از الگوریتم‌های یادگیری ماشین برای پیش‌بینی آسیب‌پذیری خاک در برابر فرسایش بهره می‌گیرند، به‌طور معمول از داده‌های پیوسته و نرمال شده به‌عنوان ورودی استفاده می‌کنند و از طبقه‌بندی گسسته یا وزن‌دهی مبتنی بر دانش کارشناسان صرف‌نظر می‌کنند. این رویکرد، به دلیل ماهیت

فرسایش خاک به‌عنوان یکی از جدی‌ترین چالش‌های زیست‌محیطی عصر حاضر، همچنان اکوسیستم‌ها، کشاورزی و زیرساخت‌های بسیاری را در سراسر جهان تحت تأثیر قرار می‌دهد (اولی<sup>۱</sup> و همکاران، ۲۰۲۳). خاک حاصلخیز، این منبع ارزشمند و حیاتی، در معرض تهدید جدی فرسایش قرار دارد. این پدیده نه تنها به تخریب پوشش گیاهی و آلودگی منابع آب منجر می‌شود، بلکه امنیت غذایی، تنوع زیستی (ارابامری<sup>۲</sup> و همکاران، ۲۰۱۹) و پایداری اقتصادی جوامع (الموکتار<sup>۳</sup> و همکاران، ۲۰۲۱) را نیز به مخاطره می‌اندازد. لذا پیش‌بینی و مدیریت دقیق حساسیت فرسایش خاک (SES<sup>۴</sup>) به‌عنوان یک ضرورت اجتناب‌ناپذیر برای حفاظت از محیط‌زیست و جلوگیری از تخریب خاک مطرح می‌شود (کاکوکار و سدانوگیرالدو، ۲۰۲۲<sup>۵</sup>). در این راستا، توسعه مدل‌های دقیق و قابل اعتماد که قادر به پیش‌بینی حساسیت مناطق مختلف به فرسایش باشند، گامی مؤثر در جهت مقابله با این معضل جهانی خواهد بود. مدل‌سازی سیستم‌های اکولوژیکی خاکی به‌منظور پیش‌بینی فرسایش خاک، به‌طور سنتی بر پایه رویکردهای تجربی استوار بوده است. این رویکردها با استفاده از داده‌های تاریخی و روابط آماری ساده، به مدل‌سازی الگوهای فرسایش خاک می‌پردازند (ساینی<sup>۶</sup> و همکاران، ۲۰۱۵). با این حال، ماهیت پیچیده و چندمتغیره فرایند فرسایش خاک که تحت تأثیر عوامل متعدد از جمله شدت بارندگی، نوع خاک، کاربری زمین و توپوگرافی قرار دارد، فراتر از توان مدل‌های ساده آماری است (اولی<sup>۷</sup> و همکاران، ۲۰۲۴a). در نتیجه، با توجه به پیچیدگی روزافزون پدیده فرسایش خاک، ضرورت توسعه مدل‌های پیچیده‌تر و قدرتمندتری که قادر به شبیه‌سازی دقیق این پیچیدگی‌ها و ارائه پیش‌بینی‌های دقیق‌تر باشند، بیش از پیش احساس می‌شود (کاکوکار و سدانوگیرالدو، ۲۰۲۲؛ گلیجانین<sup>۸</sup> و

9. Random Forest

10. Artificial Neural Network

11. Support Vector Machine

12. Generalized Liner Model

13. Gayen

14. Al-Bawi

1. Ollı

2. Arabameri

3. Almouctar

4. soil erosion susceptibility

5. Kucuker &amp; Cedano Giraldo

6. Saini

7. Ollı

8. Golijanin

توجه به ماهیت غیرخطی و پیچیده روابط بین متغیرهای محیطی و آسیب‌پذیری خاک، از مدل‌های یادگیری ماشینی با قابلیت یادگیری الگوهای پیچیده استفاده شده است. یکی از نوآوری‌های این پژوهش، استفاده از رویکرد مدل‌سازی جغرافیایی برای در نظر گرفتن تغییرات مکانی آسیب‌پذیری خاک است. با تلفیق داده‌های مکانی و مدل‌های پیش‌بینی، می‌توان نقشه‌های دقیق‌تری از پراکنش آسیب‌پذیری خاک در یک منطقه تهیه کرد. این نقشه‌ها می‌توانند به‌عنوان ابزاری کارآمد برای برنامه‌ریزی و مدیریت پایدار منابع خاک مورد استفاده قرار گیرند. یافته‌های این پژوهش نه تنها به بهبود درک ما از نقاط قوت و محدودیت‌های مدل‌های یادگیری ماشینی در حوزه مدل‌سازی محیطی کمک خواهد کرد، بلکه می‌تواند به‌عنوان یک پایه مستحکم برای تحقیقات آتی در زمینه ادغام رویکردهای آماری و یادگیری ماشینی در مدل‌سازی جغرافیایی فرسایش خاک نیز مورد استفاده قرار گیرد. به‌طور کلی، نتایج این مطالعه می‌تواند در ارتقای دقت و قابلیت اطمینان ارزیابی‌های آسیب‌پذیری خاک در برابر فرسایش و در نتیجه، بهبود مدیریت منابع طبیعی و محیط‌زیست، نقش مؤثری ایفا نماید. با شناسایی مناطق با آسیب‌پذیری بالا، می‌توان اقدامات حفاظتی مناسب‌تری را برای کاهش فرسایش خاک و حفظ حاصلخیزی آن برنامه‌ریزی کرد.

## مواد و روش‌ها

### منطقه مطالعه شده

حوزه آبخیز مختاران با وسعتی بالغ بر ۲۴۲۱ کیلومتر مربع در جنوب ارتفاعات باقران و در استان خراسان جنوبی واقع شده است. این حوزه از نظر جغرافیایی بین مختصات طول جغرافیایی  $32^{\circ} 02' 59''$  تا  $59^{\circ} 08' 59''$  طول شرقی و عرض جغرافیایی  $18^{\circ} 25' 36''$  تا  $31^{\circ} 31' 36''$  شمالی گسترده شده است (شکل ۱). شکل کلی این حوزه، کشیدگی بیشتری در جهت شرق به غرب (هم‌راستا با دشت) نسبت به شمال به جنوب دارد. تنوع توپوگرافی در این منطقه بسیار چشمگیر بوده و شامل کوهستان‌ها، تپه‌ماهورها، دشت‌های وسیع، کویر و دق‌های فاقد پوشش گیاهی می‌شود. براساس طبقه‌بندی اقلیمی دومارتن اصلاح‌شده، اقلیم حاکم بر دشت‌ها و کوهپایه‌های این حوزه،

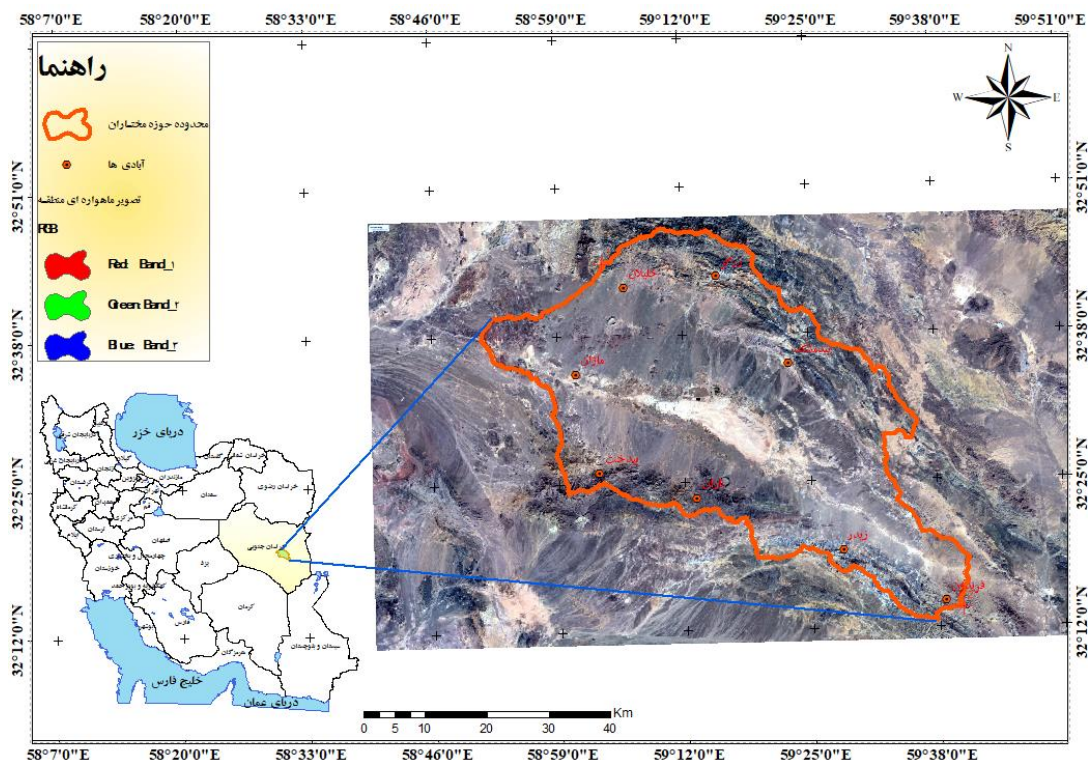
پیوسته داده‌ها و عدم لحاظ تجربیات کارشناسان، ممکن است منجر به ایجاد مدل‌هایی با قابلیت تعبیر کمتر و کاهش دقت پیش‌بینی شود. در نتیجه، ضرورت توسعه روش‌های پیچیده‌تری که بتوانند دانش تخصصی را با مدل‌های یادگیری ماشینی تلفیق نمایند، بیش از پیش احساس می‌شود. این امر به‌منظور بهبود قابلیت اطمینان و کارایی عملی ارزیابی‌های آسیب‌پذیری خاک، شکافی را در ادبیات پژوهشی ایجاد کرده است که نیازمند توجه بیشتر محققان است (هانگ<sup>۱</sup> و همکاران، ۲۰۲۳؛ گلکاریان<sup>۲</sup> و همکاران، ۲۰۲۳؛ فیزی و اسزابو<sup>۳</sup>، ۲۰۲۴).

هدف اصلی این پژوهش، پر کردن شکاف موجود در مطالعات پیشین و ارائه یک رویکرد نوین و جامع‌تر برای ارزیابی آسیب‌پذیری خاک در برابر فرسایش است. با توجه به پیچیدگی‌های فرایند فرسایش خاک و تأثیر متقابل عوامل محیطی متعدد بر آن، استفاده از مدل‌های پیشرفته آماری و یادگیری ماشینی به‌عنوان ابزاری قدرتمند برای پیش‌بینی و ارزیابی این پدیده ضروری به نظر می‌رسد. در این پژوهش، با تمرکز بر مقایسه کارایی طیف گسترده‌ای از مدل‌های پیشرفته از جمله رگرسیون خطی تعمیم‌یافته (GLM)، تقویت‌گرادیان (GBM<sup>۴</sup>)، آنالیز درخت طبقه‌بندی (CTA<sup>۵</sup>)، شبکه‌های عصبی مصنوعی (ANN)، رگرسیون اسپلاین نمونه‌برداری (SRE<sup>۶</sup>)، تحلیل عاملی تشخیصی (FDA<sup>۷</sup>)، مدل‌های پاسخ چندگانه (MARS<sup>۸</sup>)، جنگل تصادفی (RF) و حداکثر آنتروپی (MaxEnt<sup>۹</sup>)، به دنبال توسعه یک مدل پیش‌بینی دقیق‌تر و قابل اعتمادتر هستیم. در این مطالعه، به‌صورت جامع و سیستماتیک به مقایسه عملکرد این مدل‌ها در پیش‌بینی آسیب‌پذیری خاک در شرایط محیطی مختلف پرداخته شده است. با بهره‌گیری از داده‌های متنوعی شامل ویژگی‌های خاک، توپوگرافی، پوشش گیاهی، کاربری زمین و متغیرهای اقلیمی، به بررسی تأثیر متقابل این عوامل بر روی دقت مدل‌ها پرداخته می‌شود. همچنین، با

1. Huang
2. Golkarian
3. Phinzi & Szabó
4. Generalized Boosting Method
5. Classification Tree Analysis
6. Surface Range Envelope
7. Flexible Denotative Analysis
8. Multivariate Adaptive Regression Spline
9. maximum entropy model

خشک و سرد و در ارتفاعات بالاتر از ۲۱۰۰ متر، خشک و بسیار سرد است. میزان بارندگی سالانه در این منطقه بین ۱۵۰ تا ۲۲۰ میلی متر متغیر بوده و عمدتاً در مناطق مرتفع تر بیشتر است. همچنین، متوسط دمای سالانه ۱۴/۳ درجه سانتی گراد، حداقل

دمای سالانه ۵/۶ درجه سانتی گراد و حداکثر دمای سالانه ۲۲/۷ درجه سانتی گراد گزارش شده است (معماریان و مؤمنی دمنه، ۲۰۲۴).



