

کاربرد الگوریتم‌های یادگیری ماشین در تحلیل اثر آتش‌سوزی بر آب‌گریزی خاک در آبخیز توشن استان گلستان

کهزاد حیدری^{۱*}، علی نجفی‌نژاد^۲، علی محمدیان بهبهانی^۳، مجید اونق^۴، لویزدلیو دیگر^۵

- ۱- استادیار پژوهشی بخش تحقیقات حفاظت خاک و آب‌خیزداری، مرکز تحقیقات، آموزش کشاورزی و منابع طبیعی خوزستان، سازمان تحقیقات، آموزش و ترویج کشاورزی، اهواز، ایران
- ۲- استاد گروه آب‌خیزداری، دانشکده مرتع و آب‌خیزداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گلستان، ایران
- ۳- دانشیار گروه مدیریت مناطق بیابانی، دانشکده مرتع و آب‌خیزداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گلستان، ایران
- ۴- استاد گروه مدیریت مناطق بیابانی، دانشکده مرتع و آب‌خیزداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گلستان، ایران
- ۵- استاد گروه فیزیک خاک و مدیریت زمین، بخش علوم محیط زیست، دانشگاه و پژوهشگاه واخنینگن، واخنینگن، هلند

چکیده مبسوط

مقدمه و هدف

در دهه‌های گذشته آتش‌سوزی‌های جنگلی به‌عنوان یکی از مهم‌ترین تهدیدهای زیست‌محیطی در بوم‌سازگان‌های جنگلی و مرتعی شناخته شده‌اند. این پدیده افزون بر نابودی تخریب پوشش گیاهی و زیستگاه‌ها، به‌شدت سبب تغییر ویژگی‌های فیزیکی و شیمیایی خاک می‌شود که از جمله مهم‌ترین آن‌ها بروز پدیده آب‌گریزی خاک است. آب‌گریزی خاک می‌تواند منجر به افزایش رواناب سطحی، کاهش نفوذپذیری، تشدید فرسایش و در نهایت کاهش پایداری بوم‌سازگان شود. در سال‌های گذشته، رخداد آتش‌سوزی‌های پیاپی و گسترده در جنگل‌های هیرکانی شمال ایران، به‌ویژه در استان گلستان، در زمینه مدیریت منابع طبیعی سبب نگرانی‌های جدی شده است. با وجود پژوهش‌های پرشمار در سطح جهانی، پژوهش‌های داخلی در زمینه بررسی اثر آتش‌سوزی بر آب‌گریزی خاک و به‌ویژه استفاده از رویکردهای نوین مدل‌سازی همچون الگوریتم‌های یادگیری ماشین هنوز محدود است. از سوی دیگر، روش‌های سنتی مانند آزمون زمان نفوذ قطره آب (WDPT) یا آزمون اتانول، اگرچه برای شناسایی اولیه مفیدند، اما نمی‌توان روابط پیچیده و غیرخطی میان ویژگی‌های خاک و شدت آب‌گریزی را مدل‌سازی کرد. از این‌رو، این پژوهش با هدف بررسی تغییرات زمانی آب‌گریزی خاک پس از آتش‌سوزی و ارزیابی توان الگوریتم‌های یادگیری ماشین در پیش‌بینی شاخص WDPT در آبخیز توشن استان گلستان انجام شد.

نوع مقاله: پژوهشی

* مسئول مکاتبات: k.heidary@areeo.ac.ir

استناد: حیدری، ک.، نجفی‌نژاد، ع.، محمدیان بهبهانی، ع.، اونق، م.، دیگر، ل. د. ۱۴۰۵. کاربرد الگوریتم‌های یادگیری ماشین در تحلیل اثر آتش‌سوزی بر آب‌گریزی خاک در آبخیز توشن استان گلستان. پژوهش‌های آب‌خیزداری. ۳۹(۲): ۴۳-۲۰.

شناسه دیجیتال: 10.22092/wmrj.2025.370992.1637

تاریخ دریافت: ۱۴۰۴/۰۷/۲۰، تاریخ بازنگری: ۱۴۰۴/۰۸/۰۵، تاریخ پذیرش: ۱۴۰۴/۰۹/۳۰، تاریخ انتشار: ۱۴۰۵/۰۴/۰۱

پژوهش‌های آب‌خیزداری، سال ۱۴۰۵ دوره ۳۹، شماره ۲، شماره پیاپی ۱۵۱، تابستان ۱۴۰۵، صفحه‌های ۲۰ تا ۴۳.

© نویسنندگان

ناشر: مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان فارس



افزون بر این، در این پژوهش ضمن برطرف کردن محدودیت‌های علمی موجود، ابزاری کاربردی برای مدیریت خطرهای ناشی از آتش‌سوزی و برنامه‌ریزی احیای پس از آن ارائه شد.

مواد و روش‌ها

این پژوهش در آبخیز توشن در استان گلستان، بخشی از جنگل‌های هیرکانی ثبت‌شده در فهرست میراث جهانی یونسکو، انجام شد. اقلیم منطقه نیمه‌مرطوب تا مرطوب و میانگین سالانه بارندگی ۶۲۰ میلی‌متر و میانگین دما ۱۶ درجه سانتی‌گراد است. خاک‌های منطقه عمدتاً لسی با بافت لوم سیلتی با مواد آلی زیاد هستند که شرایطی مستعد برای شکل‌گیری آب‌گریزی پس از آتش فراهم می‌آورند. طرح آزمایش فاکتوریل بود و در قالب طرح کاملاً تصادفی با دو عامل اصلی شامل نوع کاربری زمین و تیمار آتش‌سوزی (شاهد و سوخته) طراحی شد. نمونه‌برداری خاک در سه بازه زمانی (یک روز، یک هفته و یک ماه پس از آتش‌سوزی) و در دو ژرفا (۵- و ۱۰- سانتی‌متر) انجام شد و در مجموع ۹۶ نمونه برداشت شد. ویژگی‌های فیزیکی و شیمیایی خاک شامل بافت، اسیدیته، هدایت الکتریکی، کربن آلی، ماده آلی، پایداری خاک‌دانه و جرم‌مخصوص‌ظاهری اندازه‌گیری شدند. شدت آب‌گریزی با شاخص WDPT سنجیده شد. داده‌ها پس از ورود به محیط پایتون پیش‌پردازش شدند؛ داده‌های پرت با روش IQR شناسایی اما حذف نشدند، بهنجارسازی با Z-score انجام شد و هم‌خطی متغیرها با VIF بررسی شد. سپس، داده‌ها به دو بخش آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم شدند. برای مدل‌سازی از ۱۲ الگوریتم یادگیری ماشین شامل مدل‌های پایه، مبتنی بر همسایگی، تجمیعی و ترکیبی استفاده شد. بهینه‌سازی ابرسنجه‌ها با روش جستجوی بیزی و اعتبارسنجی متقاطع پنج‌تایی انجام شد. عملکرد مدل‌ها با شاخص‌های R^2 ، RMSE، MAE، NSE و CCC ارزیابی شد. افزون بر این، تحلیل حساسیت با روش‌های PFI و SHAP و تحلیل نبودن قطعیت با بوت‌استرپ و شبیه‌سازی مونت کارلو انجام شد.

نتایج و بحث

نتایج نشان داد اثر آتش‌سوزی بر آب‌گریزی خاک، شدید اما کوتاه‌مدت بود. میانگین WDPT یک روز پس از آتش‌سوزی ۵/۲ دقیقه بود که نشان‌دهنده افزایش قابل‌توجه آب‌گریزی است. در هفته اول این اندازه به کمتر از یک دقیقه کاهش یافت و پس از یک ماه تقریباً صفر شد. این یافته بیانگر ماهیت گذرای اثر آتش بر آب‌گریزی سطحی خاک است. تحلیل‌های آماری (ANOVA) نشان داد اثر تیمار آتش‌سوزی و برهم‌کنش آن با زمان و کاربری زمین بر WDPT معنی‌دار بود. در میان الگوریتم‌های یادگیری ماشین، بهترین عملکرد مربوط به درخت تصمیم ($R^2=0/44$) و شیب بوستینگ ($R^2=0/43$) بود، در حالی که دقت مدل‌هایی مانند SVM و وایزی بیزین کمتر بود. نتایج تحلیل حساسیت نشان داد سیلت، هدایت الکتریکی و ماده آلی مهم‌ترین متغیرها در پیش‌بینی WDPT بودند. نتایج SHAP نیز نشان داد افزایش سیلت و ماده آلی موجب افزایش آب‌گریزی شد، در حالی که اثر افزایش EC کاهنده بود. نبودن قطعیت نشان داد پایداری مدل‌های ساده‌تر مانند درخت تصمیم در برابر داده‌های پرت بیشتر بود، در حالی که نبودن قطعیت مدل‌های پیچیده‌تر در اندازه‌های حدی WDPT افزایش یافت. بر پایه این یافته‌ها می‌توان با استفاده از مدل‌های ساده یا مبتنی بر بوستینگ، آب‌گریزی خاک پس از آتش‌سوزی را دقیق‌تر و پایدارتر پیش‌بینی کرد.

نتیجه‌گیری و پیشنهادها

این پژوهش نشان داد اثر آتش‌سوزی بر آب‌گریزی خاک در آبخیز توشن شدید اما کوتاه‌مدت بود و در مدت یک ماه این اثر به‌طور کامل از بین رفت. با بهره‌گیری از الگوریتم‌های یادگیری ماشین، به‌ویژه درخت تصمیم و شیب بوستینگ، می‌توان روابط پیچیده میان ویژگی‌های خاک و شدت آب‌گریزی را با دقت قابل‌قبولی مدل‌سازی کرد. نتایج تحلیل حساسیت و نبودن قطعیت نشان داد در شکل‌گیری آب‌گریزی، نقش متغیرهایی مانند سیلت، هدایت الکتریکی و ماده آلی مهم بود. بر اساس یافته‌های این پژوهش پیشنهاد می‌شود برای مدیریت پس از آتش‌سوزی آب‌گریزی خاک به‌شکل کوتاه‌مدت پایش شود و از مدل‌های ساده و پایدار برای پیش‌بینی تغییرات آن، بهره‌گیری شود. افزون بر این، با ترکیب داده‌های میدانی و داده‌های سنجش از دور و توسعه مدل‌های منطقه‌ای می‌توان سبب بهبود مدیریت خطرهای ناشی از آتش‌سوزی شد. در نتیجه، پیشنهاد می‌شود در پژوهش‌های آینده اثرات بلندمدت آتش‌سوزی بر دیگر

ویژگی‌های خاک و کارکردهای بوم‌سازگان بررسی شود و از الگوریتم‌های یادگیری عمیق برای افزایش دقت پیش‌بینی‌ها بهره‌گیری شود.

