



Challenges of Applying Emerging Technologies in Sustainable Watershed Management in Iran

Kohzad Heidary ^{1✉} 

1. Corresponding Author, Assistant Professor, Department of Soil Conservation and Watershed Management Research, Khuzestan Agriculture and Natural Resources Research Center, Agricultural Research, Education and Extension Organization, Ahvaz, Iran.
E-mail: kohzad93@gmail.com

Article Info

Article type: Promotional

Article history:

Received: May. 08, 2025

Revised: May. 20, 2025

Accepted: Jul. 24, 2025

Published online: Aug. 03, 2025

Keywords:

*Machine Learning,
Artificial Intelligence,
Soil Aggregate Stability,
Loess Soils,
soil water repellency.*

ABSTRACT

This study aimed to evaluate the performance of machine learning algorithms in predicting soil water repellency intensity in the loess soils of northern Iran, a region prone to water repellency due to its specific soil texture and climatic conditions. A total of 45 surface soil samples were collected from various locations across Golestan and Mazandaran provinces. For each sample, a set of physical and chemical properties—including organic carbon, organic matter, soil texture, aggregate stability, pH, and EC—were measured. The water drop penetration time (WDPT) test was used to quantify the degree of water repellency. Three machine learning algorithms, including Decision Tree (DT), Random Forest (RF), and XGBoost, were applied to model and predict the WDPT index. The results indicated that the XGBoost model outperformed the others, achieving an RMSE of 14.7 and an R² of 0.42. Moreover, organic carbon was identified as the most influential variable. These findings suggest that advanced machine learning algorithms can serve as effective tools for analyzing and predicting nonlinear phenomena in soil studies and watershed management.

Cite this article: Heidary, K., (2025) Challenges of Applying Emerging Technologies in Sustainable Watershed Management in Iran, *Scientific-Promotional Journal of Aquifer*, 19 (1).

Publisher: The University of Tehran Press.



چالش‌های استفاده از فناوری‌های نوین در مدیریت پایدار حوزه‌های آبخیز کشور

کهزاد حیدری^۱

۱. نویسنده مسئول، استادیار پژوهشی بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات، آموزش کشاورزی و منابع طبیعی خوزستان، سازمان آموزش و تحقیقات، خوزستان، ایران. رایانامه: kohzad93@gmail.com

اطلاعات مقاله	چکیده
نوع مقاله: ترویجی	این مطالعه با هدف ارزیابی قابلیت الگوریتم‌های یادگیری ماشین در پیش‌بینی شدت آب‌گریزی خاک، در خاک‌های لسی شمال ایران انجام شد؛ منطقه‌ای که به دلیل بافت ویژه و شرایط اقلیمی، مستعد پدیده آب‌گریزی است. در این پژوهش، ۴۵ نمونه خاک سطحی از مناطق مختلف استان‌های گلستان و مازندران برداشت شد. برای هر نمونه، مجموعه‌ای از ویژگی‌های فیزیکی و شیمیایی از جمله کربن آلی، ماده آلی، بافت خاک، پایداری خاکدانه، EC و pH اندازه‌گیری گردید. شاخص شدت آب‌گریزی با استفاده از آزمون زمان پایداری قطره آب تعیین شد. سه الگوریتم یادگیری ماشین شامل درخت تصمیم، جنگل تصادفی و XGBoost برای مدل‌سازی و پیش‌بینی مقدار WDPT مورد استفاده قرار گرفتند. نتایج نشان داد که مدل XGBoost با RMSE معادل ۱۴/۷ و ضریب تعیین ۰/۴۲ عملکرد بهتری نسبت به سایر مدل‌ها داشت. همچنین، کربن آلی به‌عنوان تأثیرگذارترین متغیر شناسایی شد. این یافته‌ها نشان می‌دهد که الگوریتم‌های پیشرفته یادگیری ماشین می‌توانند ابزار مؤثری برای تحلیل و پیش‌بینی پدیده‌های غیرخطی در مطالعات خاک و مدیریت حوزه‌های آبخیز باشند.
تاریخ دریافت: ۱۴۰۴/۰۴/۱۷	
تاریخ بازنگری: ۱۴۰۴/۰۴/۲۹	
تاریخ پذیرش: ۱۴۰۴/۰۵/۰۲	
تاریخ انتشار: ۱۴۰۴/۰۵/۱۲	
واژه‌های کلیدی: یادگیری ماشین، هوش مصنوعی، پایداری خاکدانه، خاک‌های لسی، آب‌گریزی خاک،	

استناد: حیدری؛ کهزاد، (۱۴۰۴) چالش‌های استفاده از فناوری‌های نوین در مدیریت پایدار حوزه‌های آبخیز کشور، نشریه علمی-ترویجی آبخوان، ۱۹ (۱).

ناشر: مؤسسه انتشارات دانشگاه تهران.