شکل (۱): موقعیت جغرافیایی منطقه مورد مطالعه

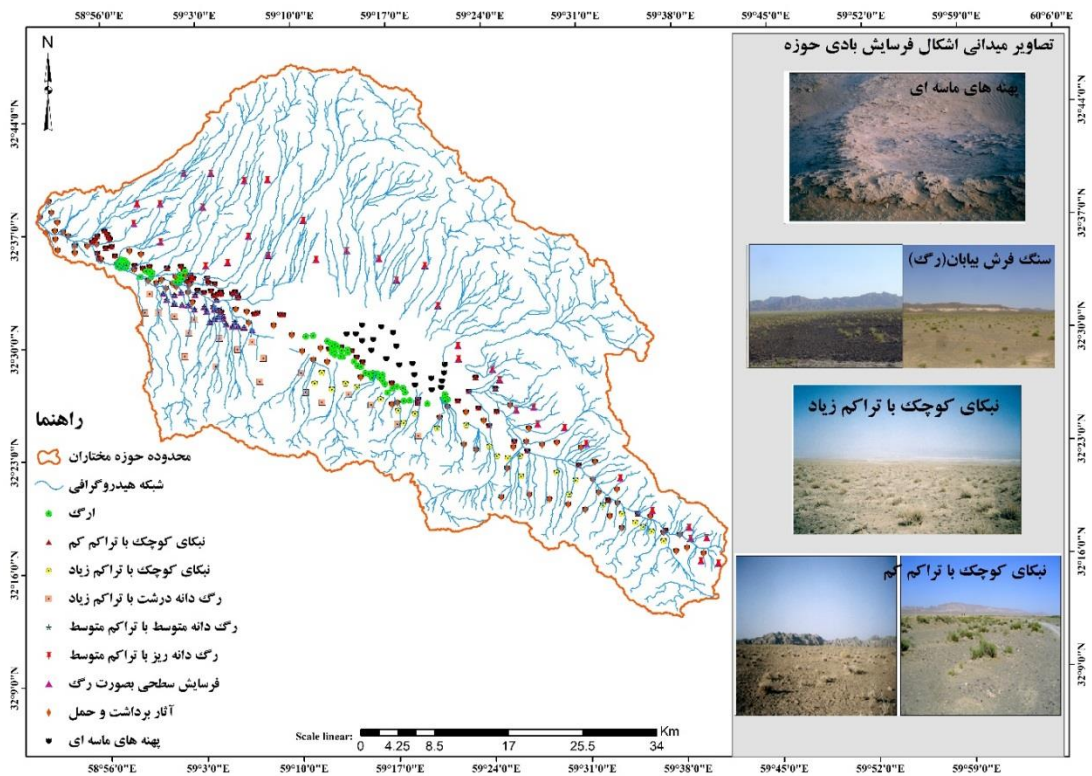
Figure (1): Geographical location of the study area

### جمع‌آوری نقاط دارای فرسایش

در پژوهش حاضر، با هدف بررسی و تحلیل گسترده فرسایش بادی در منطقه مورد مطالعه، ابتدا به جمع‌آوری داده‌های پایه پرداخته شد. این داده‌ها شامل نقشه‌های تفصیلی از شبکه آبراه‌ها، شیب زمین، ویژگی‌های زمین‌شناسی، ژئومورفولوژی، نوع خاک و کاربری اراضی بودند. این اطلاعات پایه، نقشه‌ای جامع از منطقه را فراهم آورد که در ادامه برای تعیین واحدهای کاری مورد استفاده قرار گرفت. در مرحله بعد، با بهره‌گیری از تصاویر هوایی با کیفیت بالا، اقدام به تفسیر دقیق تصاویر و شناسایی محدوده‌های تحت‌تأثیر فرسایش بادی شد. این مرحله به‌منظور تفکیک دقیق اشکال مختلف فرسایشی بر روی نقشه اولیه انجام گرفت. به‌منظور تأیید و تکمیل یافته‌های حاصل از تصاویر هوایی و مطالعات کتابخانه‌ای، بازدیدهای میدانی گسترده‌ای در منطقه انجام شد. در طول این بازدیدها، با استفاده

از دستگاه GPS، اشکال مختلف فرسایش بادی به‌دقت شناسایی و موقعیت مکانی آن‌ها ثبت گردید. براساس مشاهدات میدانی، انواع مختلفی از اشکال فرسایشی شامل رگ، نبکای کوچک با تراکم کم،<sup>۲</sup> نبکای کوچک با تراکم زیاد،<sup>۳</sup> رگ دانه‌درشت با تراکم زیاد،<sup>۴</sup> رگ دانه‌متوسط با تراکم متوسط،<sup>۵</sup> رگ دانه‌ریز با تراکم متوسط،<sup>۶</sup> فرسایش سطحی به‌صورت رگ،<sup>۷</sup> آثار برداشت برداشت و حمل<sup>۸</sup> و پهنه‌های ماسه‌ای<sup>۹</sup> شناسایی شدند. تعداد هریک از این اشکال به‌ترتیب ۷۰، ۶۳، ۲۵، ۲۰، ۲۵، ۳۶، ۸۱ و ۷۳ نقطه برداشت گردید (شکل ۲).

1. Wind Erosion-ERG
2. Wind Erosion-N1d1
3. Wind Erosion-N1d3
4. Wind Erosion-R1d3
5. Wind Erosion-R2d2
6. Wind Erosion-R3d2
7. Wind Erosion-S
8. Wind Erosion-T
9. Wind Erosion-Z



شکل (۲): موقعیت جغرافیایی پراکنش نقاط فرسایش بادی

Figure (2): Geographical location of wind erosion points

### تعیین متغیرهای محیطی

با بررسی مطالعات انجام شده و با توجه به ماهیت فرسایش بادی و منابع اطلاعاتی موجود در منطقه، ۲۵ متغیر مهم و مؤثر در فرسایش بادی شناسایی و لایه‌های اطلاعاتی آن‌ها از منابع مختلف تهیه شد (جلالی و همکاران، ۲۰۲۳). این متغیرها شامل ۵ متغیر فیزیوگرافیکی، ۲ متغیر اقلیمی، ۴ متغیر هیدرولوژیکی، ۸ متغیر خاک‌شناسی، ۴ متغیر پوشش سطحی زمین و ۲ متغیر زمین‌شناسی بودند (جدول ۱). متغیرهای فیزیوگرافیکی و ژئومورفولوژیکی از نقشه‌های توپوگرافی با مقیاس ۱:۲۵۰۰۰ سازمان نقشه‌برداری کشور استخراج شدند. داده‌های اقلیمی (بارش و تبخیر) از سازمان هواشناسی و آب منطقه‌ای تهیه شد. متغیرهای خاک‌شناسی، پوشش گیاهی و زمین‌شناسی نیز با مقیاس ۱:۵۰۰۰۰ براساس برداشت‌های میدانی و نقشه‌های مبنای ۱:۱۰۰۰۰۰ سازمان زمین‌شناسی ایران تهیه شدند. به منظور یکپارچگی داده‌ها، تمامی لایه‌های اطلاعاتی با زمین مرجع واحد، سیستم مختصات یکسان و مقیاس مشترک ۲۰×۲۰ متر آماده‌سازی شدند. این انتخاب با توجه به دقت داده‌ها، قابلیت‌های نرم‌افزار، حجم داده‌ها، مقیاس مطالعه و همبستگی

متغیرها صورت گرفت. تمام مراحل پیش‌پردازش داده‌ها در نرم‌افزار Idrisi Selva انجام شد. برای انتخاب متغیرهای مناسب در مدل‌سازی، از تحلیل آماری و شاخص ضریب تورم واریانس (VIF) استفاده شد. براساس مطالعات پیشین (مؤمنی دمنه و همکاران، ۲۰۲۳؛ a۲۰۲۲)، متغیرهایی با VIF کمتر از ۱۰ به‌عنوان متغیرهای مناسب انتخاب شدند و با فرمت Grid به‌همراه نقاط حضور اشکال غالب فرسایش بادی برای انجام مدل‌سازی در نرم‌افزار R (نسخه ۴.۲.۳) فراخوانی شدند (شکل ۴ الف و ب). همان‌طور که در مطالعات دیگر (کاتنر<sup>۱</sup> و همکاران، ۲۰۰۴؛ ساها<sup>۲</sup>، ۲۰۱۷) نیز بیان شده است، شاخص‌های VIF و Tolerance رابطه عکس دارند. این رابطه به این معناست که هرچه مقدار VIF کمتر باشد، مقدار Tolerance بیشتر خواهد بود و متغیر از همخطی کمتری برخوردار است. معادلات ۱ و ۲ (سرانی و سورلس، ۲۰۰۲؛ شیرانی و همکاران، ۲۰۱۸؛ پال<sup>۴</sup> و همکاران، ۲۰۲۰) نیز این

1. Kutner
2. Saha
3. Craney & Surles
4. Pal

- رابطه را به صورت ریاضی بیان می کنند. در این معادله،  $R^2i$  (۱)
- $$VIF = \left[ \frac{1}{Tolerance} \right]$$
- ضریب همبستگی معادله رگرسیون خطی و  $i$  تعداد کل (۲)
- $$Tolerance = 1 - Rj^2$$
- متغیرهای مستقل است.

جدول (۱): فهرست متغیرهای تأثیرگذار در فرسایش بادی

Table (1): List of influential variables in Wind erosion modeling

واحد اندازه گیری	نام کوتاه	نام متغیر	نام لاتین متغیر	دسته بندی
mm	precipitation	بارش سالانه	Annual precipitation	اقليمی
mm	Precipitation 24 hour	بارش ۲۴ ساعته	Precipitation 24 hour	
Unitless	flooding	سیل خیزی	Flooding	هیدرولوژیکی
Unitless	CN	شماره منحنی رواناب	Runoff curve number	
(Km/Km2)	densitywat	تراکم زهکشی	Drainage density	
mm	coefficient	حداکثر ظرفیت نگهداشت	Maximum storage capacity	
%	dryplant	لاشبرگ	Litter	پوشش سطحی
%	crowncover	تاج پوشش گیاهی	Canopy inlet	
%	stonespebb	سنگ و سنگ ریزه	Stones pebbles	زمین
%	bareground	خاک لخت	Bare ground	
%	Sand	ماسه	Sand	خاک شناسی
%	Silt	سیلت	Silt	
%	Clay	رس	Clay	
Dimensionless	soilhidro	گروه های هیدرولوژیکی	Hydrologic group	
Dimensionless	landsurc	اجزای واحد اراضی	Land units components	
pH * 10	pH	اسیدیته خاک	Soil pH	
dsm/m	EC	هدایت الکتریکی خاک	Soil EC	
%	T.N. V	درصد مواد خشتی شونده	T.N.V	
Dimensionless		زمین شناسی	Geology	زمین شناسی
Dimensionless	permeabili	نفوذپذیری سازندهای زمین شناسی	Permeability	
m	DEM	مدل رقمی ارتفاع	DEM	فیزیوگرافی
Dimensionless	TWI	شاخص رطوبت توپوگرافی	Topographic wetness index	
Dimensionless	SPI	شاخص قدرت جریان	Stream power index	
Dimensionless	aspect	جهت	Aspect	
%	Slope	شیب	Slope	

### مدل سازی فرسایش بادی

### ارزیابی مدل

در پژوهش حاضر، برای مدل سازی فرسایش بادی از ده الگوریتم موجود در بسته نرم افزاری بایومد<sup>۱</sup> (تیلر<sup>۲</sup> و همکاران، ۲۰۰۹) و همچنین به منظور تولید نقاط عدم حضور نیز از همین بسته نرم افزاری استفاده شد (جدول ۲). در روند مدل سازی از ۷۰ درصد نقاط موقعیت فرسایش غالب منطقه برای تولید مدل ها و از ۳۰ درصد نقاط حضور به منظور ارزیابی عملکرد مدل ها استفاده شد. همچنین برای افزایش دقت مدل سازی، تعداد تکرار ۵ در نظر گرفته شد.

