

مدل سازی هدایت هیدرولیکی بستر رودخانه های فصلی در مناطق خشک و نیمه خشک با استفاده از یادگیری ماشین: ارزیابی عملکرد و تحلیل حساسیت

چکیده

هدایت هیدرولیکی عمودی بستر رودخانه های فصلی یکی از پارامترهای کلیدی در تبادل جریان سطحی - زیرسطحی و مدیریت منابع آب در مناطق خشک و نیمه خشک است، با این حال اندازه گیری مستقیم آن با هزینه، زمان و عدم قطعیت بالا همراه می باشد. هدف این پژوهش، توسعه و ارزیابی یک چارچوب مبتنی بر یادگیری ماشین برای پیش بینی هدایت هیدرولیکی عمودی بستر با تأکید بر نقش ناهمگنی های مورفولوژیکی شامل کانال اصلی و پشته های رسوبی با درک رفتار رودخانه های فصلی است. بدین منظور، مدل های مبتنی بر تقویت با استفاده از داده های دانه بندی، شاخص های ساختاری بستر و پارامترهای هیدرولیکی توسعه داده شد. عملکرد مدل ها با سه روش اعتبارسنجی ارزیابی شد. نتایج نشان داد که مدل منتخب در داده های آزمون به مقادیر ضریب تعیین بالاتر از 0.85 دست یافته است. تحلیل عدم قطعیت بیانگر آن بود که بازه های اطمینان 95 درصد پیش بینی ها محدود بوده و نرخ برد مدل در اغلب سناریوهای اعتبارسنجی بیش از 85 درصد است. مقایسه عملکرد مدل در واحدهای مورفولوژیکی مختلف نشان داد که پیش بینی هدایت هیدرولیکی در پشته های رسوبی نسبت به کانال اصلی از پایداری بیشتری برخوردار بوده، به گونه ای که انحراف معیار نتایج آزمون بسته به روش اعتبارسنجی بین 10 تا 50 درصد کمتر گزارش شده است. نتایج تحلیل حساسیت حاکی از آن است که پارامترهای A_r و m_p به همراه صدک ریز دانه بندی (d_{10}) مهم ترین عوامل کنترل کننده هدایت هیدرولیکی عمودی هستند. یافته های این پژوهش نشان می دهد که تلفیق یادگیری ماشین با تحلیل مبتنی بر مورفولوژی می تواند رویکردی کارآمد برای برآورد هدایت هیدرولیکی بستر رودخانه های فصلی و کاهش عدم قطعیت در مطالعات هیدرولوژیکی فراهم کند.

کلمات کلیدی: یادگیری ماشین، هدایت هیدرولیکی، رودخانه های فصلی، تحلیل حساسیت

۱- مقدمه

در دنیای امروز که تغییرات اقلیمی، افزایش جمعیت و فشارهای صنعتی بر منابع آب تشدید شده، درک دقیق فرآیندهای هیدرولوژیکی زیرسطحی بیش از پیش ضروری است. هدایت هیدرولیکی عمودی بستر رودخانه (K_v) یکی از پارامترهای اساسی در این بخش است که نقش کلیدی در جریان آب زیرزمینی، حمل و نقل آلاینده‌ها و تعاملات آب سطحی-زیرزمینی ایفا می‌کند (Bear, 1972). این پارامتر در معادله پایه‌ای دارسی $q = -K_v \nabla h$ (که q شار ویژه آب، و ∇h گرادیان هیدرولیکی است) ظاهر می‌شود و سرعت و جهت جریان را تعیین می‌کند. K_v نه تنها بر سرعت جریان تأثیر می‌گذارد، بلکه بر زمان‌های رسیدن آلاینده‌ها به آبخوان‌ها، الگوهای توزیع رسوبات و حتی حفاظت از منابع آب شیرین نقش دارد.