مقدمه

حوزه‌های آبخیز کشور با چالش‌های پیچیده‌ای مواجه هستند که ناشی از تعامل تنگاتنگ عوامل طبیعی و انسانی هستند. تغییرات اقلیمی، نه تنها با افزایش فراوانی و شدت رخداد‌های آستانه‌ای مانند سیلاب‌های ناگهانی و خشکسالی‌های طولانی‌مدت خود را نشان می‌دهد، بلکه موجب تغییر در الگوهای بارش، کاهش منابع آب تجدیدپذیر و تشدید فرسایش آبی و بادی خاک شده است. فرسایش شدید خاک به نوبه خود منجر به کاهش حاصلخیزی اراضی، رسوب‌گذاری در مخازن سدها و کاهش ظرفیت ذخیره آب می‌شود. علاوه بر این، بهره‌برداری بی‌رویه و ناپایدار از منابع آب‌های زیرزمینی و سطحی، به‌ویژه در بخش کشاورزی و همچنین تغییرات نامناسب کاربری اراضی، از جمله مهم‌ترین تهدیدهایی هستند که مدیریت پایدار این حوزه‌ها را به شدت دشوار ساخته‌اند (Humnabadkar et al., 2024). فشار ناشی از رشد روزافزون جمعیت، که پیش‌بینی می‌شود تا سال ۲۰۵۰ به حدود ۱۰ میلیارد نفر در سطح جهان خواهد رسید (Pasika & Gandla, 2020)، تقاضا برای منابع نظیر آب، غذا و زمین را به طور فزاینده‌ای افزایش داده است. این افزایش تقاضا برای بهره‌برداری از اراضی در کاربری‌هایی مانند کشاورزی، شهرسازی و زیرساخت‌های توسعه فشار مضاعفی بر منابع طبیعی وارد کرده و سیاست‌گذاری‌های هوشمندانه و مبتنی بر شواهد علمی و فناورانه را بیش از پیش آشکار ساخته است. در پاسخ به این چالش‌های روبه‌رشد و پیچیده، فناوری‌های نوین و تحول‌آفرین مانند سنجش از دور پیشرفته (با بهره‌گیری از تصاویر ماهواره‌ای با قدرت تفکیک مکانی و زمانی بالا، و داده‌های راداری)، اینترنت اشیا^۱ (IoT) و شبکه‌های حسگر بی‌سیم^۲ (WSNs)، هوش مصنوعی^۳ (AI) و الگوریتم‌های پیشرفته یادگیری ماشین^۴ (ML) به عنوان ابزاری انقلابی و کارآمد در پایش، تحلیل و مدیریت منابع حوزه آبخیز معرفی شده‌اند. این فناوری‌ها قابلیت بی‌نظیری در ثبت و جمع‌آوری داده‌های محیطی به صورت برخط و مداوم با دقت و صحت بی‌سابقه، شناسایی روندهای پنهان و پیش‌بینی دقیق پدیده‌های پیچیده و دینامیکی مانند رواناب، خشکسالی، تغییرات پوشش گیاهی یا تغییرات کاربری اراضی را فراهم می‌کنند (Dachyar et al., 2019; Hong et al., 2021; Pal & Kant, 2015). برخی از این تکنولوژی‌ها در مطالعات اخیر برای پیش‌بینی دقیق وقوع سیلاب، تحلیل پایداری شیب‌ها، ارزیابی کیفیت آب، بهینه‌سازی تخصیص منابع آب و مدل‌سازی اثرات تغییر اقلیم بر منابع آب مورد استفاده قرار گرفته‌اند. علاوه بر این، فناوری‌های نوظهور نظیر دوقلوهای دیجیتال که امکان ایجاد مدل‌های مجازی از حوزه‌های آبخیز برای شبیه‌سازی سناریوها و تصمیم‌گیری‌های لحظه‌ای را فراهم می‌کنند، و بلاک‌چین برای افزایش شفافیت و امنیت در مدیریت داده‌ها و تراکنش‌های مربوط به منابع آب، پتانسیل عظیمی در ارتقاء مدیریت پایدار آبخیزداری دارند (Dachyar et al., 2019; Hong et al., 2021; Pal & Kant, 2015).

با این وجود، اجرای مؤثر این فناوری‌ها در مقیاس وسیع، با چالش‌های متعددی مواجه است. این چالش‌ها شامل کمبود داده‌های با کیفیت، یکپارچه و استاندارد، نیاز به زیرساخت فنی پیشرفته و پر هزینه (مانند مراکز داده، پهنای باند اینترنت قوی، و دسترسی به پلتفرم‌های ابری)، هزینه‌های اولیه بالا برای خرید و پیاده‌سازی سیستم‌ها و همچنین نگهداری آن‌ها و مهم‌تر از همه، کمبود نیروی انسانی متخصص و آموزش‌دیده در حوزه‌های بین‌رشته‌ای مانند هیدرولوژی محاسباتی، سنجش از دور و هوش مصنوعی است (Ismail et al., 2022; Kazeminasab & Banks, 2021). افزون بر این، چالش‌های قابلیت تعامل‌پذیری بین سیستم‌ها و نرم‌افزارهای مختلف و عدم وجود استانداردهای هماهنگ برای یکپارچه‌سازی و تبادل داده‌ها از منابع ناهمگون (مانند داده‌های ماهواره‌ای، سنسورهای زمینی و اطلاعات میدانی)، از دیگر موانع اساسی در توسعه کاربردی و فراگیر این ابزارها به‌شمار می‌روند (Ismail et al., 2022; Kourtesis et al., 2021; Plotnik et al., 2021). موانع سازمانی و حقوقی، مقاومت در برابر تغییر، و نبود چارچوب‌های سیاستی حمایتی و هماهنگ نیز به پیچیدگی این چالش‌ها می‌افزایند. در همین راستا، ارائه نمونه‌های عملی و کاربردی از به‌کارگیری فناوری‌هایی چون یادگیری ماشین در مطالعات میدانی و بومی‌شده، می‌تواند ضمن افزایش اعتبار علمی این رویکردها، راه را برای پذیرش عمومی و سیاست‌گذاری‌های حمایتی هموار سازد. این مقاله با تأکید بر چالش‌های ذکر شده در بستر حوزه‌های آبخیز کشور ایران، یک مطالعه موردی عملی را در زمینه مدیریت پایدار خاک در خاک‌های لسی شمال ایران ارائه می‌دهد. هدف این مطالعه، ارزیابی کارایی الگوریتم‌های یادگیری ماشین (مانند درخت تصمیم، جنگل تصادفی و XGBoost) در پیش‌بینی شدت آب‌گریزی خاک و شناسایی عوامل کلیدی مؤثر بر آن است. این تحلیل در چارچوب