3. receiver operating characteristic  
4. Fielding and Bell

1. BIOMOD 2\_3.3-7.1  
2. Thuiller

جدول (۲): فهرست مدل‌های استفاده شده برای مدل‌سازی فرسایش

بادی

Table (2): The list of models employed to Wind erosion modeling

نام	نام لاتین	نام فارسی
GLM	Generalized Liner Model	مدل تعمیم یافته خطی
GBM	Generalized Boosting Method	مدل تقویت شده تعمیم یافته
CTA	Classification Tree Analysis	آنالیز درخت طبقه بندی
ANN	Artificial Neural Network	شبکه عصبی مصنوعی
SRE	Surface Range Envelope	پاکت دامنه سطحی
FDA	Flexible Denotative Analysis	آنالیز تفکیکی انعطاف پذیر
MARS	Multivariate Adaptive Regression Spline	مدل رگرسیون سازشی چندمتغیره
RF	Random Forest	جنگل تصادفی
ESMs	Techniques and their ensembles	مدل‌های اجماعی
MaxEnt	maximum entropy model	حداکثر آنتروپی

## نتایج

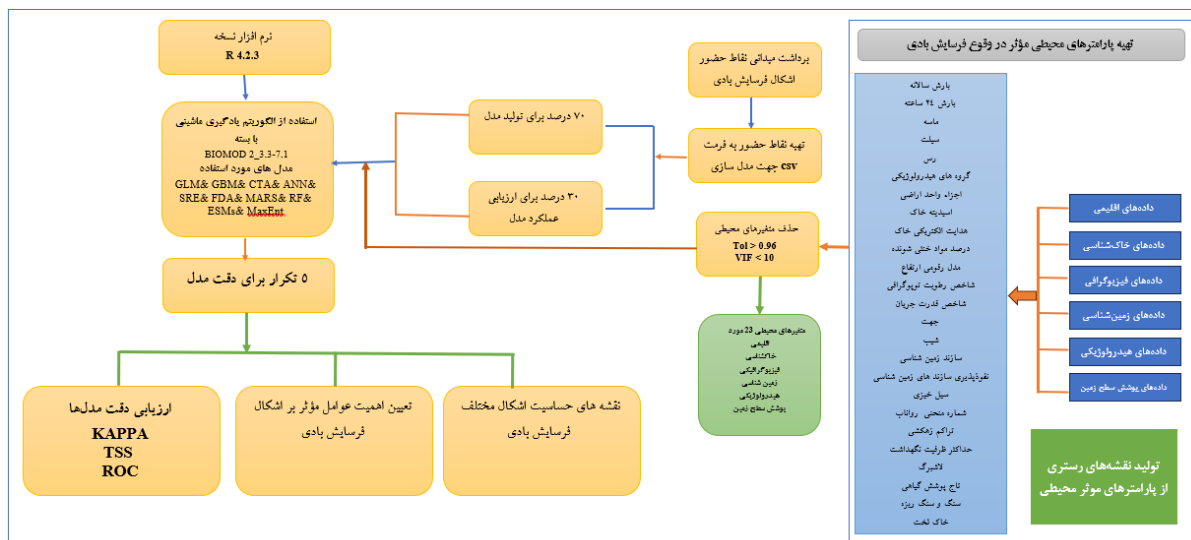
به منظور بررسی مشکل همخطی چندگانه در مدل پیش‌بینی، شاخص تورم واریانس (VIF) برای تمامی متغیرهای محیطی محاسبه شد. نتایج این آزمون که در جدول (۳) ارائه شده است، نشان می‌دهد که از میان ۲۵ متغیر محیطی، فقط ۲ متغیر دارای مقدار VIF بالاتر از ۱۰ بوده و از این رو، همبستگی چندگانه قابل توجهی با سایر متغیرها ندارند. این دو متغیر از مدل نهایی حذف شدند (شکل ۴).

روش دوم، محاسبه میزان  $TSS^1$  برای مدل‌های حضور-عدم حضور طراحی شده و نشان‌دهنده توانایی مدل در تشخیص صحیح هر دو حالت حضور و عدم حضور فرسایش است (مؤمنی دمنه و همکاران، ۲۰۲۳a). مطالعات نشان داده‌اند که ROC و TSS همبستگی بالایی دارند و TSS می‌تواند جایگزین مناسبی برای ROC در مطالعات حضور-عدم حضور باشد (والتر<sup>۲</sup> و همکاران، ۲۰۰۲؛ معاریان و مؤمنی دمنه، ۲۰۲۴).

روش سوم کاپای کوهن<sup>۳</sup> است که میزان توافق بین مدل و داده‌های واقعی را نشان می‌دهد و در واقع میزان اتفاق نظر بین دو ارزیاب (در اینجا مدل و داده‌ها) را در طبقه‌بندی موارد بررسی می‌کند (اسمتون،<sup>۴</sup> ۱۹۸۵؛ گاتن،<sup>۵</sup> ۱۹۸۲).

ROC، Kappa و TSS کمتر از ۰/۵ نشان‌دهنده عملکرد مدل‌سازی نامناسب، بین ۰/۵-۰/۶ عملکرد خیلی ضعیف، بین ۰/۶-۰/۷ عملکرد ضعیف، بین ۰/۷-۰/۸ عملکرد متوسط، بین ۰/۸-۰/۹ عملکرد خوب و ۰/۹-۱ نشانگر عملکرد بالا (مطلوب) در مدل‌سازی است (اسویتس،<sup>۶</sup> ۱۹۸۸؛ یای<sup>۷</sup> و همکاران، ۲۰۱۶؛ مؤمنی دمنه و همکاران، ۲۰۲۳b). در ادامه برای دستیابی به یک نگرش جغرافیایی از مناطقی که دارای شرایط اقلیمی و محیطی مناسب برای اشکال فرسایشی مورد مطالعه‌اند، نقشه‌های حضور مطلوب به صورت گسسته و پیوسته به تصویر کشیده شده است (شکل ۷). نقشه حضور مطلوب به دست آمده به وسیله مدل‌های مطلوبیت زیستگاه از ۰ تا ۱۰۰۰ بیان می‌شوند. صفر برای کمترین احتمال و ۱۰۰۰ برای بیشترین احتمال است. برای درک بهتر پراکنش، نقشه در نرم‌افزار Arc GIS 10.5 به چهار طبقه شامل عرصه نامطلوب بین ۰ تا ۲۵۰، عرصه با مطلوبیت کم بین ۲۵۰ تا ۵۰۰، عرصه با مطلوبیت متوسط بین ۵۰۰ تا ۷۵۰ و عرصه مطلوب بین ۷۵۰ تا ۱۰۰۰ تقسیم‌بندی شد (مؤمنی دمنه و همکاران، ۲۰۲۲) (جدول ۴).

1. True Skill Statistic
2. Walther
3. Cohens Kappa
4. Smeeton
5. Galton
6. Swets
7. Yi

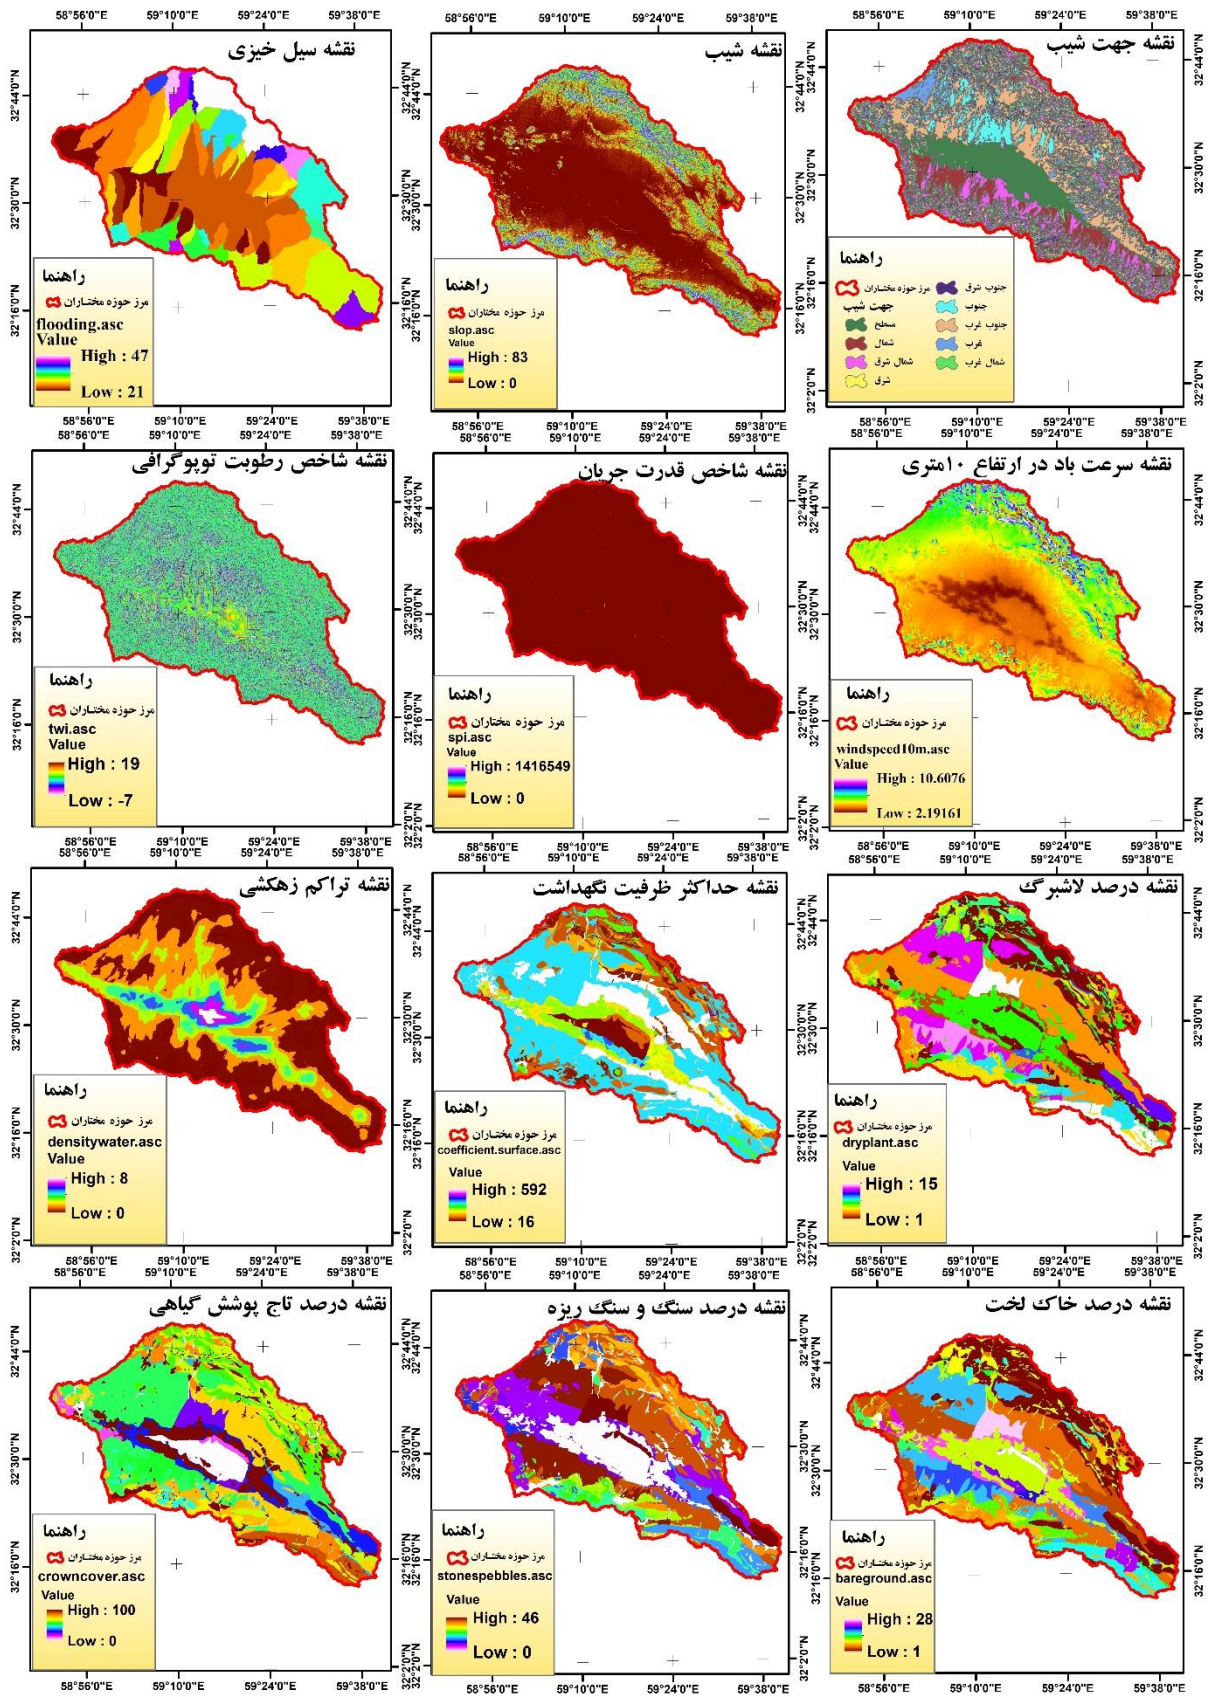


شکل (۳): فرایند انجام مدل سازی  
Figure (3): The process of modeling

جدول (۳): تجزیه و تحلیل چندخطی برای ارزیابی خطی بودن متغیرهای مستقل  
Table (3): Multilinear analysis to assess the linearity of independent variables