واژگان کلیدی

آب‌گریزی خاک، آتش‌سوزی جنگل، الگوریتم‌های یادگیری ماشین، تحلیل حساسیت، نبودن قطعیت

مقدمه

بیشتر است و با افزایش ژرفا کاهش می‌یابد (تن و همکاران ۲۰۲۵). تغییرات ژرفا بر نفوذ آب، توزیع رطوبت خاک و در نتیجه چرخه آب‌شناخت و عملکرد بوم‌سازگان نقش مهمی دارد (چی و همکاران ۲۰۲۵). در جنگل‌های متراکم با خاک غنی از مواد آلی، مانند جنگل‌های هیرکانی شمال ایران، احتمال تشکیل لایه‌های آب‌گریز پس از آتش‌سوزی بسیار زیاد است (حیدری و همکاران ۲۰۱۸). این شرایط پیامدهایی همچون کاهش رشد گیاهان، تغییر در ترکیب گونه‌ای و افزایش خطر خشکسالی‌های بوم‌شناختی به همراه دارد (بونانومی و همکاران ۲۰۲۴). با وجود پیشرفت‌های گذشته در شناخت ساز و کارهای SWR، بیشتر پژوهش‌های پیشین بر پایهٔ آزمون‌های میدانی و تحلیل‌های آماری ساده مانند آزمون نفوذ قطره آب^۲ یا مولاریته قطره اتانول^۳ بوده‌اند. این روش‌ها اگرچه برای تشخیص و طبقه‌بندی اولیه SWR مفیدند، اما قابلیت مدل‌سازی روابط غیرخطی و چند عاملی میان ویژگی‌های خاک و شدت آب‌گریزی را ندارند. در سال‌های گذشته بهره‌گیری از الگوریتم یادگیری ماشین^۴ به‌عنوان رویکردی نوین و قدرتمند در تحلیل داده‌های پیچیده خاک و عامل‌های محیطی گسترش یافته است (گو و همکاران ۲۰۲۱؛ محمودزاده و همکاران ۲۰۲۰؛ مقدم و همکاران ۲۰۲۰؛ رحمتی و همکاران ۲۰۱۹). عملکرد این الگوریتم‌ها، به‌ویژه عملکرد مدل‌هایی مانند جنگل تصادفی، ماشین بردار پشتیبان (SVM) و ایکس‌جی‌بوست، هم در شناسایی الگوهای پیچیده و روابط غیرخطی میان ویژگی‌های

در سال‌های گذشته آتش‌سوزی‌های جنگلی به‌عنوان یکی از مهمترین مخاطره‌های زیست‌محیطی شناخته شده‌اند و به‌ویژه در مناطق جنگلی، به‌دلیل افزایش فراوانی، شدت و گستره رخداد، یکی از نگرانی‌های اصلی در مدیریت منابع طبیعی و پایداری بوم‌سازگان‌ها هستند (فلینیگان و همکاران ۲۰۰۹؛ سان-میگل-آپانز و همکاران ۲۰۱۸). این رخداد، افزون بر نابودی پوشش گیاهی، حیات وحش و زیستگاه‌ها، بر ویژگی‌های فیزیکی، شیمیایی و آب‌شناختی خاک نیز اثرات شدید و ماندگاری دارد (آرونات و همکاران ۲۰۲۴). خاک به‌عنوان یکی از اجزای اصلی بوم‌سازگان، پس از آتش‌سوزی دستخوش تغییراتی مانند کاهش کربن آلی، ناپایداری خاک‌دانه‌ها، کاهش نفوذپذیری و افزایش خطر فرسایش می‌شود (بنتو-گونسالوز و همکاران ۲۰۱۲). یکی از پیامدهای مهم پس از آتش‌سوزی، بروز و تشدید پدیده آب‌گریزی خاک^۱ است که رواناب سطحی را افزایش داده و منجر به تشدید فرایندهای فرسایشی می‌شود (دوئر و سانتین ۲۰۱۶). آب‌گریزی خاک پدیده‌ای طبیعی است که در کاربری‌های گوناگون زمین و شرایط اقلیمی متفاوت مشاهده می‌شود و منشأ آن به وجود ترکیبات آلی آب‌گریز ناشی از بقایای گیاهی، سوختگی مواد آلی و یا فعالیت میکروارگانیسم‌ها بستگی دارد (آتاناسووا و دور ۲۰۱۱؛ شیکسی و همکاران ۲۰۰۰). شدت و پایداری SWR تحت تأثیر عامل‌هایی مانند شدت و مدت آتش، نوع پوشش گیاهی، بافت و ساختار خاک و ژرفای نیم‌رخ است (گونزالس-پلایو و همکاران ۲۰۲۴). نتایج پژوهش‌ها نشان داده است که در لایه سطحی خاک (۵-۰ سانتی‌متر) شدت آب‌گریزی

2- Water Drop Penetration Time (WDPT)

3- Molarity Of Ethanol Droplet

4- Machine Learning (ML)

1- Soil Water Repellency (SWR)

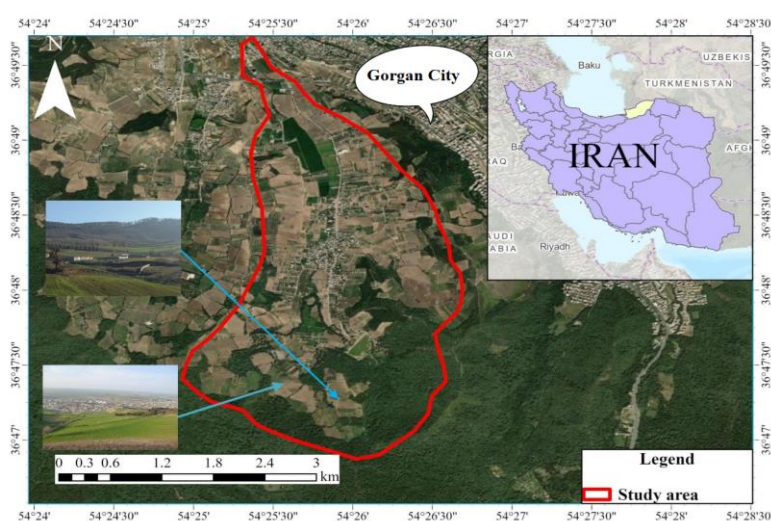
جنوب غرب شهر گرگان است و از مناطق جنگلی هیرکانی شمال ایران به شمار می‌آید. کمترین و بیشترین اندازه بلندی در آبخیز توشن به ترتیب ۱۴۷ و ۶۰۷ متر است. میانگین سالانه بارندگی منطقه مطالعه شده ۶۲۰ میلی‌متر است و وضعیت رطوبتی خاک زیرک و رژیم حرارتی آن ترمیک است (حیدری و همکاران ۲۰۱۸). منطقه پژوهشی بخشی از جنگل‌های هیرکانی است که به‌عنوان میراث جهانی یونسکو ثبت شده است. پوشش زیراشکوب در این مناطق شامل گیاهان علفی، درختچه‌ها و خزها است که نقش مهمی در حفظ تنوع زیستی و پایداری بوم‌سازگان دارند. این پوشش گیاهی ضمن جلوگیری از فرسایش خاک و حفظ رطوبت آن زیستگاه مهمی برای بسیاری از گونه‌های گیاهی و جانوری است. کاربری‌های اصلی شامل جنگل‌های سوزنی‌برگ، جنگل‌های پهن‌برگ و زمین کشاورزی است. خاک‌های منطقه عمدتاً از نوع لسی و بافت غالب آن‌ها لوم سیلتی با محتوای آهک نسبتاً زیاد است (زادورووا و همکاران ۲۰۲۱). این ویژگی‌ها همراه با تراکم زیاد مواد آلی، شرایطی مستعد برای شکل‌گیری آب‌گریزی پس از آتش‌سوزی فراهم آورده است. موقعیت جغرافیایی آبخیز توشن در استان گلستان و ایران در شکل ۱ نشان داده شده است.

خاک و پدیده‌ها موفق بوده است و هم به‌طور مؤثری در مدیریت داده‌های با ابعاد زیاد و کاهش حساسیت به داده‌های پرت به‌کار گرفته شده‌اند (الزبیدی و همکاران ۲۰۲۱). این پیشرفت‌ها به‌ویژه در مناطق با داده‌های محدود، سبب بهبود مدل‌سازی و پیش‌بینی نتایج پیچیده محیطی می‌شود. هدف اصلی این پژوهش بررسی اثر آتش‌سوزی بر ویژگی‌های خاک به‌ویژه آب‌گریزی خاک در آبخیز توشن استان گلستان بود. در این پژوهش از الگوریتم‌های پیشرفته یادگیری ماشین مانند درخت تصمیم، شیب بوستینگ و ایکس‌جی‌بوست برای شبیه‌سازی روابط پیچیده میان ویژگی‌های خاک و شدت آب‌گریزی در شرایط پس از آتش‌سوزی استفاده شد. افزون بر این، دقت این الگوریتم‌ها در پیش‌بینی آب‌گریزی خاک ارزیابی شد. در این پژوهش، یادگیری ماشین، به‌ویژه در مقایسه با دیگر الگوریتم‌ها، به‌عنوان رویکردی نوین در بررسی و پیش‌بینی اثرات آتش‌سوزی بر ویژگی‌های خاک ارزیابی شد.

مواد و روش‌ها

معرفی منطقه مطالعه شده

این پژوهش در آبخیز توشن استان گلستان (شمال شرق ایران) انجام شد (شکل ۱). این آبخیز از زیرآبخیزهای قره‌سو در استان نامبرده است که در



شکل ۱- موقعیت جغرافیایی آبخیز توشن در استان گلستان و ایران.

Figure 1- Geographic location of the Tushan watershed in Golestan Province and Iran.