¹Internet of things

²Wireless sensor networks

³Artificial intelligence

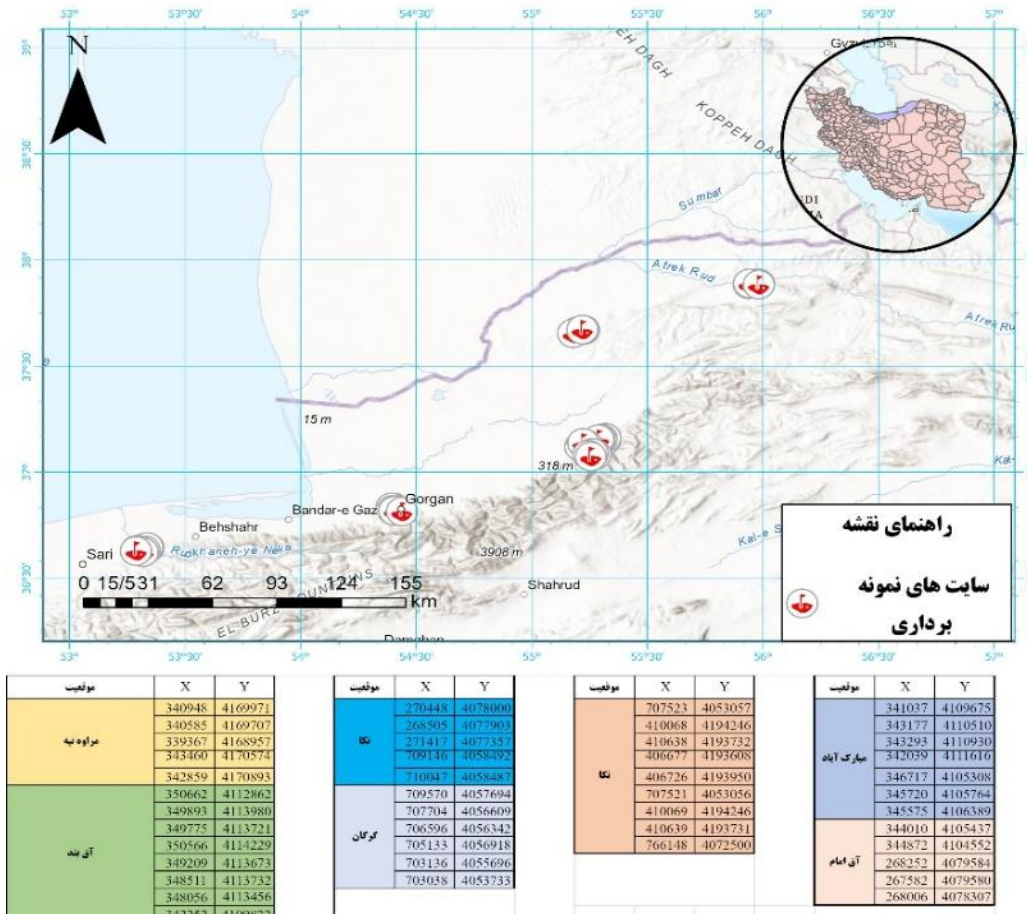
⁴Machine learning

بزرگ‌تری از بحث پیرامون فرصت‌ها و چالش‌های فناوری‌های نوین در مدیریت منابع طبیعی انجام شده است.

مواد و روش‌ها

منطقه مطالعاتی

پژوهش حاضر در بخش‌هایی از استان‌های گلستان و مازندران در شمال ایران انجام گرفت. این منطقه که شامل نقاطی نظیر گرگان، مراوه‌تپه، نکا، ساری و آمل می‌شود، دارای خاک‌های لسی است که از نظر هیدروفیزیکی مستعد پدیده آب‌گریزی هستند. موقعیت دقیق نقاط نمونه‌برداری در شکل ۱ نشان داده شده است.



شکل ۱: منطقه مورد مطالعه و موقعیت نمونه‌برداری‌ها در استان گلستان و مازندران (استخراج از محیط ArcGISPro3.4)

نمونه‌برداری و آماده‌سازی خاک

برای مطالعه آب‌گیری خاک، مجموعاً ۴۵ نمونه خاک سطحی از عمق صفر تا ۱۰ سانتی‌متری در نقاط مختلف منطقه مورد مطالعه جمع‌آوری شد (شکل ۱). پس از انتقال به آزمایشگاه، نمونه‌ها در هوای آزاد خشک شده و سپس برای انجام آزمایش‌های فیزیکی و شیمیایی آماده‌سازی شدند. آماده‌سازی شامل خرد کردن کلوخه‌ها و الک کردن نمونه‌ها برای حذف ذرات درشت‌تر و آماده‌سازی برای آزمایش‌های بعدی بود.