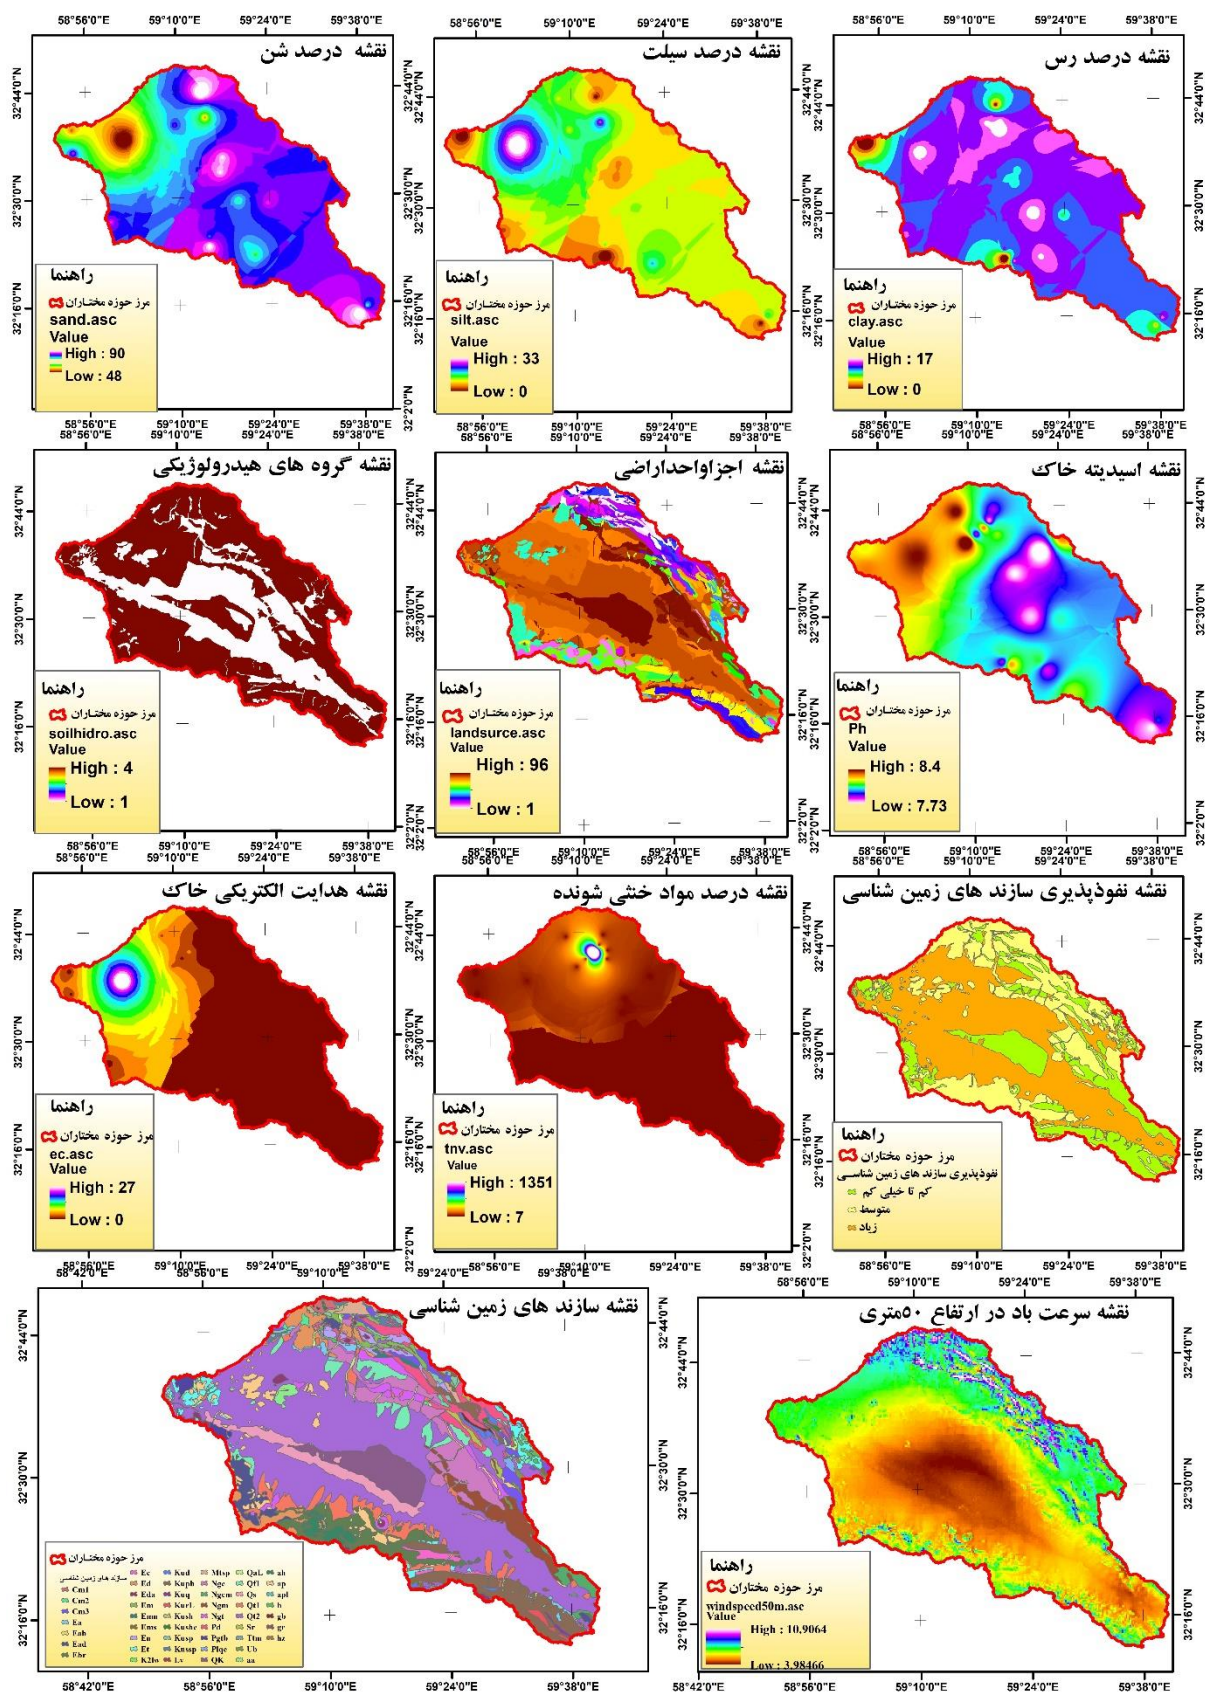
شاخص	نام کوتاه	VIF	Tolerance
شاخص قدرت جریان	spi	۱/۰۴	۰/۹۶
شاخص رطوبت توپوگرافی	twi	۱/۰۵	۰/۹۵
جهت	aspect	۱/۱۷	۰/۸۵
درصد مواد خنثی شونده	tnv	۱/۲۰	۰/۸۳
سنگ و سنگ ریزه	stonespebbles	۱/۷۲	۰/۵۸
تاج پوشش گیاهی	crowncover	۱/۷۳	۰/۵۸
اسیدیته خاک	ph	۱/۹۲	۰/۵۲
تراکم زهکشی	densitywater	۲/۰۷	۰/۴۸
خاک لخت	bareground	۲/۱۳	۰/۴۷
رس	clay	۲/۱۵	۰/۴۷
شیب	slop	۲/۱۸	۰/۴۶
لاشبرگ	dryplant	۲/۱۸	۰/۴۶
حداکثر ظرفیت نگهداشت	coefficient.surface	۲/۳۱	۰/۴۳
گروه های هیدرولوژیکی	soilhidro	۲/۳۳	۰/۴۳
نفوذپذیری سازندهای زمین شناسی	permeability	۲/۳۸	۰/۴۲
زمین شناسی	geology	۲/۷۲	۰/۳۷
سیل خیزی	flooding	۲/۷۹	۰/۳۶
اجزای واحد اراضی	landsurce	۳/۴۴	۰/۲۹
سرعت باد در ارتفاع ۱۰متری	windspeed10m	۷/۱۶	۰/۱۴
هدایت الکتریکی خاک	ec	۷/۲۷	۰/۱۴
شن	sand	۸/۰۱	۰/۱۲
سیلت	silt	۸/۵۳	۰/۱۲
سرعت باد در ارتفاع ۵۰متری	windspeed50m	۹/۱۶	۰/۱۱





شکل (۴ الف): متغیرهای تأثیرگذار در مدل‌سازی اشکال فرسایش بادی




Figure 4(a): Variables selected for wind erosion modeling



شکل (۴ ب): متغیرهای تأثیرگذار در مدل سازی اشکال فرسایش بادی

Figure 4(b): Variables selected for wind erosion modeling

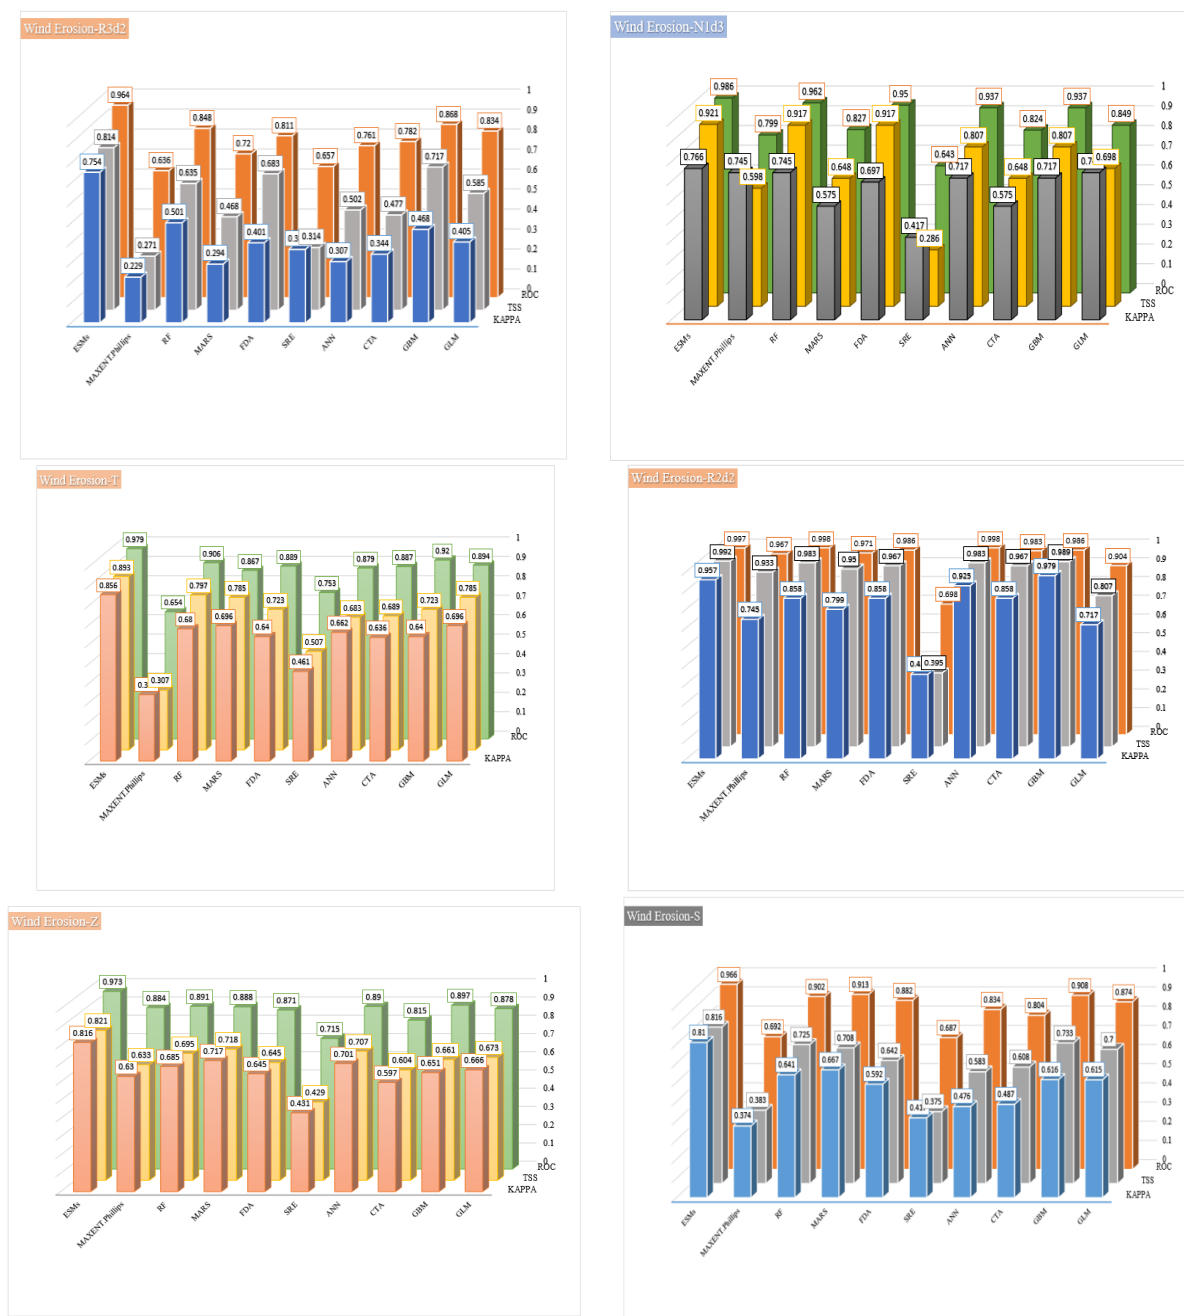
بهینه منابع را تسهیل کرده و با اهداف توسعه پایدار همسو است. کاهش تأثیر فرسایش خاک بر اکوسیستم‌ها و معیشت انسان‌ها، از جمله دستاوردهای این رویکرد است (البامری<sup>۴</sup> و همکاران، ۲۰۱۸؛ رحمتی و همکاران، ۲۰۱۷). براساس نتایج حاصل، مدل اجماعی به‌عنوان مناسب‌ترین مدل برای تحلیل‌های بعدی انتخاب شد (شکل ۵).