طراحی آزمایش و نمونه‌برداری

در این پژوهش، آزمایش فاکتوریل بود و در قالب طرح کاملاً تصادفی^۵ با دو عامل اصلی شامل نوع کاربری زمین (سوزنی‌برگ، پهن‌برگ و کشاورزی) و تیمار آتش‌سوزی (شاهد و سوخته) که در فصل تابستان اعمال شد، انجام شد. در این پژوهش، برای کاهش اثر ناهمگنی مکانی، قطعه‌های آزمایشی در محدوده‌ای با شیب، جهت و پوشش گیاهی نسبتاً مشابه انتخاب شدند و تصادفی‌سازی در درون هر کاربری زمین و تیمار آتش‌سوزی انجام شد. افزون بر این، به‌منظور اطمینان از یکنواختی شدت سوختگی، آتش‌سوزی به دو روش تجویزی و مهارشده اجرا شد (شکل ۲) و شاخص‌های چشمی شدت سوختگی (مانند ژرفای خاکستر و بلندای زغال‌سوختگی) در تمام قطعه‌های آزمایشی بررسی شد. این اقدامات باعث شد تغییرات ناشی از عامل‌های مکانی به حداقل برسد و اثرات مشاهده‌شده عمدتاً ناشی از تیمار آتش‌سوزی و زمان نمونه‌برداری باشد. در هر تیمار، قطعه‌های مجزا انتخاب و آتش‌سوزی به دو روش تجویزی و مهارشده اجرا شد تا یکنواختی شدت سوختگی تضمین شود (بهارج ۲۰۲۵). از خاک منطقه پژوهشی در سه بازه زمانی (یک روز، یک هفته و یک ماه پس از آتش‌سوزی) و در دو ژرفا (۵-۰ و ۱۰-۵ سانتی‌متر) نمونه‌برداری شد. در مجموع ۹۶ نمونه خاک برداشت شد. به‌منظور حفظ ساختار طبیعی خاک نمونه‌برداری از بخش مرکزی هر قطعه با بیلچه استیل و مته دستی انجام شد (ستاد بررسی خاک ۲۰۱۴). نمونه‌ها پس از برداشت در کیسه‌های پلی‌اتیلنی درزدار نگهداری شدند و همراه با برچسب به آزمایشگاه انتقال یافتند. سپس، در دمای محیط خشک و از الک ۲ میلی‌متری عبور داده شدند. سرانجام، ویژگی‌های فیزیکی و شیمیایی مهم خاک، بر پایه استانداردهای نامبرده اندازه‌گیری شدند (جدول ۱).

اندازه‌گیری آب‌گریزی خاک

برای سنجش شدت آب‌گریزی، آزمون زمان نفوذ قطره آب (WDPT) بر پایه دستورالعمل دوئر و شیکسبای

(۲۰۱۱) اجرا شد. در این روش، قطره‌ای از آب مقطر (حجم ۵ میلی‌لیتر) به‌وسیله پیپت واسنجی‌شده و روی سطح دست‌نخورده خاک در محل گذاشته شد و زمان نفوذ با کروномتر ثبت شد. هر آزمایش سه بار تکرار و میانگین گزارش شد. طبقه‌بندی شدت آب‌گریزی بر پایه پیشنهاد جردن و همکاران (۲۰۱۳) در پنج طبقه از غیرآب‌گریز تا بسیار آب‌گریز انجام شد. طبقه‌بندی شدت آب‌گریزی در جدول ۲ ارائه شده است. در این پژوهش، اندازه زمان نفوذ قطره (WDPT) به‌عنوان متغیر وابسته برای مدل‌سازی در نظر گرفته شد و اندازه عددی آن با دیگر متغیرهای فیزیکی و شیمیایی خاک، مبنای تحلیل‌های یادگیری ماشین بود.

پردازش و آماده‌سازی داده‌ها برای مدل‌سازی

برای آماده‌سازی داده‌ها برای مدل‌های یادگیری ماشین، ابتدا مجموعه‌ای از داده‌های خام در نرم‌افزار اکسل بررسی شدند. سپس، داده‌ها به محیط برنامه‌نویسی پایتون انتقال یافتند تا فرآیند پردازش داده‌ها به‌طور دقیق‌تر و بهینه‌تر انجام شود. در ادامه برای شناسایی داده‌های پرت از روش فاصله بین چارکی (IQR) استفاده شد (لوسیتو و همکاران ۲۰۲۴). با این وجود به‌منظور حفظ ساختار طبیعی داده‌ها و جلوگیری از کاهش حجم مؤثر نمونه‌ها، داده‌های پرت حذف نشدند. به جای آن، مدل‌هایی که نسبت به داده‌های پرت حساسیت کمتری دارند از جمله جنگل تصادفی انتخاب شدند (بیرمن ۲۰۰۱). در گام بعدی از روش Z-score برای بهنجارسازی داده‌ها به‌منظور کاهش اثرگذاری متغیرهایی با دامنه مقیاس مختلف استفاده شد. این اقدام به‌ویژه برای الگوریتم‌هایی مانند ایکس‌جی‌بوست که نسبت به مقیاس متغیرها حساس هستند، اهمیت زیادی دارد. سپس، داده‌ها به‌طور تصادفی به دو گروه آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم شدند تا عملکرد مدل‌ها در پیش‌بینی داده‌های جدید به‌شکل واقع‌بینانه‌ای ارزیابی شود.

5- Completely Randomized Design (CRD)



شکل ۲- گونه‌های گیاهی استفاده‌شده در آتش تجویزی.

Figure 2- Plant species used in the prescribed fire.

جدول ۱- ویژگی‌های فیزیکی و شیمیایی اندازه‌گیری‌شده در نمونه‌های خاک و روش‌های آزمایشگاهی استفاده‌شده در این پژوهش.

Table 1- Characteristics of Measured Soil Physicochemical Properties and Laboratory Methods Used in This Study.

Property	Measurement Method	Scientific Reference
Organic Carbon (OC)	Walkley-Black Method	Enang et al. (2018)
Organic Matter (OM)	Calculated as $1.72 \times \text{OC}$	Nelson & Sommers (1982)
pH and EC	Saturated Paste Extract (Soil:Water 1:2.5)	Kargas et al. (2020)
Soil Texture	Bouyoucos Hydrometer Method	Beretta et al. (2014)
Aggregate Stability	Wet-Sieving Method	Almajmaie et al. (2017)
Water Drop Penetration Time (WDPT)	5 mL Standard Drop on Air-Dried Soil Surface	Doerr et al. (2009)

جدول ۲- طبقه‌بندی شدت آب‌گریزی خاک بر اساس زمان نفوذ قطره آب (WDPT).

Table 2- Classification of Soil Water Repellency Intensity Based on Water Drop Penetration Time (WDPT).

Hydrophobicity Status	Penetration Time (s)
Non-hydrophobic	< 5
Slightly hydrophobic	5-60
Moderately hydrophobic	60-180
Strongly hydrophobic	180-600
Severely hydrophobic	> 600

این ترتیب داده‌ها برای ورود به فرآیند مدل‌سازی آماده شدند.

مدل‌سازی با الگوریتم‌های یادگیری ماشین

برای پیش‌بینی شاخص آب‌گریزی خاک (WDPT) پس از آتش‌سوزی، از ۱۲ الگوریتم یادگیری ماشین استفاده شد. این الگوریتم‌ها بر اساس ماهیت و ساختارشان در چهار گروه اصلی دسته‌بندی شدند (جدول ۳). با استفاده از چنین تنوعی، عملکرد مدل‌های ساده، مبتنی بر همسایگی، تجمیعی و ترکیبی مقایسه شد.

در گام بعدی، برای بررسی هم‌خطی میان متغیرهای مستقل، ضریب تورم پراکنش (VIF) محاسبه شد (سالمرن-گومز و همکاران ۲۰۲۰). در شرایطی که اندازه‌های VIF بیش از ۱۰ بود، مدل هم با آن متغیر و هم بدون آن متغیر اجرا شد تا تأثیر حذف یا نگهداری آن بر دقت مدل ارزیابی شود. سرانجام، متغیر بافت خاک با استفاده از روش one-hot encoding و با استفاده از کتابخانه pandas در پایتون به متغیرهای عددی معادل تبدیل شد تا در الگوریتم‌های عددی استفاده شود (کوهن ۲۰۰۸). به

جدول ۳ - دسته‌بندی الگوریتم‌های یادگیری ماشین استفاده‌شده برای پیش‌بینی WDPT.

Table 3- Categorization of machine learning algorithms used for predicting WDPT.

Algorithm Group	Models
Linear & Simple Models (Baseline)	Bayesian Ridge, Decision Tree
Neighborhood & Kernel-Based Models	K-Nearest Neighbors (KNN), Support Vector Machine (SVM – Polynomial Kernel)
Ensemble Models	Random Forest, Gradient Boosting, XGBoost, LightGBM
Hybrid/Meta-Models	Voting Regressor, Stacking Regressor

پیاده‌سازی مدل‌ها

داده‌های پرت از روش فاصله بین چارکی (IQR) استفاده شد و با شناسایی داده‌های پرت، از مدل‌هایی که به داده‌های پرت حساسیت کمتری دارند (مانند جنگل تصادفی) بهره‌گرفته شد تا تأثیر آن‌ها بر دقت مدل‌ها به حداقل برسد. افزون بر این، برای ارزیابی صحت مدل‌ها و کاهش خطر overfitting، از جستجوی بیزی برای بهینه‌سازی دقیق ابرسنجه‌ها و اعتبارسنجی متقاطع پنج‌تایی استفاده شد.

تحلیل حساسیت و نبودن قطعیت

برای شناسایی متغیرهای مهم مؤثر بر WDPT، از دو رویکرد مکمل استفاده شد.

رویکرد Permutation Feature Importance (PFI)

از این رویکرد برای سنجش اندازه حساسیت مدل‌ها به تغییرات ویژگی‌ها استفاده شد.

رویکرد SHAP (Shapley Additive Explanations)

از این رویکرد برای تحلیل سهم هر متغیر و جهت اثر آن بر پیش‌بینی‌ها و همچنین تعامل‌های غیرخطی

پیاده‌سازی تمام مدل‌ها در محیط پایتون نسخه ۷,۱۳,۳ و با استفاده از کتابخانه‌های scikit-learn, xgboost, lightgbm و optuna برای تنظیم ابرسنجه‌ها انجام شد. داده‌ها پس از پیش‌پردازش به دو مجموعه آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم شدند. سنجه‌های اصلی مانند max_depth, n_estimators و learning_rate برای هر مدل بهینه‌سازی شدند. بهینه‌سازی ابرسنجه‌ها با روش جستجوی بیزی در قالب ۵ بار اعتبارسنجی متقاطع انجام شد. برای ارزیابی عملکرد، شاخص‌های ضریب تبیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، ضریب نش-ساتکلیف (NSE) و ضریب همبستگی توافقی (CCC) استفاده شدند. در راستای بهینه‌سازی مدل‌ها، به‌ویژه در مدل‌هایی مانند ایکس‌جی‌بوست که حساسیت زیادی به مقیاس داده‌ها دارند، بهنجارسازی داده‌ها با روش Z-score انجام شد. برای شناسایی و مدیریت

زمانی پس از آتش‌سوزی (یک روز، یک هفته و یک ماه) محاسبه شد (جدول ۴). درصد سیلت در روز اول ۵۵/۸٪ بود و تا هفته اول تقریباً ثابت باقی ماند (۵۶٪) و پس از یک ماه به ۵۶/۴٪ رسید. درصد رس در روز اول ۳۵/۹٪ بود و یک ماه پس از آتش‌سوزی به ۳۷/۱٪ افزایش یافت، در حالی که درصد شن از ۸/۲۸٪ به ۶/۵٪ کاهش یافت. تغییرات اسیدیته خاک قابل توجه نبود که نشان‌دهنده اثر محدود آتش‌سوزی بر ذخایر کربنی لایه سطحی است. از سوی دیگر، کاهش تدریجی میانگین وزنی-قطر ذرات و جرم‌مخصوص ظاهری خاک نشان‌دهنده شل‌شدن نسبی ساختار خاک در این دوره بود. یکی از مهمترین شاخص‌ها، زمان نفوذ قطره آب بود که در روز اول به‌طور قابل توجهی افزایش یافت (۲/۴۸ دقیقه) و پس از گذشت یک ماه به‌طور کامل برابر با صفر شد. این تغییرات نشان‌دهنده گذرا بودن اثر آبریزی خاک پس از آتش‌سوزی است. این یافته با نتایج پژوهش‌های پیشین که نشان داده‌اند اثرات آبریزی در نتیجه آتش‌سوزی معمولاً گذرا بوده و در مدت زمان کوتاهی از بین می‌روند، هم‌راستا است (دوئر و همکاران ۲۰۰۹).