اندازه‌گیری ویژگی‌های فیزیکی و شیمیایی خاک

برای هر نمونه خاک، مجموعه‌ای از ویژگی‌های فیزیکی و شیمیایی که تصور می‌شد بر آب‌گیری خاک تأثیرگذار هستند، اندازه‌گیری شد. این ویژگی‌ها و روش‌های آزمایشگاهی مربوطه در جدول ۱ به شرح زیر است:

جدول ۱. مشخصات ویژگی‌های اندازه‌گیری شده و روش‌های آزمایشگاهی

منبع	روش اندازه‌گیری	ویژگی
(Enang et al., 2018)	روش والکی بلک	کربن آلی (C)
(Nelson & Sommers, 1982)	$1.72 \times C$	ماده آلی (OM)
(Kargas et al., 2020)	عصاره اشباع (1:2.5)	EC و pH
(Beretta et al., 2014)	هیدرومتری بومن	بافت خاک
(Almajmaie et al., 2017)	غربالی تر	پایداری خاکدانه (MWD)
(Doerr & Shakesby, 2011)	زمان نفوذ قطره $\mu\text{L}25$	WDPT ¹

سنجش شدت آب‌گریزی خاک (WDPT)

شدت آب‌گریزی خاک با استفاده از آزمون استاندارد زمان پایداری قطره آب اندازه‌گیری شد. در این آزمون، یک قطره آب مقطر با حجم ۵۰ میکرولیتر بر روی سطح خاک قرار داده شد و زمان لازم برای نفوذ کامل آن به داخل خاک با استفاده از کروномتر ثبت گردید. بر اساس زمان نفوذ، شدت آب‌گریزی خاک طبقه‌بندی شد. طبقه‌بندی مورد استفاده در این مطالعه در **Error! Reference source not found.** نشان داده شده است، که در آن زمان نفوذ بیش از ۶۰۰ ثانیه به عنوان آب‌گریزی بسیار قوی در نظر گرفته شد (Doerr & Shakesby, 2011).

جدول ۲. طبقه‌بندی شدت آب‌گریزی بر اساس زمان نفوذ قطره

وضعیت آب‌گریزی	زمان نفوذ (ثانیه)
آب‌گریز نیست	< 5
ضعیف	5-60
متوسط	60-180
قوی	180-600
بسیار قوی	> 600

پیش‌پردازش داده‌ها

پس از جمع‌آوری و اندازه‌گیری تمامی داده‌ها، مراحل پیش‌پردازش زیر بر روی آن‌ها انجام شد:

- حذف متغیرهای بی‌اهمیت: متغیرهای غیرمرتبط مانند مختصات جغرافیایی که به طور مستقیم در مدل‌سازی تأثیری نداشتند، حذف شدند.
- بررسی و مدیریت داده‌های پرت: داده‌های پرت با استفاده از روش دامنه میان چارکی شناسایی و مدیریت شدند.
- نرمال‌سازی داده‌ها: تمامی متغیرهای عددی با استفاده از روش Z-score نرمال‌سازی شدند تا مقیاس‌های مختلف متغیرها تأثیری بر عملکرد مدل‌های یادگیری ماشین نداشته باشند.
- تقسیم داده‌ها: مجموعه داده‌ها به دو بخش آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند تا مدل‌ها بر روی داده‌های آموزشی توسعه یافته و عملکرد آن‌ها بر روی داده‌های جدید و داده‌های آزمون ارزیابی شود.

تحلیل همبستگی

به منظور بررسی روابط بین متغیرهای عددی اندازه‌گیری شده، ماتریس همبستگی ترسیم شد. این تحلیل به شناسایی همبستگی‌های مثبت یا منفی بین ویژگی‌های خاک نظیر کربن آلی، ماده آلی، درصد رس، شن و سیلت با زمان نفوذ قطره آب (WDPT) کمک می‌کند. این ماتریس به برجسته شدن نقش متغیرهای کلیدی در پیش‌بینی آب‌گریزی خاک کمک کرده و مبنایی برای انتخاب ویژگی‌ها در مدل‌سازی فراهم آورد.

مدل‌سازی با یادگیری ماشین

در این مطالعه، برای پیش‌بینی زمان پایداری قطره آب به عنوان شاخص شدت آب‌گریزی خاک، از سه الگوریتم یادگیری ماشین در محیط برنامه‌نویسی R استفاده شد:

۱. درخت تصمیم: این مدل به دلیل سادگی و قابلیت تفسیرپذیری بالا، برای شناسایی آستانه‌ها و عوامل اصلی مؤثر بر آب‌گریزی مورد استفاده قرار گرفت. درختی تصمیم (CART) برای پیش‌بینی WDPT و همچنین طبقه‌بندی سطوح آب‌گریزی (WDPT_class) به کار

¹ Water Drop Penetration Time

رفت.

ii. جنگل تصادفی: این مدل که یک روش ensembles مبتنی بر درختان تصمیم است، برای بهبود دقت پیش‌بینی و کاهش بیش‌برازش (Overfitting) به کار گرفته شد.

iii. XGBoost: این الگوریتم، به عنوان یکی از پیشرفته‌ترین و کارآمدترین روش‌های یادگیری ماشین در مسائل رگرسیون و طبقه‌بندی، برای دستیابی به بالاترین دقت پیش‌بینی مورد بررسی قرار گرفت.

ارزیابی عملکرد مدل‌ها

عملکرد مدل‌ها با استفاده از معیارهای آماری رایج شامل ریشه میانگین مربعات خطا (RMSE) و ضریب تعیین (R^2) ارزیابی شد تا دقت پیش‌بینی کمی (برای WDPT) و قابلیت طبقه‌بندی آن‌ها (برای WDPT_class) مشخص گردد.