## ارزیابی مدل‌های استفاده‌شده

یافته‌های ارزیابی حساسیت به فرسایش خاک نشان می‌دهد که ترکیب مدل‌های یادگیری ماشین با داده‌های جغرافیایی، تأثیر قابل توجهی بر روش‌های مدیریت زمین دارد. نتایج مدل‌سازی حساسیت به فرسایش خاک که در شکل (۵) ارائه شده، حاکی از دقت بسیار بالای مدل اجماعی (ESMs) در شناسایی مناطق مستعد فرسایش است. این مدل با کسب بالاترین امتیاز TSS به‌ترتیب ۰/۸۱۴، ۰/۹۹۲، ۰/۹۸۴، ۰/۹۲۱، ۰/۹۶۸، ۰/۹۸۲، ۰/۸۱۶، ۰/۸۹۳، ۰/۸۱۶ کوچک با تراکم کم، نیکای کوچک با تراکم زیاد، رگ دانه‌درشت با تراکم زیاد، رگ دانه‌متوسط با تراکم متوسط، رگ دانه‌ریز با تراکم متوسط، فرسایش سطحی به‌صورت رگ، آثار برداشت و حمل و پهنه‌های ماسه‌ای (شکل ۵)، برتری خود را نسبت به سایر مدل‌ها نشان داده است. این مدل با ترکیب چندین الگوریتم یادگیری ماشین، قدرت تعمیم‌پذیری بالایی دارد و می‌تواند در شرایط مختلف محیطی به کار گرفته شود (معماریان و مؤمنی دمنه، ۲۰۲۴). دقت بالای این مدل در شناسایی مناطق با حساسیت بالای فرسایش بادی، امکان اجرای مداخلات هدفمندتری را فراهم می‌آورد. این مداخلات شامل جنگل‌کاری در کانون‌های بحران، ایجاد تله‌های رسوب‌گیر و بادشکن‌های زنده و غیرزنده در اطراف مزارع، مناطق مسکونی و صنعتی و همچنین مالچ‌پاشی است. این اقدامات نه تنها به جلوگیری از فرسایش خاک کمک شایانی می‌کند بلکه به افزایش بهره‌وری زمین نیز منجر می‌شود. یافته‌های این پژوهش با مطالعات پیشین (موسوی و همکاران، ۲۰۲۰) همسو بوده و بر اهمیت اقدامات هدفمند حفاظت از خاک در افزایش عملکرد کشاورزی و کاهش تخریب محیط‌زیست تأکید دارد. همچنین، این مطالعه مزایای عملی استفاده از مدل‌های یادگیری ماشین در ارزیابی‌های حساسیت به فرسایش خاک را برجسته می‌سازد (قربان‌زاده و همکاران، ۲۰۲۰؛ ونگ<sup>۱</sup> و همکاران، ۲۰۲۳؛ فولارینی<sup>۲</sup> و همکاران، ۲۰۲۳؛ نگوین<sup>۳</sup> و همکاران، ۲۰۲۳). کاربرد این پیش‌بینی‌های مبتنی بر داده در مدیریت زمین، تخصیص

1. Wang
2. Folharini
3. Nguyen




شکل (۵): ارزیابی صحت در مدل‌سازی مکان‌های مستعد فرسایش بادی

Figure (5): Assessment of accuracy in the modeling of wind erosion prone areas

سطحی خاک و خاک‌شناسی نقش بسیار مهمی در پراکنش جغرافیایی انواع فرسایش بادی در حوزه آبخیز مختاران دارند (شکل ۶). این ارزیابی‌ها نشان می‌دهند که می‌توان با استفاده از این مدل، پتانسیل فرسایش خاک را در مناطقی که حساسیت آن‌ها به فرسایش به‌طور مستقیم مشخص نیست، پیش‌بینی کرد. با این روش، می‌توان مناطق مستعد فرسایش را شناسایی و اقدامات پیشگیرانه مناسب را در اولویت قرار داد.

آنالیز حساسیت متغیرهای محیطی در مدل‌سازی پراکنش مناطق مستعد فرسایش بادی نشان داد که مهم‌ترین عوامل محیطی شامل تراکم زهکشی، گروه‌های هیدرولوژیکی، فراوانی سنگ و سنگ‌ریزه، درصد خاک لخت، شیب، دمای متوسط هوا و پوشش گیاهی هستند. این عوامل بیشترین تأثیر را در توزیع جغرافیایی انواع فرسایش بادی با شدت‌های متفاوت داشته‌اند (شکل ۶). بررسی اهمیت نسبی تمام عوامل محیطی در منطقه مورد مطالعه نشان داد که عوامل فیزیوگرافی، پوشش



شکل (۶): درصد اهمیت نسبی پارامترهای محیطی اثرگذار در شدت انواع فرسایش بادی

Figure (6): Percentage of relative importance of environmental parameters affecting the intensity of wind erosion types

روزافزون گردوغبار در منطقه مختاران که به یکی از معضلات اجتماعی آن تبدیل شده است، یافته‌های این پژوهش می‌تواند در تدوین راهبردهای مدیریت فرسایش بادی در سطح محلی بسیار مفید باشد.

نتایج حاصل از اجرای مدل جامع ESMS، که برای ارزیابی حساسیت به انواع فرسایش بادی طراحی شده بود، با دقت بسیار بالایی به دست آمد. مطابق جدول (۴)، این مدل توانست مساحت و درصد مساحت هریک از طبقات فرسایش بادی در حوزه مختاران را با دقت مشخص کند. با توجه به افزایش

جدول (۴): مساحت و درصد مساحت طبقات اشکال مختلف فرسایش بادی

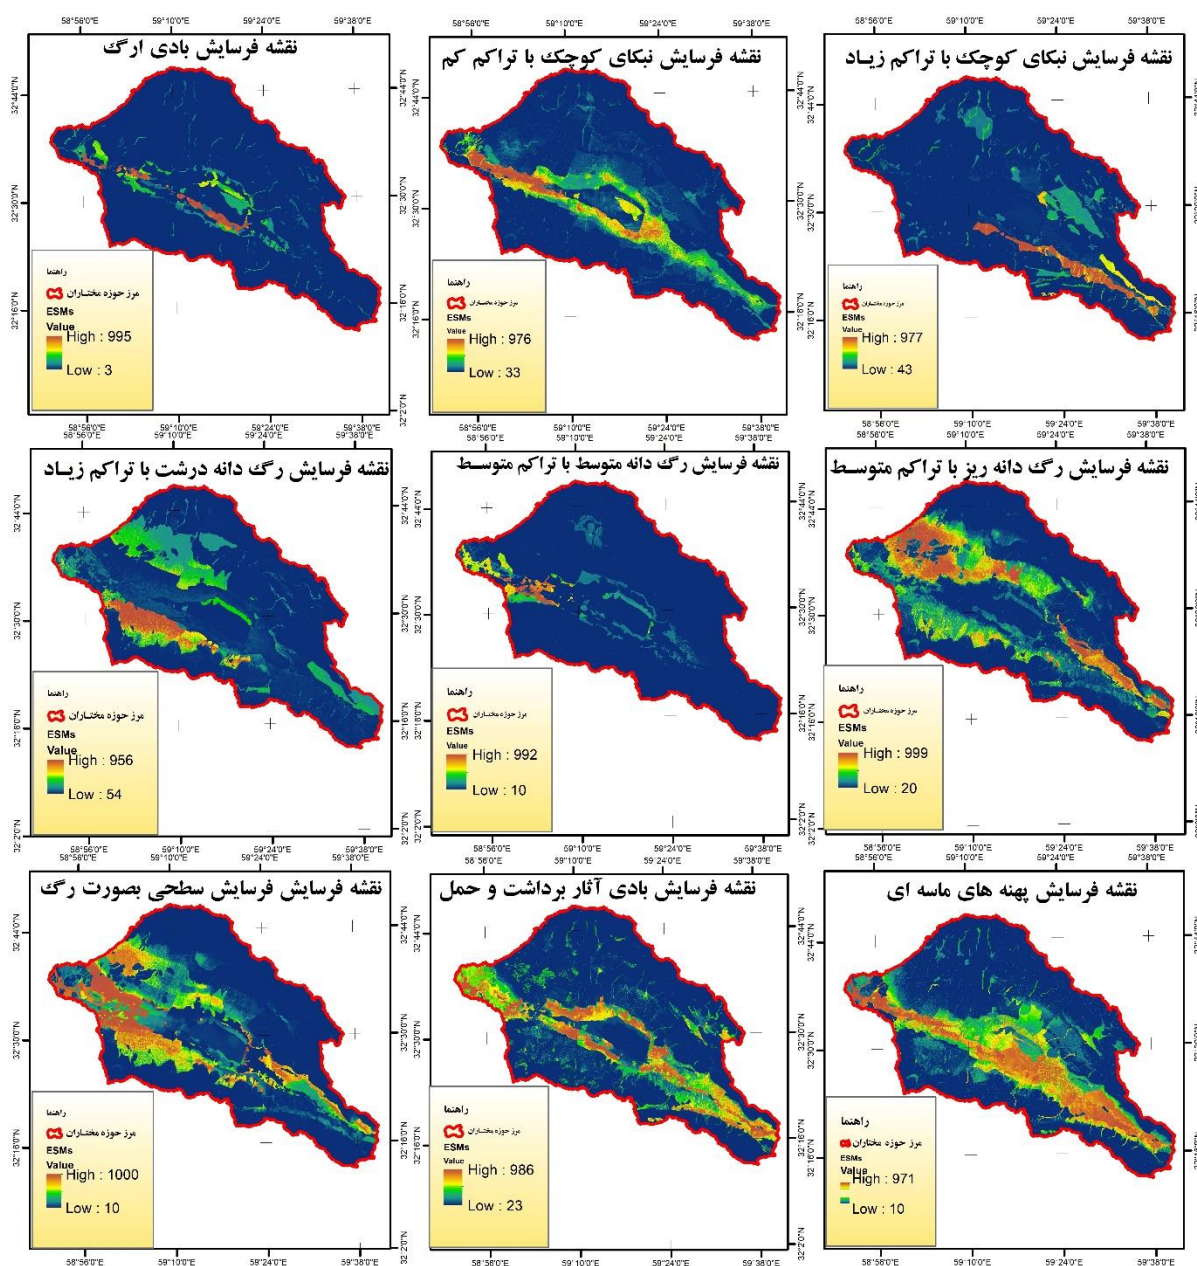
Table (4): Area and percentage of area of different types of wind erosion classes