استفاده شد. به‌منظور ارزیابی نبودن قطعیت و پایداری مدل‌ها، دو روش به‌کار گرفته شد. روش Bootstrap: در این بخش، با استفاده از ۲۰۰ بار نمونه‌گیری تصادفی از داده‌های آزمون، اندازه‌های R^2 و RMSE برای مدل‌های منتخب محاسبه شد. نتایج پراکنش نقاط در فضای R^2 -RMSE همراه با بیضی‌های اطمینان ۹۵٪ برای هر مدل رسم شد. روش Monte Carlo Simulation: با ۵۰۰ تکرار و افزودن نویز تصادفی (۵٪ انحراف معیار ویژگی‌ها)، بازه‌های اطمینان پیرامون پیش‌بینی‌ها محاسبه شد. شایان ذکر است که تحلیل حساسیت و نبودن قطعیت برای مدل‌های برتر (بر اساس دقت و پایداری) و همچنین یک مدل پیشرفته مبتنی بر boosting انجام شد. این انتخاب باعث گردآوری نتایج و جلوگیری از افزایش بیش از حد حجم مقاله شد.

نتایج و بحث

بررسی آماری اولیه داده‌ها

برای ارزیابی تغییرات ویژگی‌های فیزیکی و شیمیایی خاک در ژرفا ۱۰-۰ سانتی‌متر، آمار توصیفی شامل میانگین و انحراف معیار ده شاخص اصلی در سه بازه

جدول ۴- آمار توصیفی متغیرهای مهم در روز اول پس از آتش‌سوزی.

Table 4- Descriptive statistics of key variables on the first day following the wildfire.

Property	One day post-fire (mean \pm SD)	One week post-fire (mean \pm SD)	One month post-fire (mean \pm SD)
Silt (%)	55.8 \pm 4.55	56.0 \pm 4.51	56.4 \pm 4.12
Sand (%)	8.28 \pm 2.55	6.63 \pm 1.92	6.50 \pm 1.83
Clay (%)	35.9 \pm 3.43	37.4 \pm 4.90	37.1 \pm 4.45
pH	7.58 \pm 0.31	7.60 \pm 0.27	7.61 \pm 0.15
EC (dS m ⁻¹)	1.02 \pm 0.20	0.95 \pm 0.19	0.93 \pm 0.17
OC (%)	1.26 \pm 0.74	1.27 \pm 0.72	1.30 \pm 0.74
OM (%)	2.17 \pm 1.28	2.19 \pm 1.25	2.24 \pm 1.28
MWD (mm)	0.36 \pm 0.17	0.33 \pm 0.15	0.31 \pm 0.14
BD (g cm ⁻³)	1.66 \pm 0.16	1.62 \pm 0.13	1.57 \pm 0.12
WDPT (min)	2.48 \pm 4.28	0.48 \pm 1.00	0.00 \pm 0.00


آتش‌سوزی بر ویژگی‌های خاک در طول زمان و بازسازی تدریجی ساختار خاک است. با گذشت زمان، اثرات آتش‌سوزی کاهش یافت و همبستگی روابط میان ویژگی‌های خاک و WDPT کمتر شد. در تجزیه و تحلیل همبستگی، افزون بر رابطه‌های میان WDPT و ویژگی‌های خاک مانند درصد رس و شن، MWD (میانگین وزنی-قطر خاکدانه‌ها) نیز به‌عنوان شاخصی از پایداری خاکدانه بررسی شد. نتایج نشان داد در بازه زمانی یک ماه پس از آتش‌سوزی، همبستگی میان میانگین وزنی-قطر خاکدانه‌ها با WDPT مثبت کم ($P < 0.05$, $R^2 = 0.29$) بود که نشان‌دهنده کاهش تدریجی اثرات آتش‌سوزی بر ساختار خاک و بازسازی تدریجی خاکدانه‌ها در طول زمان است. همچنین، نتایج میانگین وزنی-قطر خاکدانه‌ها نشان داد آتش‌سوزی بر پایداری خاکدانه‌ها اثرگذار بود و سبب تغییر ویژگی‌های آب‌گریزی خاک شد. نقشه‌های حرارتی^۶ رسم‌شده و تغییرات ضریب‌های همبستگی در سه بازه زمانی مطالعه‌شده در شکل ۳ نشان‌دهنده شده است.

در این نقشه‌ها، رنگ قرمز نشان‌دهنده همبستگی مثبت و رنگ آبی بیانگر همبستگی منفی است؛ همچنین شدت رنگ متناسب با بزرگی ضریب همبستگی تغییر می‌کند. این یافته بیانگر آن است که با گذشت زمان، شدت همبستگی‌ها کاهش یافت و در برخی موارد جهت آنها نیز تغییر یافت؛ موضوعی که بیانگر تعدیل تدریجی اثر آتش‌سوزی بر روابط میان WDPT و ویژگی‌های خاکی است.


تحلیل همبستگی شاخص آب‌گریزی خاک (WDPT) با ویژگی‌های خاکی


به‌منظور ارزیابی کمی روابط میان شاخص آب‌گریزی خاک (WDPT) و مجموعه‌ای از ویژگی‌های فیزیکی و شیمیایی خاک در بازه‌های زمانی مختلف پس از رخداد آتش‌سوزی، از ضریب همبستگی پیرسون به‌عنوان شاخص سنجش ارتباط خطی استفاده شد. تمام محاسبه‌ها بر اساس داده‌های اندازه‌گیری‌شده در سه مقطع زمانی یک روز، یک هفته و یک ماه پس از آتش‌سوزی انجام شد. نتایج بررسی تغییرات مکانی-زمانی ضریب‌های همبستگی در شکل ۴ ارائه‌شده است. در بازه یک روز پس از آتش‌سوزی، بیشترین همبستگی منفی و معنادار میان WDPT و درصد رس ($R^2 = -0.83$, $P < 0.001$) خیلی زیاد) مشاهده شد. این همبستگی منفی خیلی زیاد را می‌توان به اثرات اولیه آتش‌سوزی بر ساختار خاک نسبت داد. آتش‌سوزی باعث تغییرات شدید در ساختار خاک، به‌ویژه در لایه‌های سطحی، و افزایش آب‌گریزی در خاک‌هایی با محتوای رس زیاد می‌شود. همچنین، رابطه همبستگی WDPT با درصد شن منفی و در حد متوسط ($R^2 = -0.67$, $P < 0.001$) بود که نشان‌دهنده اثرات آتش‌سوزی بر پراکندگی ذرات شن و کاهش نفوذپذیری خاک است. همبستگی دیگر ویژگی‌های خاک در این بازه از نظر آماری معنادار نبود. در بازه یک هفته پس از آتش‌سوزی، همبستگی میان WDPT و ماده آلی مثبت و بسیار زیاد ($R^2 = 0.9$, $P < 0.001$) بود که دلیل آن اثرات آتش‌سوزی بر افزایش تجزیه مواد آلی و کاهش آب‌گریزی خاک است. افزون بر این، همبستگی میان WDPT و درصد رس منفی و کم ($R^2 = -0.26$) بود که نشان‌دهنده کاهش اثرات آتش‌سوزی بر ویژگی‌های فیزیکی خاک در این بازه زمانی است. در بازه زمانی یک ماه پس از آتش‌سوزی، هیچ رابطه مهم و معناداری میان WDPT و دیگر ویژگی‌های خاکی شناسایی نشد، اما همبستگی میان WDPT با میانگین وزنی-قطر خاکدانه‌ها مثبت کم ($R^2 = 0.29$) بود که نشان‌دهنده کاهش اثرات

WDPT Correlation with Soil Properties - One Day After Fire



WDPT Correlation with Soil Properties - One Week After Fire





شکل ۳ - نقشه حرارتی همبستگی WDPT با ویژگی‌های خاکی در سه بازه زمانی پس از آتش‌سوزی.

Figure 3- Heatmap of correlations between WDPT and soil properties across three post-fire time intervals.




شکل ۴ - نقشه حرارتی مقایسه عملکرد مدل‌های یادگیری ماشین در پیش‌بینی شاخص آب‌گریزی خاک (WDPT) پس از آتش‌سوزی بر اساس معیارهای RMSE, MAE, R², NSE و CCC.

Figure 4- Heatmap comparison of machine learning models' performance in predicting soil water repellency (WDPT) post-fire based on RMSE, MAE, R², NSE, and CCC metrics.

۴). با این حال، با بررسی دقیق نتایج مدل‌ها یافته‌های ارزشمندی از رفتار هر الگوریتم مشاهده شد. نتایج مقایسه کلی مدل‌ها در میان الگوریتم‌های استفاده‌شده نشان داد بهترین عملکرد مربوط به درخت تصمیم ساده ($R^2=0.44$, $RMSE=3.76$)، $MAE=1.7$, $CCC=0.63$ بود. نتایج مقایسه اندازه‌های ضریب تبیین (R^2) مدل‌های یادگیری ماشین استفاده‌شده، در شکل ۵ ارائه شده است. بر پایه نتایج شکل ۵ عملکرد درخت تصمیم ساده در مقایسه با دیگر الگوریتم‌ها بهتر بود.