نتایج و بحث

تحلیل آماری توصیفی داده‌های جمع‌آوری شده (شامل کربن آلی، ماده آلی، pH، EC، بافت خاک، پایداری خاکدانه و WDPT) نشان‌دهنده تنوع قابل توجهی در ویژگی‌های فیزیکی و شیمیایی خاک در منطقه مورد مطالعه است (جدول ۳).

جدول ۳. شاخص‌های آماری توصیفی متغیرهای اندازه‌گیری شده در نمونه‌های خاک منطقه مطالعه

متغیر	میانگین	میان	انحراف معیار	حداقل	حداکثر	چولگی	کشیدگی
C (%)	۱/۵۱	۱/۱۷	۱/۱۰	۰/۱۶	۴/۶۸	-۰/۸۸	۰/۰۹
OM (%)	۲/۶	۲/۰۱	۱/۸۹	۰/۲۷	۸/۰۵	-۰/۸۸	-۰/۰۹
EC (dS/m)	۲/۲۷	۱/۱۵	۳/۳۲	۰/۵۹	۱۹/۳۵	۳/۶۰	۱۳/۹۸
pH	۷/۳۴	۷/۴۰	۰/۱۹	۶/۸۹	۷/۷۰	-۰/۴۷	-۰/۵۸
MWD (mm)	۸/۱۵	۵/۶۹	۶/۴۷	۰/۲۶	۲۶/۸۲	۱/۲۳	۰/۹۱
شن (%)	۲۸/۶۷	۲۵/۸۰	۱۲/۳۴	۱۳/۸۰	۶۵/۸۰	۱/۰۸	۰/۶۴
رس (%)	۱۷/۵۴	۱۶/۸۰	۶/۲۲	۶/۸۰	۳۰/۸۰	-۰/۲۷	-۰/۶۸
سیلت (%)	۵۳/۷۹	۵۳/۴۰	۱۰/۳۵	۲۷/۴۰	۷۱/۴۰	-۰/۴۵	-۰/۵۷
WDPT (ثانیه)	۲۱/۴۰	۱۹	۱۵/۴۹	۳	۶۴	۱/۱۱	۰/۵۱


این تنوع، به‌ویژه در متغیرهایی مانند EC، MWD و WDPT که دارای چولگی و کشیدگی بالا هستند، اهمیت استفاده از روش‌های آماری مقاوم و مدل‌های یادگیری ماشین را که توانایی مدیریت داده‌های پرت و روابط غیرخطی را دارند، برجسته می‌سازد. با توجه به این امر، داده‌های پرت شناسایی شده در نمودارهای باکس پلات (شکل ۲) حذف نشدند، بلکه مدل‌های یادگیری ماشین مقاوم به آن‌ها (نظیر جنگل تصادفی و درخت تصمیم) به کار گرفته شدند تا از حفظ اطلاعات ارزشمند موجود در داده‌ها اطمینان حاصل شود (Kuhn & Johnson, 2013; Liaw & Wiener, 2002).

تحلیل همبستگی بین ویژگی‌های عددی خاک

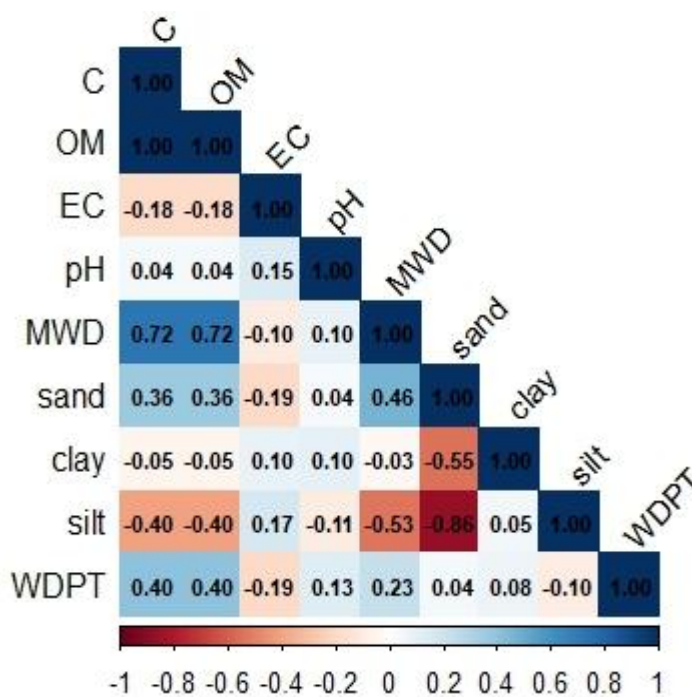
برای بررسی روابط بین ویژگی‌های خاک، از تحلیل همبستگی پیرسون استفاده شد. نتایج نشان داد که ماده آلی و کربن آلی همبستگی مثبت و نسبتاً قوی با میانگین وزنی قطر خاک‌دانه‌ها دارند، که بیانگر نقش آن‌ها در افزایش پایداری خاک است. همچنین، درصد رس با ماسه همبستگی منفی قابل توجهی نشان داد، و درصد سیلت اغلب همبستگی منفی ضعیفی با سایر ویژگی‌ها داشت. شاخص آب‌گریزی خاک نیز رابطه مثبتی با کربن و ماده آلی نشان داد ($r \approx 0.40$)، که می‌تواند نشان‌دهنده تأثیر مواد آلی در افزایش آب‌گریزی در برخی شرایط خاص باشد. این نتایج بر اهمیت نقش ماده آلی و کربن در رفتار فیزیکی خاک تأکید دارد.