طبقات شدت فرسایش	فرسایش ارگ		فرسایش نیکای کوچک با تراکم کم		فرسایش نیکای کوچک با تراکم زیاد	
	مساحت (km <sup>2</sup> )	مساحت (%)	مساحت (km <sup>2</sup> )	مساحت (%)	مساحت (km <sup>2</sup> )	مساحت (%)
کم	۲۲۸۰/۶۱	۹۴/۴۳	۲۰۸۰/۳۵	۸۶/۱۴	۲۲۴۵/۲۱	۹۲/۹۶
متوسط	۷۶/۵۴	۳/۱۷	۱۴۴/۹۵	۶/۰۰	۶۰/۲۱	۲/۴۹
زیاد	۱۸/۲۵	۰/۷۶	۱۰۴/۴۰	۴/۳۲	۳۵/۴۶	۱/۴۷
خیلی زیاد	۳۹/۷۵	۱/۶۵	۸۵/۴۴	۳/۵۴	۷۴/۲۵	۳/۰۷
طبقات شدت فرسایش	فرسایش رگ دانه درشت با تراکم زیاد		فرسایش رگ دانه متوسط با تراکم متوسط		فرسایش رگ دانه ریز با تراکم متوسط	
	مساحت (km <sup>2</sup> )	مساحت (%)	مساحت (km <sup>2</sup> )	مساحت (%)	مساحت (km <sup>2</sup> )	مساحت (%)
کم	۲۰۹۱/۵۶	۸۶/۶۰	۲۳۳۱/۲۰	۹۶/۵۲	۱۸۱۵/۹۳	۷۵/۱۹
متوسط	۱۸۱/۸۷	۷/۵۳	۲۱/۴۹	۰/۸۹	۲۰۶/۲۰	۸/۵۴
زیاد	۵۱/۳۵	۲/۱۳	۳۴/۴۲	۱/۴۳	۱۴۰/۴۸	۵/۸۵
خیلی زیاد	۹۰/۳۶	۳/۷۴	۲۸/۰۳	۱/۱۶	۲۵۲/۵۲	۱۰/۴۶
طبقات شدت فرسایش	فرسایش سطحی به صورت رگ		آثار برداشت و حمل		پهنه‌های ماسه‌ای	
	مساحت (km <sup>2</sup> )	مساحت (%)	مساحت (km <sup>2</sup> )	مساحت (%)	مساحت (km <sup>2</sup> )	مساحت (%)
کم	۱۸۲۱/۰۳	۷۵/۴۰	۱۸۵۱/۷۴	۷۶/۶۷	۱۷۴۱/۱۰	۷۲/۰۹
متوسط	۱۸۷/۲۶	۷/۷۵	۲۱۳/۸۴	۸/۸۵	۲۱۴/۹۲	۸/۹۰
زیاد	۱۴۰/۶۸	۵/۸۳	۱۴۲/۷۹	۵/۹۱	۱۶۹/۵۳	۷/۰۲
خیلی زیاد	۲۶۶/۱۶	۱۱/۰۲	۲۰۶/۷۵	۸/۵۶	۲۸۹/۵۹	۱۱/۹۹

نقشه‌های فرسایش بادی

شرقی بیشتر است. انواع رگ نیز عمدتاً در نواحی شمال غربی و جنوب شرقی، به‌ویژه در اطراف نیکاه‌ها، با شدت بیشتری دیده می‌شوند. در برخی مناطق، رخساره‌های بادی نیکا و رگ به‌طور هم‌زمان مشاهده می‌شوند. فرسایش سطحی رگ بیشتر در قسمت‌های شمال غربی و غربی حوزه رخ می‌دهد، درحالی‌که نیمه شرقی حوزه فرسایش کمتری را تجربه می‌کند. همچنین، پهنه‌های ماسه‌ای عمدتاً از مرکز حوزه به سمت جنوب، جنوب غربی و شرق گسترش یافته‌اند.

شکل (۷) نقشه‌های تفکیکی انواع فرسایش بادی در حوزه مختاران را نشان می‌دهد. این نقشه‌ها با استفاده از مدل‌های انتخاب‌شده اجماعی (ESMs) که بیشترین دقت را در ارزیابی دارند، تهیه شده‌اند. براساس این نقشه‌ها، انواع نیکا و ارگ عمدتاً در نوار مرکزی شمال غربی تا جنوب شرقی حوزه پراکنده شده‌اند. شدت فرسایش بادی از نیکاه‌های کوچک در مرکز به سمت جنوب شرقی به تدریج افزایش می‌یابد. درعین حال، تراکم نیکاه‌ها در پهنه‌های شمال غربی تا جنوب

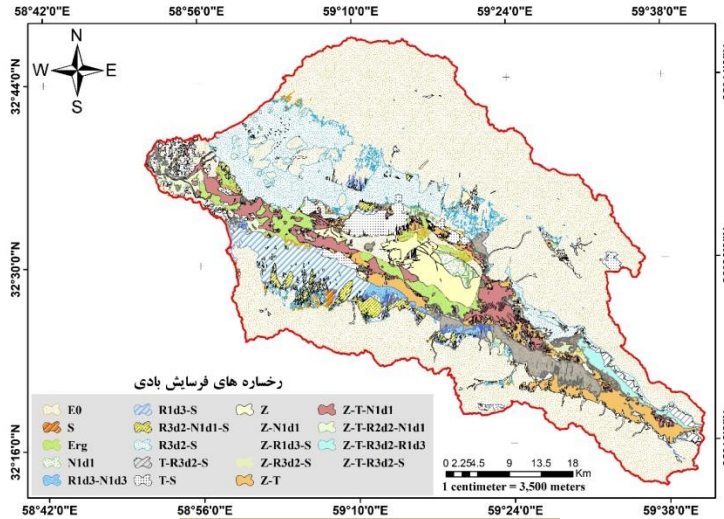


شکل (۷): نقشه‌های حساسیت زمین‌ها به انواع اشکال فرسایش بادی

Figure (7): Maps of land sensitivity to various forms of wind erosion

شدند. با توجه به اهمیت تهیه نقشه کامل از اشکال مختلف فرسایش بادی در هر حوزه آبخیز، به‌منظور برنامه‌ریزی و مدیریت پایدار و مؤثر برای کنترل فرسایش، نقشه نهایی تهیه و در شکل (۸) نمایش داده شده است.

پس از مدل‌سازی و ارزیابی مدل‌های مورد استفاده، به‌منظور تهیه نقشه نهایی و جامع از انواع فرسایش بادی، نقشه‌های حاصل از مدل‌های تجمیعی فرسایش بادی (ESMs) که عملکرد بهتری از خود نشان دادند، با یکدیگر ترکیب



شکل (۸): نقشه ترکیبی اشکال فرسایش بادی

Figure (8): Composite map of wind erosion forms

فرسایش بادی، مستعد فرسایش بادی بوده و پتانسیل بالایی برای وقوع این پدیده را دارد (شکل ۸). این پتانسیل در رخساره‌های تلفیقی به‌طور قابل توجهی بیشتر از رخساره‌های منفرد فرسایش بادی است.

جدول (۵)، مساحت، شیب متوسط و ارتفاع هر واحد طبقه‌بندی را براساس نقشه ترکیبی حاصل از تلفیق عوامل مختلف نشان می‌دهد. بیشترین مساحت (۵۴/۸۴٪) به طبقه‌ای تعلق دارد که کمترین پتانسیل فرسایش بادی را داراست. به‌طور کلی، ۴۴/۱۶ درصد از کل منطقه، به‌ویژه در رخساره‌های ترکیبی

جدول (۵): مساحت و درصد فراوانی وقوع طبقات ترکیبی اشکال فرسایش بادی منطقه

Table (5): Area and percentage of occurrence of combined classes of wind erosion forms in the region

نام اختصاری رخساره فرسایشی	مساحت (km <sup>2</sup> )	مساحت (%)	ارتفاع حداقل (M)	ارتفاع حداکثر (M)	ارتفاع متوسط (M)	شیب (%)
E0	۱۳۷۲/۶۱	۵۶/۸۴	۱۲۶۹	۲۶۹۰	۱۸۷۵	۱۱/۳۱
Erg	۶۷/۶۴	۲/۸۰	۱۲۸۲	۱۶۱۰	۱۴۶۱	۰/۴۸
N1d1	۱۴/۳۳	۰/۵۹	۱۳۵۵	۱۵۳۲	۱۴۷۹	۰/۱۴
R1d3-N1d3	۱۳/۹۰	۰/۵۸	۱۴۹۶	۲۴۲۵	۱۵۵۶	۱/۵۲
R1d3-S	۹۴/۵۶	۳/۹۲	۱۲۸۸	۱۷۳۷	۱۵۲۰	۱/۱۸
R3d2-N1d1-S	۳۷/۰۰	۱/۵۳	۱۴۰۹	۱۷۶۲	۱۵۷۶	۱/۵۸
R3d2-S	۲۷۸/۰۱	۱۱/۵۱	۱۴۱۵	۱۸۳۵	۱۵۷۵	۱/۴۴
S	۱۵/۶۴	۰/۶۵	۱۳۶۰	۱۸۳۱	۱۶۰۸	۲/۲۸
T-R3d2-S	۱۸/۴۹	۰/۷۷	۱۳۰۹	۱۸۰۱	۱۷۰۰	۲/۰۶
T-S	۹۸/۸۴	۴/۰۹	۱۲۶۰	۲۱۰۸	۱۵۱۲	۱/۵۷
Z	۸۴/۳۰	۳/۴۹	۱۳۴۶	۱۸۶۷	۱۵۱۲	۰/۶۱
Z-N1d1	۱۵/۳۸	۰/۶۴	۱۳۳۰	۱۶۹۹	۱۴۸۷	۰/۵۵
Z-R1d3-S	۵۳/۵۴	۲/۲۲	۱۴۸۳	۱۷۹۹	۱۵۸۰	۱/۲۱
Z-R3d2-S	۱۷/۶۴	۰/۷۳	۱۳۰۱	۱۷۴۲	۱۵۷۴	۱/۲۵
Z-T	۹۷/۳۴	۴/۰۳	۱۲۶۰	۱۸۹۲	۱۵۹۳	۱/۰۶
Z-T-N1d1	۸۷/۸۲	۳/۶۴	۱۲۶۱	۱۷۱۶	۱۴۷۰	۰/۴۰
Z-T-R2d2-N1d1	۱۷/۶۰	۰/۷۳	۱۲۶۰	۱۴۸۱	۱۳۵۴	۱/۳۷
Z-T-R3d2-R1d3	۱۵/۷۸	۰/۶۵	۱۵۱۷	۱۷۶۱	۱۶۷۱	۱/۹۱
Z-T-R3d2-S	۱۴/۳۹	۰/۶۰	۱۲۶۰	۱۷۵۳	۱۵۲۷	۱/۱۷

## بحث و نتیجه گیری

حوزه آبخیز مورد مطالعه با چالش جدی تخریب اراضی به واسطه انواع فرسایش بادی مواجه است. این مسئله نه تنها بر اقتصاد منطقه تأثیرگذار بوده، بلکه اکوسیستم طبیعی را نیز تحت فشار قرار داده است. به منظور شناسایی دقیق مناطق مستعد فرسایش و اتخاذ راهکارهای مدیریتی مناسب، از روش‌های یادگیری ماشین و پارتیشن‌بندی تصادفی نمونه‌ها استفاده شد. هدف اصلی این پژوهش، تعیین مدل بهینه برای پیش‌بینی حساسیت به انواع فرسایش و ارائه چارچوبی مفهومی برای آماده‌سازی و تقسیم‌بندی داده‌ها برای دستیابی به بالاترین دقت پیش‌بینی بود. با توجه به وسعت منطقه و محدودیت‌های اندازه‌گیری مستقیم فرسایش، مدل‌سازی، به‌ویژه با استفاده از هوش مصنوعی، به دلیل دقت بالا، سادگی و نیاز کم به داده، به‌عنوان روشی مناسب انتخاب شد. در این مطالعه، ۱۰ مجموعه داده آموزشی برای مدل‌سازی فرسایش بادی ایجاد شد. انتخاب دقیق متغیرهای ورودی به‌عنوان یکی از مراحل کلیدی در مدل‌سازی، نقش بسزایی در دقت نتایج دارد. مطالعات پیشین نشان داده‌اند که تعداد و نوع متغیرهای ورودی در مدل‌های فرسایش لزوماً ثابت نیست و به دیدگاه محقق و اهداف پژوهش بستگی دارد (جلالی و همکاران، ۲۰۲۳؛ معماریان و مؤمنی دمنه، ۲۰۲۴ و ۲۰۲۵). با این حال، برخی متغیرها مانند NDVI و شیب زمین به‌طور معمول در این مدل‌ها مورد استفاده قرار می‌گیرند (کان<sup>۱</sup> و همکاران، ۲۰۱۹؛ شهری<sup>۲</sup> و همکاران، ۲۰۱۹؛ گوس پنافیل و هرناندز روخاس، ۲۰۲۱<sup>۳</sup>؛ جلالی و همکاران، ۲۰۲۳). نقشه‌های تولیدشده براساس چهار کلاس حساسیت به فرسایش (کم، متوسط، شدید و خیلی شدید) طبقه‌بندی شدند (جدول ۴، شکل ۷). برای ارزیابی پایداری مدل‌های تولیدشده، از ۱۰ مجموعه داده متفاوت استفاده شد و شاخص‌های کاپا، حساسیت و ویژگی (TSS) و منحنی مشخصه عملیاتی گیرنده (ROC) به کار گرفته شد. نتایج ارزیابی نشان داد که مدل تجمیعی (ESMs) در مقایسه با سایر مدل‌ها، عملکرد بهتری در پیش‌بینی همه انواع فرسایش داشته و