نتایج مدل‌های یادگیری ماشین در این پژوهش نتایج به‌کارگیری مجموعه‌ای از الگوریتم‌های یادگیری ماشین برای پیش‌بینی WDPT پس از آتش‌سوزی بیانگر یکسان نبودن عملکرد مدل‌ها و وجود تفاوت محسوسی میان آنها بود. بر پایه نقشه حرارتی مقایسه عملکرد مدل‌ها اندازه‌های نسبتاً کم ضریب تبیین (بیشترین اندازه R^2 برابر ۰/۴۴) بیانگر پیچیدگی زیاد فرآیندهای مؤثر بر آب‌گریزی و محدودیت داده‌های موجود است (شکل



شکل ۵- مقایسه اندازه‌های ضریب تبیین (R^2) مدل‌های یادگیری ماشین استفاده‌شده در پیش‌بینی شاخص آب‌گریزی خاک (WDPT) پس از آتش‌سوزی.

Figure 5- Comparison of the coefficient of determination (R^2) values of machine learning models used for predicting the soil water repellency index (WDPT) post-fire.

مدل‌های Boost-tree، عملکرد این مدل به‌دلیل تفسیرپذیری زیاد، قابل قبول بود که با یافته‌های این پژوهش هم‌راستا است. نتایج پژوهش‌های دیگری نیز در زمینه پیش‌بینی ویژگی‌های خاک با یافته‌های این پژوهش هماهنگی دارد (پادریان و همکاران ۲۰۲۰، چن و همکاران ۲۰۱۹). در میان مدل‌های تجمیعی، بهترین عملکرد مربوط به الگوریتم شیب بوستینگ بود ($R^2=0.43$, $CCC=0.62$). در این راستا، نتایج

نتایج بررسی اولیه کمی غیرقابل انتظار بود اما با توجه به محدودیت داده‌ها و ناهمگنی نمونه‌ها، قابل توجیه بودند. در چنین شرایطی، تصمیم‌پذیری مدل‌های ساده در مقایسه با مدل‌های پیچیده معمولاً بهتر است. در این راستا، پانیاواراپورن و همکاران (۲۰۲۵) عملکرد مدل‌های مختلف یادگیری ماشین در پیش‌بینی ویژگی‌های خاک را ارزیابی کردند و دریافتند که با وجود دقت کمتر مدل درخت تصمیم در مقایسه با


از سوی دیگر، عملکرد مدل‌های SVM با کرنل چندجمله‌ای ($R^2=0.07$) و Bayesian Ridge ($R^2=0.29$) کم بود که احتمالاً دلیل آن وابستگی بیشتر آنها به داده‌های گسترده و پایدار است. در حالی که پویایی ویژگی‌های خاک پس از آتش‌سوزی زیاد است. افزون بر این، ترکیب مدل‌ها با روش‌های Voting ($R^2=0.37$) و Stacking ($R^2=0.22$) بهبود معنادار دقت پیش‌بینی نشد. این یافته با نتایج پژوهش‌های فرانک و همکاران (۲۰۱۱) و لامیچان و همکاران (۲۰۲۵) هماهنگی دارد. این پژوهشگران گزارش کردند که در شرایط با حجم داده کم و متغیرهای هم‌بسته، مدل‌های ترکیبی الزاماً برتری محسوسی بر مدل‌های منفرد ندارند.

زیادی از داده‌ها حول خط یک‌به‌یک بودند که نشان‌دهنده همبستگی مناسب میان اندازه‌های واقعی و پیش‌بینی شده است.

پژوهش فرناندز-گارسیا و همکاران (۲۰۱۹) بیانگر دقت بیشتر این الگوریتم در مقایسه با جنگل تصادفی در پیش‌بینی فرآیندهای خاکی پیچیده بود که با نتایج این پژوهش همخوانی دارد. در این پژوهش، دقت جنگل تصادفی در مقایسه با درخت تصمیم و شیب بوستینگ کمتر بود ($R^2 \approx 0.32$). عملکرد مدل‌های XGBoost ($R^2=0.36$, $CCC=0.55$) و LightGBM ($R^2=0.35$, $CCC=0.54$) متوسط بود که با یافته‌های پیشین در زمینه پیش‌بینی رطوبت خاک هم‌راستا است. نتایج پژوهش لامیچان و همکاران (۲۰۲۵) نیز مؤید آن بود که ترکیب مدل‌های یادگیری ماشین با مدل‌های فیزیکی تصمیم‌پذیری را در مناطق با داده محدود افزایش داد.

تحلیل دقیق سه مدل برتر

بیشترین دقت مربوط به مدل درخت تصمیم ($R^2=0.44$) بود که به‌طور قابل توجهی گویای تغییرات شاخص WDPT بود. برپایه شکل ۶، بخش



شکل ۶- مقایسه اندازه‌های واقعی و پیش‌بینی شده شاخص آب‌گریزی خاک (WDPT) به‌وسیله سه مدل برتر (خط قرمز نقطه‌چین بیانگر حالت ایده‌آل پیش‌بینی ($y = x$) است).


Figure 6- Comparison of observed versus predicted soil water repellency (WDPT) values by the top three models (the red dashed line represents the ideal prediction scenario, ($y = x$)).

این نتایج با یافته‌های لامیچان و همکاران (۲۰۲۵) و فریدمن (۲۰۰۱) همخوانی دارد. عملکرد مدل KNN ($R^2=0.42$)، به‌رغم سادگی نسبی، مشابه درخت تصمیم و شیب بوستینگ بود، اما به توزیع داده‌ها و

عملکرد مدل شیب بوستینگ ($R^2=0.43$) مشابه درخت تصمیم بود و در محدوده اندازه‌های میانی WDPT دقیق بود، اما پراکندگی آن در اندازه‌های حدی (خیلی کم یا خیلی زیاد) بیشتر بود.

درخت تصمیم، شیب بوستینگ و ایکس‌جی‌بوست استفاده شد. نتایج نشان داد در هر سه مدل، بیشترین اهمیت مربوط به درصد سیلت یک روز پس از آتش‌سوزی است (شکل ۷). این نتایج مؤید نقش مهم بافت خاک در پایداری آب‌گریزی است. این یافته در پژوهش‌های دوئر و توماس (۲۰۰۰) و بنتو-گونسالوز و همکاران (۲۰۱۲) نیز گزارش شده است.

انتخاب سنجه k حساس بود و اندازه MAE آن بیشتر (۲/۳۳) بود که با یافته‌های کاور و هارت (۱۹۶۷) هم‌راستا است. نتایج این پژوهشگران مؤید حساسیت k به ساختار داده و انتخاب همسایگی است. در تحلیل حساسیت و شناسایی مهم‌ترین متغیرهای مؤثر بر شاخص آب‌گریزی خاک پس از آتش‌سوزی، از روش اهمیت ویژگی جایگشتی روی سه مدل برتر یعنی



شکل ۷- اهمیت ویژگی‌های خاک در پیش‌بینی شاخص آب‌گریزی بر اساس روش اهمیت ویژگی جایگشتی برای سه مدل یادگیری ماشین منتخب.

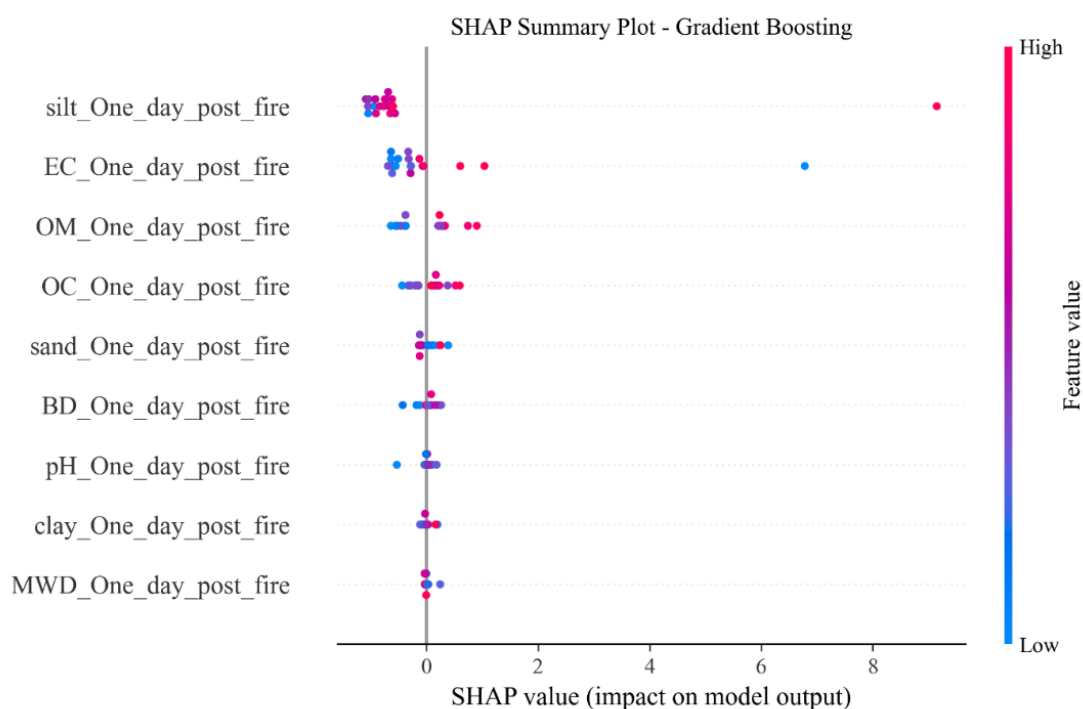
Figure 7- Importance of soil features in predicting the soil water repellency index based on the Permutation Feature Importance method for three selected machine learning models.

آتش‌سوزی سبب افزایش پایداری آب‌گریزی خاک می‌شود، هم‌راستا است. با بهره‌گیری از مدل شیب بوستینگ، می‌توان اثر غیرخطی و برهم‌کنش ویژگی‌ها را بهتر نشان داد، در حالی که حساسیت

افزون بر درصد سیلت، جایگاه هدایت الکتریکی و ماده آلی نیز در هر سه مدل نیز مهم بود (شکل ۷). این نتایج با یافته‌های بودی و همکاران (۲۰۱۳) مبنی بر اینکه افزایش هدایت الکتریکی و ماده آلی پس از

مربوط به افزایش سیلت است (شکل ۸). همچنین، اثر هدایت الکتریکی به‌طور معناداری کمتر از دیگر ویژگی‌ها بود. این یافته نشان‌دهنده تعامل پیچیده عامل‌های فیزیکی و شیمیایی خاک است. در پژوهش‌هایی استفاده از SHAP به‌عنوان ابزار قدرتمندی برای شفاف‌سازی تصمیمات مدل‌های یادگیری ماشین در علوم خاک گزارش شده است (لاندربرگ و لی ۲۰۱۷؛ مولنار ۲۰۲۰).