مدل‌سازی آب‌گریزی خاک با الگوریتم‌های یادگیری ماشین

در این مطالعه، به‌منظور پیش‌بینی شاخص پایداری قطره آب به عنوان شاخصی از آب‌گریزی خاک، سه الگوریتم یادگیری ماشین شامل درخت تصمیم، جنگل تصادفی و XGBoost در خاک‌های لسی شمال ایران به کار گرفته شد. داده‌های ورودی شامل ۴۵ نمونه خاک با ۹ ویژگی فیزیکی و شیمیایی اندازه‌گیری شده بودند. عملکرد مدل‌ها با استفاده از معیارهای RMSE و ضریب تعیین (R^2) ارزیابی شد.



شکل ۱: نمودار باکس پلات توزیع متغیرهای فیزیکی و شیمیایی خاک

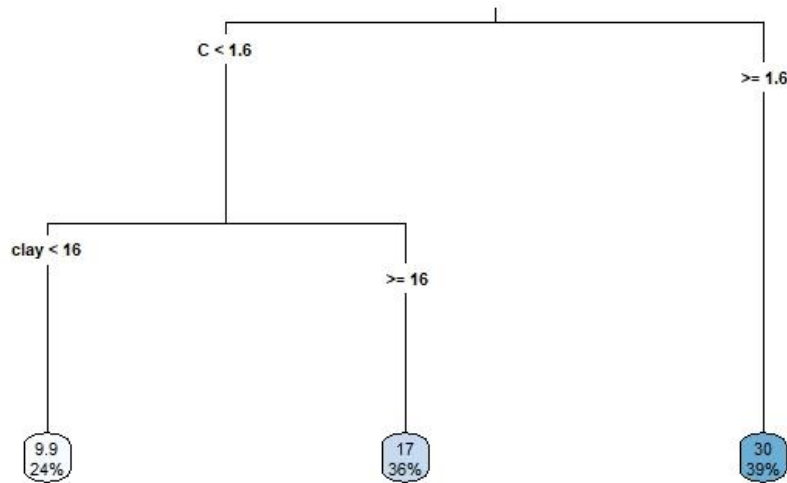


شکل ۲: ماتریس همبستگی بین ویژگی‌های فیزیکی و شیمیایی خاک

مدل درخت تصمیم (DT)

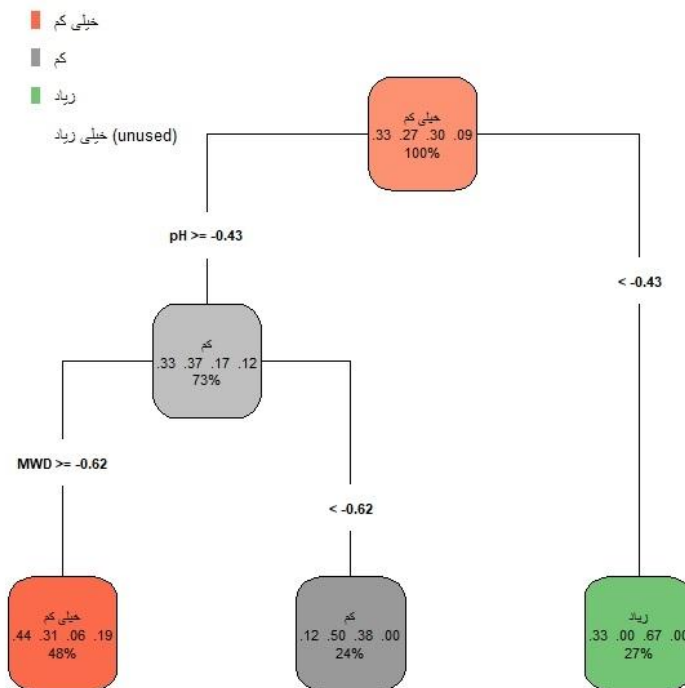
مدل درخت تصمیم (CART) به عنوان الگوریتم پایه، ساختاری ساده از روابط بین متغیرهای خاکی و WDPT ارائه داد (شکل ۴). تحلیل گره‌های مدل نشان داد که کربن آلی (C) با آستانه ۱/۶ درصد، مهم‌ترین عامل مؤثر در تعیین میزان آب‌گیری خاک است. در مقادیر کمتر از این آستانه، درصد رس به‌عنوان متغیر مکمل عمل می‌کند. ساختار مدل در شکل ۴ ارائه شده است. این الگو با یافته‌های پژوهش‌هایی چون Doerr et al., (2000) و Urbanek et al (2007) همخوانی دارد که کربن آلی را به‌عنوان عامل تقویت‌کننده آب‌گیری، به‌ویژه در خاک‌های سبک یا کم‌ساختار گزارش کرده‌اند. در پژوهش Rahmati et al., (2021) نیز همین روند در خاک‌های لسی ایران تأیید شده است. با این حال، برخی مطالعات نظیر Benito et al., (2013) نشان داده‌اند که نوع و منشأ مواد آلی (گیاهی یا سوخته‌شده) می‌تواند

اثرگذاری متفاوتی در رفتار آب‌گریزی ایجاد کند.



شکل ۴: درخت تصمیم حاصل از مدل CART برای پیش‌بینی WDPT

با وجود ارائه تفسیر مفهومی، عملکرد پیش‌بینی کمی این مدل ضعیف بود ($RMSE \approx 55.19$ و $R^2 = 0.02$) در طبقه‌بندی WDPT به کلاس‌های آب‌گریزی نیز، متغیرهای pH و میانگین وزنی قطر خاکدانه‌ها (MWD) به عنوان متغیرهای کلیدی شناسایی شدند (شکل ۵).