در مناطق خشک و نیمه‌خشک، که بیش از ۴۰٪ سطح زمین را پوشش می‌دهند (شامل بخش‌های وسیعی از ایران مانند استان خراسان رضوی است)، بارش سالانه کم (کمتر از ۲۵۰ mm) و تبخیر بالا (تا ۲۰۰۰ mm/year) منجر به وابستگی شدید به رودخانه‌های فصلی برای تغذیه آبخوان‌ها می‌شود (Shanfield and Cook, 2014). این رودخانه‌ها اغلب جریان‌های سریع^۱ دارند که رسوبات را به سرعت جابه‌جا می‌کنند و ساختار بستر را تغییر می‌دهند. بستر رودخانه نقش دروازه‌ای برای تبادل آب سطحی-زیرزمینی ایفا می‌کند، جایی که K_v توسط عوامل بافتی (مانند PSD^2) و ساختاری (مانند زره‌پوشی^۳) کنترل می‌شود (Datry et al., 2017). برای مثال، زره‌پوشی سطحی که نسبت $A_r = d_{50,surf}/d_{50,subsurf}$ را افزایش می‌دهد، K_v را افزایش می‌دهد (Karrabi and Tabatabai, 2025). همچنین، درصد گل^۴ (m_p) رسوبات کمتر از ۰/۰۶۲۵ mm فضاهای منفذی را مسدود می‌کند و نفوذ را کم می‌کند (Rosas et al., 2015). اندازه‌گیری مستقیم K_v چالش‌های متعددی دارد. روش‌های میدانی مانند آزمایش‌های پمپاژ میانگین‌های فضایی بزرگ ارائه می‌دهند اما هزینه‌بر، نیروی کار فشرده و حساس به شرایط محلی هستند (Genereux et al., 2008). آزمایش‌های نفوذپذیری بار افتان^۵ و بار ثابت^۶ نیاز به نمونه‌های دست‌نخورده دارند و برای رسوبات ناهمگن نامناسب هستند (Hiscock and Bense, 2021). در نتیجه، K_v اغلب از PSD با روابط تجربی برآورد می‌شود. روابط کلاسیک مانند Hazen (1892)، یا Kozeny (1953) برای رسوبات شنی تمیز توسعه یافته‌اند اما در رسوبات سیلتی/رسی شکست می‌خورند (Cabalar and Akbulut, 2016; Chandel and Shankar, 2022). بر اساس تحقیقات انجام شده، به نظر می‌رسد

فرمول‌های کاربردی برای ارزیابی اولیه K_v بستر مناسب باشند. با این حال، با توجه به تفاوت در مقادیر میانگین K_v محاسبه‌شده، نتایج برای تجزیه و تحلیل‌های با وضوح بالا از تغییرات K_v مورد نیاز برای مدل‌سازی جریان یا انتقال، به اندازه کافی قابل اعتماد نیستند (Vienken and Dietrich, 2011). در مطالعه (Karrabi and Tabatabai, 2025)، یک مدل تجربی جدید برای K_v در رودخانه‌های فصلی پیشنهاد شد که عوامل A_r ، m_p و d_{10} را در بر می‌گیرد. با این حال، این مدل همچنان از روابط غیرخطی و تغییرات مکانی غفلت می‌کند و برای زیرگروه‌های مورفولوژیکی (کانال اصلی^۷ و پشته رسوبی^۸) تفکیک نشده است. مورفولوژی بستر تأثیر قابل توجهی دارد: در کانال اصلی، جریان سریع‌تر منجر به رسوبات درشت‌تر و K_v بالاتر می‌شود (تا ۱۰ مرتبه بزرگی بیشتر)، در حالی که در پشته‌های رسوبی، رسوب‌گذاری ریز و فشردگی، K_v را کاهش می‌دهد (Korus et al., 2020). این رفتار به دینامیک رسوبات و ویژگی‌های جریان نیز وابسته بوده و محرک‌های مهم در ناپایداری هدایت هیدرولیکی بستر محسوب می‌شوند.