ایکس‌جی‌بوست افزون بر سیلت، به درصد شن و پایداری خاکدانه نیز زیاد بود. این یافته با نتایج پژوهش ژائو و همکاران (۲۰۲۰) مبنی بر اینکه این مدل در داده‌های با تنوع بافتی زیاد به ویژگی‌های ساختاری خاک، حساسیت بیشتری دارد، مطابقت دارد. برای تکمیل تحلیل حساسیت، از روش SHAP نیز استفاده شد. با بهره‌گیری از این روش سهم نسبی هر متغیر و جهت اثر آن بر خروجی مدل بررسی شد. نتایج نشان داد بیشترین اثر بر شاخص WDPT



شکل ۸- چکیده SHAP برای مدل شیب بوستینگ در پیش‌بینی شاخص آب‌گریزی خاک (WDPT).
Figure 8- SHAP summary plot for the Gradient Boosting model in predicting the soil water repellency index (WDPT).

(۲۰۲۲) نیز تأکید شده است. نتایج این پژوهش‌ها بیانگر آن است که در مدیریت پایدار پس از آتش‌سوزی، نمی‌توان فقط به یک دسته از ویژگی‌های خاک (مثلاً بافت یا ویژگی شیمیایی) اکتفا کرد.

به‌طور کلی نتایج تحلیل حساسیت نشان داد ترکیب عامل‌های فیزیکی (بافت خاک) و شیمیایی (هدایت الکتریکی و ماده آلی) در مهار آب‌گریزی پس از آتش‌سوزی تعیین‌کننده است. این هم‌افزایی در پژوهش‌های جدیدتر مانند مارکوت و همکاران



شکل ۹- پراکنش شاخص‌های عملکرد R^2 و RMSE برای سه مدل منتخب بر اساس بازنمونه‌گیری بوت‌استرپ، همراه با بیضی‌های اطمینان ۹۵٪ برای هر مدل.

Figure 9- Scatter plot of R^2 and RMSE performance metrics for the three selected models based on bootstrap resampling, with 95% confidence ellipses for each model.

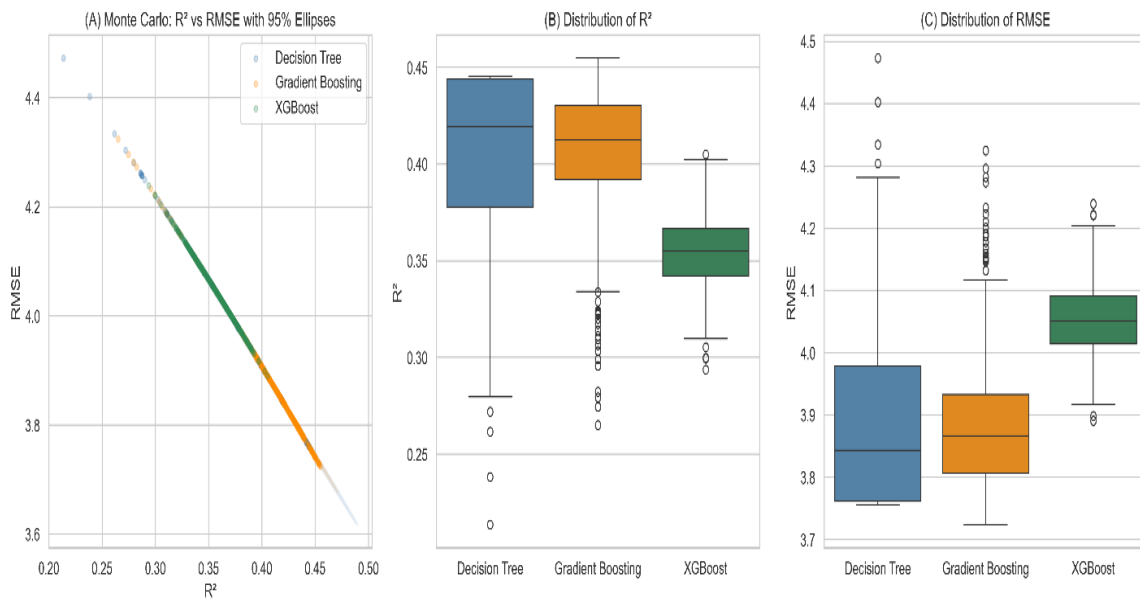
تحلیل نبودن قطعیت Bootstrap

درخت تصمیم و شیب بوستینگ بیانگر پایداری و دقت بیشتر و عملکرد قابل‌اعتمادتر این مدل‌ها در پیش‌بینی با شرایط مختلف داده‌ای بود. این نتایج با یافته‌های فرانک و همکاران (۲۰۱۱) و هستی و همکاران (۲۰۰۹) مبنی بر اینکه در شرایط داده‌های محدود و ناهمگن، ثبات و پایداری مدل‌های ساده‌تر یا مرحله‌ای بیشتر است و عملکرد آنها در پیش‌بینی‌های برون‌نمونه قابل اعتمادتر است، همخوانی دارد.

شبیه‌سازی مونت‌کارلو

به‌منظور ارزیابی نبودن قطعیت ناشی از نویز ورودی، شبیه‌سازی مونت‌کارلو با ۵۰۰ تکرار روی مدل شیب بوستینگ اجرا شد. در هر تکرار، به داده‌های آزمون نویز تصادفی معادل ۵٪ از انحراف معیار هر ویژگی افزوده شد و سپس پیش‌بینی‌ها ثبت شد. در ادامه میانگین پیش‌بینی‌ها و بازه اطمینان ۹۵٪ محاسبه و در کنار اندازه‌های واقعی رسم شد (شکل ۱۰).

نتایج به‌دست‌آمده نشان داد پایداری نسبی الگوریتم‌های درخت تصمیم و شیب بوستینگ با میانه R^2 حدود ۰/۴۵ و دامنه پراکندگی محدود، در برابر تغییرات داده بیشتر است (شکل ۹). از سوی دیگر، الگوریتم ایکس‌جی‌بوست با وجود داشتن میانه مشابه، در تعدادی از بازنمونه‌گیری‌ها اندازه‌های R^2 آن منفی و RMSE زیاد بود. این یافته نشان‌دهنده حساسیت بیشتر این الگوریتم به تغییرات جزئی در داده‌های ورودی و احتمال بیش‌برازش در مجموعه‌های کوچک است. تحلیل بیضی‌های اطمینان نشان داد درخت تصمیم و شیب بوستینگ خوشه‌های متراکم‌تری در فضای عملکرد ایجاد کرده‌اند. با ارزیابی بیضی‌های اطمینان، پراکندگی نتایج مدل‌ها به‌شکل گرافیکی بررسی شد. از سوی دیگر، اندازه و شکل این بیضی‌ها نیز بیانگر اطلاعاتی در زمینه پایداری مدل‌ها در برابر تغییرات داده‌ها بود. بیضی‌های کوچک‌تر و متراکم‌تر در



شکل ۱۰- نتایج شبیه‌سازی مونت کارلو برای سه مدل درخت تصمیم، شیب بوستینگ و ایکس‌جی‌بوست شامل (A): پراکنش R^2 -RMSE همراه با بیضی اطمینان ۹۵٪، (B) توزیع R^2 ، و (C) توزیع RMSE.

Figure 10- Monte Carlo simulation results for the three models (Decision Tree, Gradient Boosting, and XGBoost), including: (A) R^2 -RMSE scatter plot with 95% confidence ellipse, (B) R^2 distribution, and (C) RMSE distribution.

نتیجه‌گیری و پیشنهادها

به‌طور کلی، یافته‌های این پژوهش نشان داد اثر آتش‌سوزی بر آب‌گریزی خاک، شدید اما کوتاه‌مدت بود. شاخص WDPT در روز نخست پس از آتش-سوزی به‌طور قابل توجهی افزایش یافت، اما پس از یک هفته به‌طور چشمگیری کاهش یافت و در پایان ماه نخست تقریباً به صفر رسید. از این‌رو، پایداری آب‌گریزی در خاک‌های منطقه محدود به بازه‌ای کوتاه‌مدت بود. مدل‌سازی با الگوریتم‌های یادگیری ماشین نشان داد بهترین عملکرد در پیش‌بینی WDPT مربوط به درخت تصمیم و شیب بوستینگ بود و با بهره‌گیری از آنها می‌توان بخش قابل توجهی از تغییرات داده‌ها را توضیح داد. از سوی دیگر، عملکرد مدل‌های پیچیده‌تر مانند ایکس‌جی‌بوست و LightGBM متوسط بود و عملکرد برخی مدل‌ها مانند SVM و وایزی بیزین کم‌تر بود. این یافته بیانگر آن است که در شرایط داده‌های کوچک و ناهمگن،

نتایج شبیه‌سازی بیانگر هم‌خوانی زیاد میان میانگین پیش‌بینی‌ها (خط آبی) با اندازه‌های مشاهده‌شده بود و در اغلب نمونه‌ها، باند اطمینان ۹۵٪ (ناحیه آبی) باریک باقی ماند (شکل ۱۰). این یافته بیانگر اطمینان و دقت زیاد مدل در شرایط معمولی است. با این حال، در اندازه‌های حدى شاخص نفوذپذیری آب در خاک (خیلی زیاد یا خیلی کم)، پهنای باند افزایش یافت که نشان‌دهنده رشد نبودن قطعیت در شرایط غیرمعمول یا داده‌های کم‌نمونه است. این یافته با نتایج پژوهش‌های مارکوت و همکاران (۲۰۲۲) و فرناندز-گارسیا و همکاران (۲۰۱۹) مبنی بر اینکه مدل‌ها در محدوده داده‌های پرت یا کم‌نمونه، به‌دلیل نبود الگوهای مشابه در داده‌های آموزشی، پیش‌بینی‌هایی با اطمینان کمتر ارائه می‌دهند، مطابقت دارد.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منفعی در راستای نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده‌شده در این پژوهش، با مکاتبه با نویسنده مسئول در اختیار مخاطب قرار خواهد گرفت.

مشارکت نویسندگان

نویسنده اول: انجام تحلیل‌های نرم‌افزاری/آماري، نگارش نسخه اولیه مقاله

نویسنده دوم: راهنمایی، ویرایش و بازبینی مقاله، بازبینی نتایج

نویسنده سوم: مفهوم‌سازی، مشاوره، بازبینی متن مقاله، تحلیل‌های آماری

نویسنده چهارم: طراحی مطالعه، نظارت بر اجرای پژوهش، بازبینی متن مقاله

نویسنده پنجم: ارائه راهنمایی‌های تخصصی، بازبینی و ویرایش علمی مقاله

انتخاب مدل‌های ساده‌تر یا مرحله‌ای می‌تواند مناسب‌تر باشد. نتایج تحلیل حساسیت نشان داد که درصد سیلت، هدایت الکتریکی و ماده آلی سه عامل مهم در مهار WDPT پس از آتش‌سوزی است. از این‌رو، هم ویژگی‌های فیزیکی و هم تغییرات شیمیایی خاک در شکل‌گیری آب‌گریزی نقش دارند. نتایج بررسی نبودن قطعیت نیز نشان داد پایداری درخت تصمیم و شیب بوستینگ در خروجی‌ها بیشتر بود و در بیشتر نمونه‌گیری‌ها نتایج آنها مشابه بود، در حالی که ایکس‌جی‌بوست حساسیت بیشتری به تغییرات نشان داد. نتایج شبیه‌سازی مونت‌کارلو نیز نشان داد اطمینان پیش‌بینی‌ها در محدوده اندازه‌های معمول WDPT زیاد بود، اما در اندازه‌های حدی نبودن قطعیت افزایش یافت.