شکل ۵: نمودار درخت تصمیم برای طبقه‌بندی WDPT_class بر اساس متغیرهای خاکی

مدل جنگل تصادفی

با اعمال تنظیمات پارامتری (افزایش تعداد درخت‌ها و انتخاب مناسب mtry)، مدل RF به عملکرد قابل قبولی دست یافت ($RMSE = 15$ و $R^2 = 0.42$) بر اساس تحلیل اهمیت متغیرها، کربن آلی (C)، درصد شن و ماده آلی به ترتیب مهم‌ترین عوامل پیش‌بینی WDPT بودند. این مدل به دلیل قابلیت خودکار در تشخیص تعامل‌های غیرخطی بین متغیرها، نسبت به DT دقت بیشتری داشت. یافته‌های این بخش با نتایج Liaw & Wiener., (2002) درباره قدرت الگوریتم RF در مدل‌سازی داده‌های محیطی همخوان است. در مطالعات مشابه، مانند پژوهش Araya et al., (2022) در مناطق مدیترانه‌ای، مدل RF نیز بهترین عملکرد را در پیش‌بینی کلاس‌های آب‌گریزی خاک داشت.

قدرت این مدل در شناسایی آستانه‌های حساس متغیرها، به‌ویژه در داده‌های کوچک، مزیت ویژه آن است.

مدل XGBoost

مدل XGBoost پس از تنظیم دقیق پارامترهایی نظیر η ، \max_depth و n_rounds ، بهترین عملکرد را در میان مدل‌ها ارائه داد (RMSE = 14.7 و $R^2 = 0.42$) تحلیل حساسیت متغیرها نشان داد که کربن آلی (C) با اختلاف زیاد نسبت به سایر عوامل، مهم‌ترین متغیر ورودی بود و پس از آن رس، pH و شن قرار گرفتند. این عملکرد در تطابق با یافته‌های Zhao et al., (2020) (۲۰۲۰) و Haghghi et al., (2021) قرار دارد که در تحلیل ویژگی‌های هیدرولوژیک خاک، XGBoost را به‌عنوان الگوریتمی با توان تفکیک بالا و مقاومت در برابر بیش‌برازش معرفی کرده‌اند. به‌ویژه در شرایطی با تعداد نمونه محدود و ویژگی‌های غیرخطی، XGBoost نسبت به مدل‌های سنتی عملکرد بهتری داشته است.

ارزیابی عملکرد مدل‌ها

مقایسه نهایی عملکرد سه مدل در جدول ۴ ارائه شده است:

جدول ۴. مقایسه آماری عملکرد مدل‌های یادگیری ماشین در پیش‌بینی WDPT

متغیرهای کلیدی	R ²	RMSE	مدل
MWD ,pH ,Clay ,C	۰/۰۲	۵۵/۱۹	درخت تصمیم (DT)
OM ,Sand ,C	۰/۴۲	۱۵/۰۰	جنگل تصادفی (RF)
Sand ,pH ,Clay ,C	۰/۴۲	۱۴/۷۰	XGBoost

به‌طور کلی، دو مدل پیشرفته‌تر RF و XGBoost توانایی بالاتری در شناسایی الگوهای پیچیده آب‌گریزی خاک از خود نشان دادند. این نتیجه اهمیت بهینه‌سازی پارامترها و انتخاب مدل مناسب با توجه به ماهیت غیرخطی متغیر وابسته را تقویت می‌کند.

نتیجه‌گیری و پیشنهادها

این مطالعه با هدف ارزیابی کارایی الگوریتم‌های یادگیری ماشین در پیش‌بینی آب‌گریزی خاک، با استفاده از شاخص زمان نفوذ قطره آب، در خاک‌های لسی شمال ایران انجام شد؛ منطقه‌ای که به‌واسطه ویژگی‌های زمین‌شناختی و اقلیمی خود، حساسیت بالایی به تخریب‌های هیدرولوژیکی دارد. این بررسی در چارچوب کلان‌تری از بحث پیرامون نقش و چالش‌های فناوری‌های نوین در مدیریت حوزه‌های آبخیز در کشورهای در حال توسعه قرار گرفت. نتایج نشان داد که از میان سه الگوریتم بررسی شده (درخت تصمیم، جنگل تصادفی و XGBoost)، مدل‌های مبتنی بر تجمیع (RF و XGBoost) عملکرد به‌مراتب بهتری نسبت به مدل پایه (DT) داشتند. مقدار خطای RMSE در این دو مدل حدود ۱۴/۷ تا ۱۵ و ضریب تعیین (R^2) معادل ۰/۴۲ به‌دست آمد. در تمامی مدل‌ها، کربن آلی به‌عنوان تأثیرگذارترین متغیر در پیش‌بینی WDPT شناسایی شد، و پس از آن، درصد رس، pH و شن، بسته به ساختار مدل، نقش مکمل ایفا کردند. این نتایج با یافته‌های پژوهش‌های پیشین در زمینه نقش ماده آلی در رفتار آب‌گریزی خاک، به‌ویژه در مناطق با شیب و بافت حساس، هم‌راستاست. تحلیل مدل‌ها همچنین نشان داد که روابط بین ویژگی‌های خاکی و آب‌گریزی، به‌طور معناداری غیرخطی و چندمتغیره هستند. این ویژگی‌ها باعث می‌شوند که مدل‌های آماری سنتی در شناسایی الگوهای پنهان دقت کافی نداشته باشند؛ در حالی که الگوریتم‌های یادگیری ماشین، با توانایی در تحلیل روابط پیچیده و تعاملی، ابزار مناسبی برای پیش‌بینی پدیده‌های دینامیکی در مطالعات منابع طبیعی به‌شمار می‌آیند. با وجود نتایج امیدوارکننده، این مطالعه به چالش‌های مهمی نیز اشاره دارد. محدودیت حجم نمونه (۴۵ سایت)، ناهمگنی مکانی داده‌ها، و محدودیت‌های پردازشی، بیانگر نیاز به زیرساخت‌های داده‌ای قوی، توسعه همکاری‌های میان‌رشته‌ای، و فراهم‌سازی ابزارهای یادگیری ماشین متناسب با نیازهای علوم محیطی است. افزون‌براین، موفقیت فنی مدل‌ها به‌تنهایی برای انتقال آن‌ها به فرآیند تصمیم‌گیری مدیریتی کافی نیست. استفاده عملی از این مدل‌ها نیازمند تقویت جنبه‌های تفسیرپذیری، قابلیت بصری‌سازی نتایج و ارتقاء ظرفیت نهادی کاربران نهایی است. در مجموع، تلفیق یادگیری ماشین در مدیریت حوزه‌های آبخیز، نویدبخش افق جدیدی در پیش‌بینی فرآیندهای محیطی و طراحی مداخلات حفاظتی است. با این حال، تحقق کامل این ظرفیت‌ها تنها زمانی ممکن خواهد بود که عملکرد الگوریتم‌ها با بسترهای نهادی، داده‌ای و آموزشی مناسب پشتیبانی شود. به این ترتیب، یادگیری ماشین نه‌فقط به‌عنوان یک ابزار تحلیلی، بلکه به‌عنوان یکی از