یادگیری ماشین (ML)^۹ به عنوان ابزاری قدرتمند برای مدل‌سازی روابط پیچیده در علوم زمین و هیدرولوژی ظاهر شده است (Tahmasebi et al., 2020). در مطالعه (De Rijk et al., 2025)، شش الگوریتم ML برای پیش‌بینی K از PSD استفاده شد و نتایج آنان نشان داد الگوریتم‌های مبتنی بر درخت مانند جنگل تصادفی (RF)^{۱۰} و گرادپان تقویت شده (XGBoost)^{۱۱} برای پیش‌بینی مناسب‌ترین هستند، اما تمرکز صرفاً بر PSD^{12} بود و تحلیل حساسیت محدود به اهمیت ویژگی بود. مطالعات دیگر مانند (Araya and Ghezzehei, 2019) ۲۷۰۰۰ نمونه از ویژگی‌های بافتی و ساختاری از یک پایگاه داده بزرگ برای توسعه PTF^{13} های مبتنی بر یادگیری ماشین عمومی برای تخمین K_s بکار گرفتند. نتایج آنان نشان داد مدل‌های BRT^{14} نسبت به سایر الگوریتم‌های یادگیری ماشین که مدل‌های جنگل تصادفی با فاصله کمی پس از آنها قرار دارند، عملکرد بهتری داشتند. آنان اشاره کردند که این روابط عملکردی، پتانسیل این را نشان می‌دهند که چنین مدل‌هایی را می‌توان در مدل‌های سطح زمین و سیستم‌های خاک گنجانده و برای در نظر گرفتن حساسیت نفوذ و جریان آب به تغییرات و اختلالات ساختاری خاک (به عنوان مثال، تجمع مواد آلی یا شخم) استفاده کرد.

(Jorda et al., 2015) نشان دادند که یک تکنیک یادگیری ماشین (درخت‌های رگرسیون تقویت‌شده) افزایش قابل توجهی در عملکرد پیش‌بینی توابع انتقالی خاک برای هدایت هیدرولیکی اشباع و نزدیک به اشباع نسبت به رگرسیون‌های خطی چندگانه ساده ارائه می‌دهد. آنان همچنین دریافتند که اعتبارسنجی منبع^{۱۵} برای دستیابی به تخمین‌های واقع‌بینانه از عملکرد پیش‌بینی توابع انتقالی خاک ضروری است. اگر داده‌های منابع داده منفرد در مجموعه داده‌های آموزشی و اعتبارسنجی مخلوط شوند، عملکرد پیش‌بینی

مدل‌های آنان به شدت بیش از حد تخمین زده می‌شود. (Granata et al., 2022) از پنج مدل مختلف برای پیش‌بینی هدایت هیدرولیکی اشباع با استفاده از مجموعه داده‌های استخراج‌شده از پایگاه داده جهانی نفوذ آب خاک استفاده کردند. مدل‌ها بر اساس پیش‌بینی‌کننده‌های مختلف بودند. هفت نوع از هر مدل با جایگزینی الگوریتم پیاده‌سازی شده مقایسه شدند. سه نوع بر اساس مدل‌های منفرد بودند، در حالی که چهار نوع بر اساس مدل‌های مختلط بودند. الگوریتم‌های یادگیری ماشین منفرد مورد استفاده، پرسپترون چندلایه (MLP)^{۱۶}، جنگل تصادفی و ماشین‌های بردار پشتیبان (SVM)^{۱۷} بودند. مدل مبتنی بر بیشترین تعداد پیش‌بینی‌کننده‌ها منجر به دقیق‌ترین پیش‌بینی‌ها شد. علاوه بر این، در تمام مدل‌ها، گونه‌های ترکیبی مبتنی بر هر سه الگوریتم و گونه‌های ترکیبی جنگل تصادفی و رگرسیون بردار پشتیبان دقیق‌ترین بودند. با این حال، همه گونه‌ها تمایل به تخمین بیش از حد هدایت هیدرولیکی در خاک‌هایی که هدایت هیدرولیکی بسیار کم است، نشان دادند.