بر پایه یافته‌های این پژوهش پیشنهاد می‌شود از مدل‌های ساده‌تر یا الگوریتم‌های شیب بوستینگ با تنظیمات پایدار که ابزار مناسبی برای پیش‌بینی پدیده آب‌گریزی هستند، بهره‌گیری شود. افزون بر این، از دیدگاه مدیریتی، پیشنهاد می‌شود در هفته‌های نخست پس از آتش‌سوزی اقدامات پیشگیرانه که نقش و اهمیت ویژه‌ای دارند، انجام شود تا اثرات منفی بر پایداری خاک کاهش یابد و فرسایش سطحی مهار شود.

فهرست منابع

- Almajmaie A, Hardie M, Acuna T, Birch C. 2017. Evaluation of methods for determining soil aggregate stability. *Soil and Tillage Research*. 167:39-45. <https://doi.org/10.1016/J.STILL.2016.11.003>
- Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, Santamaría J, Fadhel MA, Al-Amidie M, Farhan L. 2021. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*. 8(1):1-74. <https://doi.org/10.1186/S40537-021-00444-8>
- Arunrat N, Kongsurakan P, Solomon LW, Sreenonchai S. 2024. Fire Impacts on Soil Properties and Implications for Sustainability in Rotational Shifting Cultivation: A Review.

- Agriculture. 14(9):1660-1675. <https://doi.org/10.3390/agriculture14091660>
- Atanassova I, Doerr SH. 2011. Changes in soil organic compound composition associated with heat-induced increases in soil water repellency. *European Journal of Soil Science*. 62(4):516-532. <https://doi.org/10.1111/j.1365-2389.2011.01350.x>
- Bento-Gonçalves A, Vieira A, Úbeda X, Martin D. 2012. Fire and soils: Key concepts and recent advances. *Geoderma*. 191:3-13. <https://doi.org/10.1016/J.GEODERMA.2012.01.004>
- Beretta AN, Silbermann AV, Paladino L, Torres D, Bassahun D, Musselli R, García-Lamohte A. 2014. Análisis de textura del suelo

con hidrómetro: Modificaciones al método de Bouyoucus. *Ciencia e Investigación Agraria*. 41(2):263–271. <https://doi.org/10.4067/S0718-16202014000200013>

Bhardwaj AP. 2025. Modeling the Long-Term Effectiveness of Prescribed Burns in Reducing Wildfire Risk (Master's thesis, State University of New York at Buffalo). ProQuest Dissertations and Theses Global).

Bodí MB, Muñoz-Santa I, Armero C, Doerr SH, Mataix-Solera J, Cerdà A. 2013. Spatial and temporal variations of water repellency and probability of its occurrence in calcareous Mediterranean rangeland soils affected by fires. *Catena*. 108:14–25.

<https://doi.org/10.1016/j.catena.2012.04.002>

Bonanomi G, Motti R, Abd-ElGawad AM, Idbella M. 2024. Soil water repellency along elevation gradients: The role of climate, land use and soil chemistry. *Geoderma*. 443:116847. <https://doi.org/10.1016/j.geoderma.2024.116847>

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1): 5–32. <https://doi.org/10.1023/A:1010933404324>

Certini G. 2005. Effects of fire on properties of forest soils: A review. *Oecologia*. 143(1):1–10. <https://doi.org/10.1007/s00442-004-1788-8>

Chen L, Ren C, Li L, Wang Y, Zhang B, Wang Z, Li L. 2019. A comparative assessment of geostatistical, machine learning, and hybrid approaches for mapping topsoil organic carbon content. *ISPRS International Journal of Geo-Information*. 8(4): 174–180.

Cover TM, Hart PE. 1967. Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*. 13(1):21–27. <https://doi.org/10.1109/TIT.1967.1053964>

Debano LF. 2000. Water repellency in soils: A historical overview. *Journal of Hydrology*. 231–232:4–32. [https://doi.org/10.1016/S0022-1694\(00\)00180-3](https://doi.org/10.1016/S0022-1694(00)00180-3)

Doerr SH, Santín C. 2016. Global trends in wildfire and its impacts: perceptions versus realities in a changing world. *Philosophical Transactions of the Royal Society B: Biological Sciences*. 371(1696):1–12. <https://doi.org/10.1098/RSTB.2015.0345>

Doerr SH, Shakesby RA. 2011. Handbook of Soil Sciences Properties and Processes, second edition. In: Handbook of Soil Sciences Properties and Processes, second edition. CRC press, Taylor and Francis group. pp. 515–525. <https://doi.org/10.1016/B978-0-444-51269-7.50023-0>

Doerr SH, Shakesby RA, MacDonald LH. 2009. Soil water repellency: a key factor in post-fire erosion. In: Cerdà A, Robichaud PR,

Editors. *Fire Effects on Soils and Restoration Strategies*. Science Publishers, New Hampshire, Enfield, NH. pp. 197–223. <https://doi.org/10.1201/9781439843338>

Doerr SH, Shakesby RA, Walsh RPD. 2000. Soil water repellency: Its causes, characteristics and hydro-geomorphological significance. *Earth-Science Reviews*. 51(1–4): 33–65. [https://doi.org/10.1016/S0012-8252\(00\)00011-8](https://doi.org/10.1016/S0012-8252(00)00011-8)

Doerr SH, Thomas AD. 2000. The role of soil moisture in controlling water repellency: new evidence from forest soils in Portugal. *Journal of Hydrology*. 231–232:134–147. [https://doi.org/10.1016/S0022-1694\(00\)00190-6](https://doi.org/10.1016/S0022-1694(00)00190-6)

Enang RK, Yerima BPK, Kome GK, Van Ranst E. 2018. Assessing the Effectiveness of the Walkley-Black Method for Soil Organic Carbon Determination in Tephra Soils of Cameroon. *Communications in Soil Science and Plant Analysis*. 49(19):2379–2386. <https://doi.org/10.1080/00103624.2018.1510948>

Fernández-García V, Miesel J, Baeza MJ, Marcos E, Calvo L. 2019. Wildfire effects on soil properties in fire-prone pine ecosystems: Indicators of burn severity legacy over the medium term after fire. *Applied Soil Ecology*. 135:147–156. <https://doi.org/10.1016/J.APSOIL.2018.12.002>

Flannigan MD, Krawchuk MA, De Groot WJ, Wotton BM, Gowman LM. 2009. Implications of changing climate for global wildland fire. *International Journal of Wildland Fire*. 18(5):483–507. <https://doi.org/10.1071/WF08187>

Frank E, Hall MA, Witten IH. 2011. Data mining: Practical machine learning tools and techniques. 3rd ed. Elsevier (Morgan Kaufmann), Burlington, MA, USA. pp. 1–664. <https://doi.org/10.1016/C2009-0-19715-5>

Friedman JH. 2001. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*. 29(5):1189–1232. <https://doi.org/10.1214/AOS/1013203451>

González-Pelayo O, Prats SA, van den Elsen E, Malvar MC, Ritsema C, Bautista S, Keizer JJ. 2024. The effects of wildfire frequency on post-fire soil surface water dynamics. *European Journal of Forest Research*. 143(2):493–508. <https://doi.org/10.1007/S10342-023-01635-Z/METRICS>

Gu C, Zhou Q, Cusick RD, Margenot AJ. 2021. Evaluating agronomic soil phosphorus tests for soils amended with struvite. *Geoderma*. 399:115093. <https://doi.org/10.1016/J.GEODERMA.2021.115093>