اجزای کلیدی سامانه تصمیم‌یار در مدیریت پایدار منابع آب و خاک قابل بهره‌برداری خواهد بود.

REFERENCE

- Almajmaie, A., Hardie, M., Acuna, T., & Birch, C. (2017). Evaluation of methods for determining soil aggregate stability. *Soil and Tillage Research*, 167, 39–45 .
- Beretta, A. N., Silbermann, A. V., 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 Investigacion Agraria*, 41(2), 263–271 .
- Dachyar, M., Zagloel, T. Y. M., & Saragih, L. R. (2019). Knowledge growth and development: internet of things (IoT) research, 2006–2018. *Heliyon*, 5 .(۸)
- Doerr, S. H., & Shakesby, R. A. (2011). Handbook of Soil Sciences Properties and Processes, second edition. In *Handbook of Soil Sciences Properties and Processes*, second edition (pp. 515–525). CRC press, Taylor and Francis group .
- Enang, R. K., Yerima, B. P. K., Kome, G. K., & 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 .
- Hong, W. J., Shamsuddin, N., Abas, E., Apong, R. A., Masri, Z., Suhaimi, H., Gödeke, S. H., & Noh, M. N. A. (2021). Water Quality Monitoring with Arduino Based Sensors. *Environments 2021*, Vol. 8, Page 6, 8(1), 6 .
- Humnabdkar, A., Karve, A., Shivbhakta, B., & A. Kokate, A. (2024). Advanced Technologies for Sustainable Water Management: A Comprehensive Review. *International Journal For Multidisciplinary Research*, 6 .(۵)
- Ismail, S., Dawoud, D. W., Ismail, N., Marsh, R., & Alshami, A. S. (2022). IoT-Based Water Management Systems: Survey and Future Research Direction. *IEEE Access*, 10, 35942–35952 .
- 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 E_{Ce} from Saturated Paste Extract Based Method. *Water 2020*, Vol. 12, Page 1010, 12(4), 1010 .
- Kazeminasab, S., & Banks, M. K. (2021). A Localization and Navigation Method for an In-Pipe Robot in Water Distribution System Through Wireless Control Towards Long-Distance Inspection. *IEEE Access*, 9, 117496–117511 .
- Kourtesis, P., Collina, S., Dumas, L. A. A., & MacPherson, S. E. (2021). Validation of the Virtual Reality Everyday Assessment Lab (VR-EAL): An Immersive Virtual Reality Neuropsychological Battery with Enhanced Ecological Validity. *Journal of the International Neuropsychological Society*, 27(2), 181–196 .
- Kuhn, M., & Johnson, K. (2013). Applied predictive modeling. *Applied Predictive Modeling*, 1–600. <https://doi.org/10.1007/978-1-4614-6849-3/COVER>
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R News*, 2(3), 18–22.
- Nelson, D. W., & Sommers, L. E. (1982). Total Carbon, Organic Carbon, and Organic Matter. 539–579 .
- Pal, A., & Kant, K. (2015). Water flow Driven Sensor Networks for leakage and contamination monitoring. *Proceedings of the WoWMoM 2015: A World of Wireless Mobile and Multimedia Networks* .
- Pasika, S., & Gandla, S. T. (2020). Smart water quality monitoring system with cost-effective using IoT. *Heliyon*, 6 .(۷)
- Plotnik, M., Ben-Gal, O., Doniger, G. M., Gottlieb, A., Bahat, Y., Cohen, M., Kimel-Naor, S., Zeilig, G., & Beeri, M. S. (2021). Multimodal immersive trail making-virtual reality paradigm to study cognitive-motor interactions. *Journal of NeuroEngineering and Rehabilitation*, 18(1).