براساس شاخص‌های ارزیابی، در سطح بسیار عالی قرار گرفته است (شکل ۵). نتایج این پژوهش حاکی از آن است که تلفیق روش‌های سنجش از دور، سیستم اطلاعات جغرافیایی و مدل‌های یادگیری ماشین (مانند مدل‌های تجمیعی) ابزاری قدرتمند برای ارزیابی حساسیت مناطق به فرسایش بادی است. یافته‌های این مطالعه با مطالعات پیشین که از مدل‌های ماشین بردار پشتیبان برای تهیه نقشه‌های حساسیت به فرسایش استفاده کرده‌اند، همخوانی دارد. با توجه به توانایی بالای روش‌های یادگیری ماشین در درک الگوهای پیچیده در داده‌های محیطی، انتظار می‌رود که این روش‌ها در آینده نقش مهمی در مدیریت مخاطرات طبیعی ایفا کنند. نتایج این پژوهش نشان می‌دهد که عوامل فیزیوگرافیک و پوشش گیاهی نقش کلیدی در کنترل فرسایش بادی در حوزه آبخیز مختاران دارند. این یافته‌ها می‌تواند در تدوین برنامه‌های مدیریت پایدار خاک و آب در این منطقه و سایر مناطق مشابه مورد استفاده قرار گیرد. همچنین، ضرورت اجرای اقدامات آبخیزداری در مناطق مستعد فرسایش مجاور شبکه زهکشی، به‌ویژه در شرایط اقلیمی خشک و نیمه‌خشک، مورد تأکید است. با وجود پیشرفت‌های روش‌های مدل‌سازی، این مطالعه با چندین محدودیت مواجه است که می‌تواند بر دقت و تعمیم‌پذیری نتایج تأثیر بگذارد. یکی از محدودیت‌های مهم، وابستگی به کیفیت و وضوح داده‌های ورودی است که می‌تواند مستقیماً بر دقت خروجی‌های مدل تأثیر بگذارد (اولی و همکاران، ۲۰۲۱). برای مثال، توانایی مدل‌ها در طبقه‌بندی دقیق مناطق به کلاس‌های مختلف فرسایش بادی، به شدت به کیفیت و دقت داده‌های جغرافیایی وابسته است. تعمیم‌پذیری این یافته‌ها همچنین ممکن است با ویژگی‌های خاص محیطی و جغرافیایی منطقه مورد مطالعه محدود شود و اعمال نتایج را در مناطق با اقلیم، نوع خاک و الگوهای کاربری زمین متفاوت چالش برانگیز کند (سنانایک<sup>۴</sup> و همکاران، ۲۰۲۰). این محدودیت‌ها اهمیت تفسیر دقیق نتایج و اعتبارسنجی مدل‌ها با مجموعه داده‌های مستقل را برای اطمینان از قابلیت اطمینان آن‌ها برجسته می‌کند (کنوستی<sup>۵</sup> و همکاران، ۲۰۱۴). پژوهش‌های آینده باید بر رفع این

1. Can
2. Shahri
3. Goes-Penafiel & Hernandez-Rojas

4. Senanayake
5. Conoscenti



### سیاسگزاری

بدین وسیله از اداره کل منابع طبیعی و آبخیزداری خراسان جنوبی به سبب در اختیار قرار دادن داده‌های لازم برای انجام این پژوهش سپاسگزاری می‌شود.

محدودیت‌ها با بررسی راه‌های جدید برای افزایش دقت و قابلیت کاربرد مدل‌های حساسیت فرسایش خاک متمرکز شوند. برای مثال، استفاده از داده‌های فضایی با وضوح بالاتر می‌تواند عملکرد مدل را با ارائه ورودی‌های دقیق‌تر بهبود بخشد که به‌ویژه در اصلاح طبقه‌بندی مناطق با حساسیت به فرسایش خاک بسیار بالا یا بسیار پایین، مفید خواهد بود. همچنین می‌توان اثربخشی مدل‌های ML پیشرفته‌تر مانند یادگیری عمیق را که ممکن است بهتر بتوانند تعاملات پیچیده بین متغیرهای محیطی و فرایندهای فرسایش خاک را درک کنند، بررسی کرد (خسروی و همکاران، ۲۰۲۳). علاوه بر این، مطالعات آینده باید از ادغام داده‌های فناوری‌های سنجش از دور را برای امکان‌پذیر کردن پایش دینامیک حساسیت فرسایش خاک بررسی کنند (موساسا<sup>۱</sup> و همکاران، ۲۰۲۴). این رویکرد می‌تواند به‌طور قابل توجهی پاسخ‌گویی راهبردهای مدیریت زمین را به تغییرات محیطی جاری افزایش دهد و با نیاز به چارچوب‌های انطباق‌پذیرتر و مقاوم‌تر برای ارزیابی حساسیت فرسایش خاک و مدیریت محیطی همسو شود (اجگو و یگیزاو،<sup>۲</sup> ۲۰۲۱).

مطالعه حاضر نشان داد که مدل تجمیعی (ESMs) با دقت بسیار بالا قادر به شناسایی مناطق مستعد فرسایش بادی است و می‌تواند به‌عنوان ابزاری مؤثر در مدیریت و برنامه‌ریزی برای مقابله با این پدیده مورد استفاده قرار گیرد. با این حال، محدودیت‌هایی نظیر کیفیت داده‌های ورودی و ویژگی‌های خاص منطقه مورد مطالعه می‌تواند بر دقت و قابلیت تعمیم نتایج تأثیر بگذارند. بنابراین، در پژوهش‌های آینده، تمرکز بر رفع این محدودیت‌ها و استفاده از داده‌های با وضوح بالاتر و مدل‌های پیشرفته‌تر می‌تواند به بهبود دقت و قابلیت کاربرد مدل‌های حساسیت فرسایش خاک کمک کند. با پرداختن به این حوزه‌ها، پژوهش‌های آینده می‌توانند در توسعه مدل‌های قوی‌تر و جامع‌تر که نه تنها دقت پیش‌بینی را بهبود می‌بخشند، بلکه قابلیت کاربرد ارزیابی‌های SES را در زمینه‌های محیطی متنوع گسترش می‌دهند، سهم باشند.

1. Musasa  
2. Ejegu & Yegizaw

## منابع

- Al-Bawi, A. J., Al-Abadi, A. M., Pradhan, B., & Alamri, A. M. (2021). Assessing gully erosion susceptibility using topographic derived attributes, multi-criteria decision-making, and machine learning classifiers. *Geomatics, Natural Hazards and Risk*, 12(1), 3035–3062. <https://doi.org/10.1080/19475705.2021.1994024>
- Almouctar, M. A. S., Wu, Y., Zhao, F., & Dossou, J. F. (2021). Soil erosion assessment using the rusle model and geospatial techniques (Remote sensing and gis) in south-central niger (maradi region). *Water (Switzerland)*, 13(24). <https://doi.org/10.3390/w13243511>
- Arabameri, A., Cerda, A., & Tiefenbacher, J. P. (2019). Spatial pattern analysis and prediction of gully erosion using novel hybrid model of entropy-weight of evidence. *Water (Switzerland)*, 11(6), 1–23. <https://doi.org/10.3390/w11061129>
- Arabameri, A., Pradhan, B., Pourghasemi, H. R., & Rezaei, K. (2018). Identification of erosion-prone areas using different multi-criteria decision-making techniques and gis. *Geomatics, Natural Hazards and Risk*, 9(1), 1129–1155. <https://doi.org/10.1080/19475705.2018.1513084>
- Can, A., Dagdelenler, G., Ercanoglu, M., & Sonmez, H. (2019). Landslide susceptibility mapping at Ovacık-Karabük (Turkey) using different artificial neural network models: comparison of training algorithms. *Bulletin of Engineering Geology and the Environment*, 78, 89–102. <https://doi.org/10.1007/s10064-017-1034-3>
- Conoscenti, C., Angileri, S., Cappadonia, C., Rotigliano, E., Agnesi, V., & Märker, M. (2014). Gully erosion susceptibility assessment by means of GIS-based logistic regression: A case of Sicily (Italy). *Geomorphology*, 204, 399–411. <https://doi.org/10.1016/j.geomorph.2013.08.021>
- Craney, T. A., & Surles, J. G. (2002). Model-dependent variance inflation factor cutoff values[J]. *Quality Engineering*, 2002(14), 391–403. <https://doi.org/10.1081/QEN-120001878>
- Ejegu, M. A., & Yegizaw, E. S. (2021). Modeling soil erosion susceptibility and LULC dynamics for land degradation management using geoinformation technology in Debre Tabor district, Northwestern highlands of Ethiopia. *J. Degrad. Min. Land Manage*, 8(2), 2623–2633. <https://doi.org/10.15243/jdmlm.2021.082.2623>
- Fielding, A. H., & Bell, J. F. (1997). A review of methods for the assessment of prediction errors in conservation presence/absence models. *Environmental conservation*, 24(1), 38–49.
- Folharini, S., Vieira, A., Bento-Gonçalves, A., Silva, S., Marques, T., & Novais, J. (2023). Soil Erosion Quantification using Machine Learning in Sub-Watersheds of Northern Portugal. *Hydrology*, 10(1). <https://doi.org/10.3390/hydrology10010007>
- Galton, F. (1892). *Finger prints* (No. 57490-57492). Macmillan and Company.
- Gayen, A., Pourghasemi, H. R., Saha, S., Keesstra, S., & Bai, S. (2019). Gully erosion susceptibility assessment and management of hazard-prone areas in India using different machine learning algorithms. *Science of the Total Environment*, 668, 124–138. <https://doi.org/10.1016/j.scitotenv.2019.02.436>
- Ghorbanzadeh, O., Shahabi, H., Mirchooli, F., Valizadeh Kamran, K., Lim, S., Aryal, J., Jarihani, B., & Blaschke, T. (2020). Gully erosion susceptibility mapping (GESM) using machine learning methods optimized by the multi-collinearity analysis and K-fold cross-validation. *Geomatics, Natural Hazards and Risk*, 11(1), 1653–1678. <https://doi.org/10.1080/19475705.2020.1810138>
- Golijanin, J., Nikolić, G., Valjarević, A., Ivanović, R., Tunguz, V., Bojić, S., Grmuša, M., Lukić Tanović, M., Perić, M., Hrelja, E., & Stankov, S. (2022). Estimation of potential soil erosion reduction using GISbased RUSLE under different land cover management models: A case study of Pale Municipality, B&H. *Frontiers in Environmental Science*, 10(August), 1–13. <https://doi.org/10.3389/fenvs.2022.945789>
- Golkarian, A., Khosravi, K., Panahi, M., & Clague, J. J. (2023). Spatial variability of soil water erosion: Comparing empirical and intelligent techniques. *Geoscience Frontiers*, 14(1), 101456. <https://doi.org/10.1016/j.gsf.2022.101456>
- Goyes-Peñafiel, P., & Hernandez-Rojas, A. (2021). Doble evaluación de la susceptibilidad por movimientos en masa basada en redes neuronales artificiales y pesos de evidencia. *Boletín de Geología*, 43(1), 173–191. DOI: 10.18273/revbol.v43n1-2021009
- Huang, D., Su, L., Zhou, L., Tian, Y., & Fan, H. (2023). Assessment of gully erosion susceptibility using different DEM-derived topographic factors in the black soil region of Northeast China. *International Soil and Water Conservation Research*, 11(1), 97–111. <https://doi.org/10.1016/j.iswcr.2022.04.001>
- Jalali, M., Gholami, H., Rezaie, M., & Omidvar, E. (2023). Integrated Modeling of Soil Erosion by Water and Wind Using Machine Learning Methods. *Watershed Management Research Journal*, 36(3), 128–145. doi: 10.22092/wmrj.2022.358127.1458
- Khosravi, K., Rezaie, F., Cooper, J. R., Kalantari, Z., Abolfathi, S., & Hatamiafkouei, J. (2023). Soil water erosion susceptibility assessment using deep learning algorithms. *Journal of Hydrology*, 618. <https://doi.org/10.1016/j.jhydrol.2023.129229>
- Kucuker, D. M., & Cedano Giraldo, D. (2022). Assessment of soil erosion risk using an integrated