- Hastie T, Tibshirani R, Friedman J. 2009. *The Elements of Statistical Learning*. 2nd ed. Springer, New York, USA. pp. 1–745. <https://doi.org/10.1007/978-0-387-84858-7>
- Heidary K, Najafinejad A, Mohammadian Behbahani A, Ownegh M. 2018. Assessment of soil water repellency intensity and its temporal variability after prescribed fire in forest areas of toshen watershed, Golestan Province. *Journal of Water and Soil Conservation*. 25(4):27–47. (In Persian). <https://doi.org/10.22069/jwsc.2018.14663.2960>
- Jordán A, Zavala L, Mataix-Solera J, Doerr S. 2013. Soil water repellency: origin, assessment and geomorphological consequences. *Catena*. 108:1–5. <http://www.sciencedirect.com/science/article/pii/S0341816213001057>
- Kargas G, Londra P, Sgoubopoulou A. 2020. Comparison of soil EC values from methods based on 1:1 and 1:5 soil to water ratios and ECe from saturated paste extract based method. *Water*. 12(4):1010. <https://doi.org/10.3390/W12041010>
- Kuhn M. 2008. Building predictive models in R using the caret package. *Journal of Statistical Software*. 28(5):1–26. <https://doi.org/10.18637/jss.v028.i05>
- Lamichhane M, Mehan S, Mankin KR. 2025a. Soil moisture prediction using remote sensing and machine learning algorithms: A Review on Progress, Challenges, and Opportunities. *Remote Sensing*. 17(14):2397. <https://doi.org/10.3390/RS17142397/S1>
- Lundberg SM, Lee SI. 2017. A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*. 2017-December: pp. 4765–4774. <https://arxiv.org/pdf/1705.07874>
- Lusito S, Pugnana A, Guidotti R. 2024. Solving imbalanced learning with outlier detection and features reduction. *Machine Learning*. 113(8):5273–5330. <https://doi.org/10.1007/S10994-023-06448-0/TABLES/24>
- Mahmoudzadeh H, Matinfar HR, Taghizadeh-Mehrjardi R, Kerry R. 2020. Spatial prediction of soil organic carbon using machine learning techniques in western Iran. *Geoderma Regional*. 21:e00260. <https://doi.org/10.1016/J.GEODRS.2020.E00260>
- Marcotte AL, Limpens J, Stoof CR, Stoorvogel JJ. 2022. Can ash from smoldering fires increase peatland soil pH? *International Journal of Wildland Fire*. 31(6):607–620. <https://doi.org/10.1071/WF21150>
- Moghaddam DD, Rahmati O, Haghizadeh A, Kalantari Z. 2020. A Modeling Comparison of Groundwater Potential Mapping in a Mountain Bedrock Aquifer: QUEST, GARP, and RF Models. *Water*. 12(3):679. <https://doi.org/10.3390/W12030679>
- Molnar C. 2020. *Interpretable Machine Learning*. 1st ed. Lulu.com, Morrisville, NC, USA. pp. 1–318. <https://christophm.github.io/interpretable-ml-book>
- Nelson DW, Sommers LE. 1982. Total carbon, organic carbon, and organic matter. In: Page AL, Editor. *Methods of Soil Analysis: Part 2 Chemical and Microbiological Properties*. American Society of Agronomy, Soil Science Society of America. pp. 539–579. <https://doi.org/10.2134/AGRONMONOGR9.2.2ED.C29>
- Padarian J, Minasny B, McBratney AB. 2020. Machine learning and soil sciences: A review aided by machine learning tools. *Soil*. 6(1): 35-52.
- Panyavaraporn J, Horkaew P, Arjwech R, Eua-apiwatch S. 2025. Machine learning approaches for soil moisture prediction using ground penetrating radar: A Comparative Study of Tree-Based Algorithms. *Earth*. 6(3):98. <https://doi.org/10.3390/EARTH6030098>
- Qi L, Li X, Pan Y, Yu T. 2025. Impacts of forest fire on hydro-sediment using the SWAT model: a case study in the Zhangweinan Canal, China. *Acta Geophysica*. 73(5):4761–4780. <https://doi.org/10.1007/S11600-025-01634-1/TABLES/12>
- Rahmati O, Kalantari Z, Samadi M, Uuemaa E, Moghaddam DD, Nalivan OA, Destouni G, Bui DT. 2019. GIS-based site selection for check dams in watersheds: Considering geomorphometric and topo-hydrological factors. *Sustainability*. 11(20):5639. <https://doi.org/10.3390/SU11205639>
- Salmerón-Gómez R, García-García CB, García-Pérez JA. 2020. Overcoming the inconsistencies of the variance inflation factor: A redefined VIF and a test to detect statistical troubling multicollinearity. *Sociological Methods and Research*. 51(1): 150–189. <https://doi.org/10.1177/0049124119882452>
- San-Miguel-Ayanz J, Durrant T, Boca R, Libertà G, Branco A, DE R, Ferrari D, Maianti P, Artes VT, Pfeiffer H. 2018. Luxembourg: publications office of the European Union, European Commission Joint Research Centre. pp. 1–175.
- Shakesby RA, Doerr SH, Walsh RPD. 2000. The erosional impact of soil hydrophobicity:

Current problems and future research directions. *Journal of Hydrology*. 231–232:178–191.

[https://doi.org/10.1016/S0022-1694\(00\)00193-1](https://doi.org/10.1016/S0022-1694(00)00193-1)

Soil Survey Staff. 2014. Keys to soil taxonomy. 12th edition. USDA-Natural Resources Conservation Service, Washington DC.

<https://www.scirp.org/reference/referencespapers?referenceid=1581780>

Then M, Shemehsavar S, Henry DJ, Harper RJ. 2025. The effects of climatic and soil properties on soil water repellency. *Catena*. 258:109218.

<https://doi.org/10.1016/J.CATENA.2025.109218>

Zádorová T, Skála J, Žížala D, Vaněk A, Penížek V. 2021. Harmonization of a large-scale national soil database with the World Reference Base for Soil Resources 2014. *Geoderma*. 384:114819.

<https://doi.org/10.1016/J.GEODERMA.2020.114819>

Zhao G, Gao P, Tian P, Sun W, Hu J, Mu X. 2020. Assessing sediment connectivity and soil erosion by water in a representative catchment on the Loess Plateau, China. *Catena*. 185:104284.

<https://doi.org/10.1016/J.CATENA.2019.104284>



Application of Machine Learning Algorithms in Analyzing the Effect of Fire on Soil Water Repellency in Tushan Watershed, Golestan Province

Kohzad Heidary^{1*}, Ali Najafi Nejad², Ali Mohammadian Behbahani³, Majid Ownegh⁴,
Louis.W. Dekker⁵

- 1- Research Assistant Professor, Soil Conservation and Watershed Management Research Department, Khuzestan Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Ahvaz, Iran
- 2- Professor, Department of Watershed Management, Faculty of Rangeland and Watershed Management, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Golestan, Iran
- 3- Associate Professor, Department of Desert Area Management, Faculty of Rangeland and Watershed Management, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Golestan, Iran
- 4- Professor, Department of Desert Areas Management, Faculty of Rangeland and Watershed Management, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran
- 5- Environmental Sciences Department, Soil Physics and Land management Group, Wageningen University and research, Wageningen, Netherlands

Extended Abstract

Introduction and Goal

In recent decades, forest fires have been recognized as one of the most important environmental threats to forest and rangeland ecosystems. In addition to destroying vegetation and habitats, this phenomenon also severely changes the physical and chemical properties of the soil, the most important of which is the occurrence of the phenomenon of soil water repellency. Soil water repellency can lead to increased surface runoff, reduced permeability, increased erosion, and ultimately reduced ecosystem stability. In recent years, the occurrence of successive and widespread fires in the Hyrcanian forests of northern Iran, particularly in Golestan Province, has caused serious concerns in the field of natural resource management. Despite numerous studies worldwide, domestic research on the effect of fire on soil water repellency, especially the use of new modeling approaches such as machine learning algorithms, is still limited. On the other hand, traditional approaches such as the Water Drop Penetration Time (WDPT) test or ethanol test, although useful for initial identification, cannot model the complex and nonlinear relationships between soil properties and water repellency intensity. Therefore, this study aimed to investigate the temporal changes in soil water repellency after fire and evaluate the power of Machine learning (ML) algorithms in predicting the WDPT index in the Tushan watershed of Golestan Province.

Article Type: Research Article

***Corresponding Authors' E-mail:** k.heidary@areeo.ac.ir

Citation: Heidary, K., Najafi Nejad, A., Mohammadian Behbahani, A., Ownegh, M., Dekker, L.W. 2026. Application of Machine Learning Algorithms in Analyzing the Effect of Fire on Soil Water Repellency in Tushan Watershed, Golestan Province. *Watershed Management Research*. 39(2): 20-43.

DOI: 10.22092/wmrj.2025.370992.1637

Received: 12 October 2025, **Received in revised form:** 27 October 2025, **Accepted:** 21 December 2025

Published online: 22 June 2026

Watershed Management Research, Vol. 39, No. 2, Ser. No. 151, Summer 2026, pp. 20-43.

Publisher: Fars Agricultural and Natural Resources and Education Center

©Author(s)



In addition, this research, while addressing existing scientific limitations, provided a practical tool for managing fire risks and planning post-fire recovery.

Materials and Methods

The study was conducted in the Tushan watershed in Golestan Province, part of the Hyrcanian Forests registered on the UNESCO World Heritage List. The climate of the region is semi-humid to humid, with an average annual rainfall of 620 mm and mean temperature of 16 °C. The soils in the region are mainly loess with silty loam texture and high organic matter content, which provide conditions susceptible to the formation of soil water repellency after fire. The experimental design was factorial and was designed in a completely randomized design with two main factors including land-use type and fire treatment (burned vs. control). Soil samples were collected at three time intervals (one day, one week, and one month after the fire) and at two depths (0–5 and 5–10 cm), and total of 96 samples were collected. Physical and chemical properties of the soil, including texture, pH, EC, OC, OM, aggregate stability, bulk density, were measured. The soil water repellency intensity was measured by the WDPT test. After entering the data into the Python environment, they were preprocessed; outliers were identified using the IQR method but not removed, normalization was performed using Z-score, and the collinearity of variables was checked using VIF. Then, the data was divided into two parts: training (70%) and testing (30%). Twelve ML algorithms were implemented for modeling, including basic, neighborhood-based, aggregate, and hybrid models. Optimization of the hyperparameters was performed using Bayesian search and five-way cross-validation. The performance of the model was evaluated with R^2 , RMSE, MAE, NSE, and CCC indices. In addition, sensitivity analysis was performed using PFI and SHAP methods, and uncertainty analysis was performed using bootstrap and Monte Carlo simulations.

Results and Discussion

The results show that the effect of fire on soil water repellency was severe but short-lived. The average WDPT one day after the fire was 2.5 minutes, indicating a significant increase in water repellency. In the first week, this decreased to less than a minute and after a month, it was almost zero. This finding indicates the transient nature of the effect of fire on soil surface water repellency. Statistical analyses ANOVA showed that the effects of fire treatment and its interaction with time and land-use on WDPT was significant. Among ML models, the best performance was for Decision Tree ($R^2=0.44$) and Gradient Boosting ($R^2=0.43$), while models such as SVM and Bayesian inference were less accurate. The results of sensitivity analysis showed that silt, EC, and OM were the most important variables in predicting WDPT. SHAP results also showed that increasing silt and OM increased water repellency, while increasing EC had a decreasing effect. The uncertainty analysis indicated that simpler models such as Decision Tree were more robust to outliers, while the uncertainty of more complex models increased at extreme WDPT values. Based on these findings, soil water repellency after fire can be predicted more accurately and stably using simple or boosting-based models.

Conclusion and Suggestions

This study demonstrated that the effect of fire on soil water repellency in the Tushan watershed was severe but short-lived, and this effect completely disappeared within one month. By using machine learning algorithms, especially Decision Tree and Gradient Boosting, complex relationships between soil properties and water repellency intensity can be modeled with acceptable accuracy. The results of sensitivity and uncertainty analysis showed that variables such as silt, EC, and OM played an important role in the formation of water repellency. Based on the findings of this study, it is suggested that for post-fire management, soil water repellency should be monitored in the short-term and simple and stable models should be used to predict its changes. In addition, by combining field data and remote sensing data and developing regional models, it is possible to improve fire risk management. As a result, it is suggested that future research should examine the long-term effects of fire on other soil properties and ecosystem functions, and that deep learning algorithms be used to increase the accuracy of predictions.

Keywords: Forest fire, machine learning algorithms, sensitivity analysis, soil water repellency, uncertainty

Article Type: Research Article

Conflicts of interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.

Data Availability Statement

The datasets are available upon a reasonable request to the corresponding author.

Authors' Contribution

Author 1: Software/statistical analyses, Writing – original draft preparation

Author 2: Supervision, editing and reviewing the article, reviewing the results

Author 3: Conceptualization, consulting, reviewing the text of the article, statistical analyses

Author 4: Study design, supervising the implementation of the research, reviewing the text of the article

Author 5: Providing expert guidance, reviewing and editing the article