- approach of GIS and Analytic Hierarchy Process (AHP) in Erzurum, Turkiye. *Ecological Informatics*, 71, 101788. <https://doi.org/https://doi.org/10.1016/j.ecoinf.2022.101788>
21. Kutner, M. H., Nachtsheim, C., & Neter, J. (2004). *Applied linear regression models*. McGraw-Hill/Irwin.
  22. Memarian H, & Momeni Damaneh J. (2024). Evaluating the efficiency of different machine learning models in extracting the map of erosion forms of arid watersheds (Case study: Mukhtaran plain watershed, South Khorasan, Iran). *E.E.R.*, 14 (4), 119-145. <http://magazine.hormozgan.ac.ir/article-1-856-fa.html>
  23. Momeni Damaneh, J., Ahmadi, J., & Jafarpour Chekab, Z. (2023b). Identification of Suitable Areas for Cultivation of Saffron (*Crocus sativus* L.) Using Artificial Intelligence-Based Models in Khorasan Razavi Province. *Journal of Saffron Research*, 11(2), 328-345. doi: 10.22077/jsr.2024.7137.1231
  24. Momeni Damaneh, J., Memarian, H. and Safdari, A. A. (2025). Machine Learning Techniques for Gully Erosion Susceptibility Mapping (Case Study: Mukhtaran Watershed, South Khorasan Province, Iran). *Sustainable Earth Trends*, doi: 10.48308/set.2025.237956.1093
  25. Momeni Damaneh, J., Tajbakhsh, S. M., Ahmadi, J., & Safdari, A. A. (2022). Comparison of species distribution models in determining the habitat landscape of *Pistacia vera* L. specie in Razavi Khorasan province. *Water and Soil Management and Modelling*, 3(4), 77-92. doi: 10.22098/mmws.2022.11698.1160
  26. Momeni Damaneh, J., Tajbakhsh, S. M., Ahmadi, J., & Safdari, A. A. (2023a). Determining The Areas Prone to The Growth of *Rhume ribes* L. Specie in Razavi Khorasan Province Using Vector Machine Models. *Water and Soil Management and Modelling*, doi: 10.22098/mmws.2023.12726.1276. [In Persian].
  27. Mosavi, A., Sajedi-Hosseini, F., Choubin, B., Taromideh, F., Rahi, G., & Dineva, A. A. (2020). Susceptibility mapping of soil water erosion using machine learning models. *Water (Switzerland)*, 12(7). <https://doi.org/10.3390/w12071995>
  28. Musasa, T., Dube, T., & Marambanyika, T. (2024). Landsat satellite programme potential for soil erosion assessment and monitoring in arid environments: A review of applications and challenges. *International Soil and Water Conservation Research*, 12(2), 267-278. <https://doi.org/10.1016/j.iswcr.2023.10.003>
  29. Nguyen, C. Q., Tran, T. T., Nguyen, T. T. T., Nguyen, T. T., Astarkhanova, T. S., Vu, L. V., Dau, K. T., Nguyen, H. N., Pham, G. H., Nguyen, D. D., Prakash, I., & Pham, B. (2023). Mapping of soil erosion susceptibility using advanced machine learning models at Nghe An, Vietnam. *Journal of Hydroinformatics*, 26(1). <https://doi.org/10.2166/hydro.2023.327>
  30. Ollii, M. R., Kironoto, B. A., Ollii, A., Pakaya, R., & Ollii, A. K. Z. (2024b). Advancing Soil Erosion Assessment: Application of Remote Sensing and Geospatial Techniques in Bulango Ulu Reservoir Basin. *E3S Web of Conferences*, 476, 1-15. <https://doi.org/10.1051/e3sconf/202447601041>
  31. Ollii, M. R., Ollii, A. K. Z., Ollii, A., Pakaya, R., & Kironoto, B. A. (2024a). Spatial modeling of soil erosion risk a multi-criteria decision-making (MCDM) approach in the paguyaman watershed, Gorontalo, Indo.pdf. *Arabian Journal of Geosciences*, 17(226), 1-13. <https://doi.org/https://doi.org/10.1007/s12517-024-12032-0>
  32. Ollii, M. R., Ollii, A., & Pakaya, R. (2021). The Integrated Spatial Assessment of The Flood Hazard Using AHP-GIS: The Case Study of Gorontalo Regency. *Indonesian Journal of Geography*, 53(1), 126-135. <https://doi.org/10.22146/ijg.59999>
  33. Ollii, M. R., Ollii, A., Pakaya, R., & Ollii, M. Y. U. P. (2023). GIS-based analytic hierarchy process (AHP) for soil erosion-prone areas mapping in the Bone Watershed, Gorontalo, Indonesia. *Environmental Earth Sciences*, 82(9), 1-14. <https://doi.org/10.1007/s12665-023-10913-3>
  34. Pal, S.C., Arabameri, A., Blaschke, T., Chowdhuri, I., Saha, A., Chakraborty, R., Lee, S. & Band, S.S. (2020). Ensemble of machine-learning methods for predicting gully erosion susceptibility. *Remote Sensing*, 12(22), p.3675. <https://doi.org/10.3390/rs12223675>
  35. Phinzi, K., & Szabó, S. (2024). Predictive machine learning for gully susceptibility modeling with geoenvironmental covariates: main drivers, model performance, and computational efficiency. *In Natural Hazards* (Vol. 120, Issue 8). Springer Netherlands. <https://doi.org/10.1007/s11069-024-06481-9>
  36. Rahmati, O., Tahmasebipour, N., Haghizadeh, A., Pourghasemi, H. R., & Feizizadeh, B. (2017). Evaluating the influence of geo-environmental factors on gully erosion in a semi-arid region of Iran: An integrated framework. *Science of the Total Environment*, 579, 913-927. <https://doi.org/10.1016/j.scitotenv.2016.10.176>
  37. Saha, S. (2017). Groundwater potential mapping using analytical hierarchical process: a study on Md. Bazar Block of Birbhum District, West Bengal. *Spatial Information Research*, 25(4), pp.615-626. <https://doi.org/10.1007/s41324-017-0127-1>
  38. Saini, S. S., Jangra, R., & Kaushik, S. P. (2015). Vulnerability Assessment of Soil Erosion Using Geospatial Techniques-a Pilot Study of Upper Catchment of Markanda River. *Research Article*

- International Journal of Advancement in Remote Sensing*, 3(1), 9–21.
39. Senanayake, S., Pradhan, B., Huete, A., & Brennan, J. (2020). A review on assessing and mapping soil erosion hazard using geo-informatics technology for farming system management. *Remote sensing*, 12(24), 4063. <https://doi.org/10.3390/rs12244063>
40. Shahri, A. A., Spross, J., Johansson, F., & Larsson, S. (2019). Landslide susceptibility hazard map in southwest Sweden using artificial neural network. *Catena*, 183, 104225. DOI: 10.1016/j.catena.2019.104225
41. Shirani, K., Pasandi, M., & Arabameri, A. (2018). Landslide susceptibility assessment by Dempster-Shafer and index of entropy models, Sarkhoun basin, Southwestern Iran. *Natural Hazards*, 93(3), 1379–1418. <https://doi.org/10.1007/s11069-018-3356-2>
42. Smeeton, N. C. (1985). Early history of the kappa statistic. *Biometrics*, 41, 795.
43. Swets, J. A. (1988). Measuring the accuracy of diagnostic systems. *Science*, 240(4857), 1285–1293.
44. Thuiller, W., Lafourcade, B., Engler, R., & Araújo, M. B. (2009). BIOMOD—a platform for ensemble forecasting of species distributions. *Ecography*, 32(3), 369–373.
45. Walther, G. R., Post, E., Convey, P., Menzel, A., Parmesan, C., Beebee, T. J., ... & Bairlein, F. (2002). Ecological responses to recent climate change. *Nature*, 416(6879), 389–395.
46. Wang, Y., Zhang, Y., & Chen, H. (2023). Gully erosion susceptibility prediction in Mollisols using machine learning models. *Journal of Soil and Water Conservation*, 78(5), 385–396. <https://doi.org/10.2489/jswc.2023.00019>
47. Yi, Y. J., Cheng, X., Yang, Z. F. & Zhang, S. H. (2016). Maxent modeling for predicting the potential distribution of endangered medicinal plant (*H. riparia* Lour) in Yunnan, China. *Ecological Engineering*, (92), 260–269.

## Machine Learning-Based Decision Support System for Sustainable Wind Erosion Management

Javad momeni damaneh,<sup>1</sup> Hadi Memarian<sup>2\*</sup>

Received: 19/01/2025

Accepted: 17/03/2025

### Extended abstract

**Introduction:** Soil erosion, a critical environmental issue, endangers ecosystems, agriculture, and food security. This study aims to develop a precise and comprehensive method for assessing soil vulnerability to erosion by exploring various advanced statistical and machine learning models. Combining spatial modeling and machine learning, this research seeks to create a model capable of accurately simulating complex soil erosion processes and identifying erosion-prone areas with high precision. Our findings reveal that machine learning models like Random Forest and Artificial Neural Networks excel at predicting soil vulnerability. This breakthrough can significantly aid in management planning to mitigate soil erosion and conserve natural resources.

**Materials and methods:** To comprehensively assess wind erosion in the study area, a multi-stage approach was employed. Initially, a robust foundation for subsequent analyses was established by gathering diverse data, including high-resolution topographic maps, vegetation cover, and soil and geology data, all integrated using GIS. Subsequently, high-quality aerial imagery and extensive field visits were utilized to precisely locate wind erosion points. This step was crucial for ensuring the accuracy and reliability of modeling input data. During field visits, a GPS device was used to record the exact locations of various wind erosion types, such as ripples, dunes of varying density, ridges with different grain sizes and densities, surface erosion in the form of ridges, signs of erosion and transport, and sand plains. Following data collection, we proceeded to identify and select environmental variables that significantly influence wind erosion. From the 25 identified environmental variables, suitable variables for modeling were selected using statistical analysis and the Variance Inflation Factor (VIF) criterion, ensuring a value less than 10. This step aimed to reduce multicollinearity among variables and enhance model accuracy. To model the spatial distribution of wind erosion, a wide range of machine learning algorithms were employed. These algorithms included GLM, GBM, CTA, ANN, SRE, FDA, MARS, RF, and MaxEnt, along with a powerful ensemble model (ESMs) developed in R software. The selection of these algorithms was based on the complex nature of wind erosion and the superior ability of these algorithms to model nonlinear relationships. The data was divided into training and validation sets with a 70:30 ratio and repeated five times for model robustness. To evaluate the accuracy of the developed models, common statistical indices such as ROC, TSS, and Kappa were used. These indices represent the model's ability to discriminate between erosion and non-erosion points, overall model accuracy, and agreement between the model and observed data, respectively. By comparing these indices for different models, the optimal model for predicting wind erosion distribution was selected.

**Results:** Finally, the generated maps were classified into four classes based on erosion sensitivity: low, moderate, high, and very high. These maps graphically illustrate areas with a high potential for erosion and can be used as a management tool for planning and implementing erosion control measures. Among the 25 environmental variables examined, 23 variables with a Variance Inflation Factor (VIF) of less than 10 were selected for the final model to minimize multicollinearity. This careful selection of variables significantly improved model accuracy and reduced errors in the results. Based on the stability results, the ensemble models

1. Department of Natural Resources Engineering, Agriculture and Natural Resources Faculty, Hormozgan University, Bandarabbas, Iran. Email: j.momenidamaneh.phd@hormozgan.ac.ir

2. Associate Professor, Department of Watershed Management, Faculty of Natural Resources and Environment, University of Birjand, Birjand, Iran. Email: hadi\_memarian@birjand.ac.ir

(ESMs) demonstrated the best overall performance in predicting all forms of wind erosion, including ergs, low-density small dunes, high-density small dunes, high-density coarse-grained ridges, medium-density medium-grained ridges, medium-density fine-grained ridges, surface erosion in the form of ridges, removal and transport traces, and sandy areas, with respective accuracies of 0.982, 0.968, 0.921, 0.984, 0.992, 0.814, 0.816, 0.893, and 0.821. These models achieved very high accuracy in all three evaluation criteria. By combining multiple machine learning algorithms, this model has high generalizability and can be applied to various environmental conditions. Some of the most important environmental variables affecting the potential of wind erosion include drainage density, hydrological groups, frequency of rocks and pebbles, percentage of bare soil, slope, average air temperature, and vegetation cover. These variables indicate that various natural and human factors influence the wind erosion process. Modeling results indicated that nebkas and ergs were primarily distributed in the central part of the basin, while surface erosion was more prevalent in the northwestern and western regions. These spatial patterns highlight the influence of various topographic, vegetation, and climatic factors on wind erosion distribution within the basin.

**Conclusion:** The significance of this research lies in its ability to empower natural resource planners and managers to accurately identify critical areas susceptible to erosion. By utilizing this information, targeted management practices, such as afforestation, windbreak establishment, mulching, and proper rangeland management, can be strategically implemented in vulnerable areas. These measures not only mitigate wind erosion and conserve soil but also contribute to improved air quality, enhanced biodiversity, and ecosystem sustainability. Machine learning models offer numerous advantages for wind erosion assessment. These models provide a powerful tool for accurate and generalizable prediction and monitoring of soil erosion. Furthermore, they enable the evaluation of the impact of climate change and land use changes on wind erosion, facilitating long-term strategic planning for sustainable water and soil resource management. Additionally, these models can optimize the costs of implementing management measures and enhance their effectiveness. In conclusion, this study demonstrates the significant potential of machine learning models in assessing and managing wind erosion. By employing these models, a deeper understanding of complex wind erosion processes can be achieved, enabling the design and implementation of effective and adaptive management strategies to conserve natural resources and protect the environment.

**Keyword:** Erosion susceptibility, Risk assessment, Remote sensing data, Spatial data, Ensemble model, Natural resource management.