قابلیت تفسیر مدل به عنوان یک الزام حیاتی برای کاربردهای یادگیری ماشین در مهندسی ظهور کرده است، زیرا درک مکانیسم‌های فیزیکی زیربنای پیش‌بینی‌ها برای ایجاد اعتماد به توصیه‌های مدل و تضمین انطباق با الزامات نظارتی ضروری است. رویکردهای سنتی یادگیری ماشین جعبه سیاه، در حالی که به طور بالقوه به دقت پیش‌بینی بالایی دست می‌یابند، اغلب فاقد شفافیت لازم برای تصمیم‌گیری مهندسی هستند و ممکن است پیش‌بینی‌هایی ارائه دهند که با اصول فیزیکی تثبیت‌شده در تضاد باشند. توسعه روش‌های تفسیرپذیری مستقل از مدل، به ویژه توضیحات افزودنی شاپلی (SHAP)^{۱۸} با ارائه نسبت کمی سهم ویژگی‌های منفرد در پیش‌بینی‌های خاص، ضمن حفظ سازگاری با اصول نظریه بازی مشارکتی، این محدودیت‌ها را برطرف کرده است (Salih et al., 2025). همبستگی‌های پیرسون^{۱۹} (برای روابط خطی) و اسپیرمن^{۲۰} (برای غیرخطی و رتبه‌ای) مکمل هستند و در ارزیابی اولیه مفیدند (Hastie et al., 2009).

اعتبارسنجی متقابل (CV)^{۲۱} برای ارزیابی پایداری مدل و مدیریت عدم قطعیت حیاتی است، به ویژه در داده‌های هیدرولوژیکی دارای چولگی (Hastie et al., 2009). روش‌های K لایه (K-fold) برای تقسیم سیستماتیک، مونت کارلو (Monte Carlo) برای شبیه‌سازی تقسیم‌های تصادفی تکراری، و بوت استرپ (Bootstrap) برای نمونه‌گیری مجدد^{۲۲} با جایگزینی استفاده می‌شود، که واریانس معیارها را تخمین می‌زند (Efron and Tibshirani, 1994). در داده‌های کوچک یا نامتوازن مانند زیرگروه‌های پشته رسوبی/کانال، این روش‌ها خطا را کاهش می‌دهند. بهینه‌سازی پارامترها^{۲۳} با جستجوی شبکه‌ای یا بیزین^{۲۴} ضروری است تا از بیش تخمینی جلوگیری شود و عملکرد بهینه شود (Chen and Guestrin, 2016).

برای گرادیان تقویت شده؛ (Pedregosa et al. (2011 برای scikit-learn). تحلیل پیچیدگی-عملکرد^{۲۵} (مانند Low برای LR، High برای شبکه‌های عصبی مصنوعی (ANN²⁶)) برای انتخاب مدل عملی مهم است (Russell and Norvig, 2021).

با توجه به شکاف‌های تحقیقاتی موجود در ادبیات و ضرورت شناخت دقیق‌تر رفتار رودخانه‌های فصلی، که تحت تأثیر شرایط اقلیمی خاص و رویدادهای سیلاب‌های ناگهانی دستخوش دگرگونی‌های ساختاری پیچیده‌ای می‌شوند، این مطالعه به بررسی روابط پیچیده بین هدایت هیدرولیکی عمودی (K_v) و ویژگی‌های رسوب در بستر این رودخانه‌ها می‌پردازد. در این راستا، نخست با بهره‌گیری از روش‌های تحلیل حساسیت چندگانه شامل SHAP، اهمیت ویژگی در جنگل تصادفی و ضرایب همبستگی پیرسون و اسپیرمن، و ویژگی‌های کلیدی رسوب رتبه‌بندی شده و روابط غیرخطی آن‌ها با K_v آشکار می‌گردد. هم‌زمان، عملکرد شش الگوریتم یادگیری ماشین شامل رگرسیون خطی، درخت تصمیم، جنگل تصادفی، رگرسیون بردار پشتیبان، گرادیان تقویت شده و شبکه عصبی مصنوعی با بهینه‌سازی تطبیقی و تأکید بر مدیریت ناهمگونی داده‌ها ارزیابی می‌شود. سپس، با تفکیک داده‌ها به سه گروه کل، کانال اصلی و پشته رسوبی و اجرای روش‌های اعتبارسنجی متقابل پیشرفته، پایداری و عدم قطعیت پیش‌بینی‌ها در هر واحد مورفولوژیکی به‌طور مستقل سنجیده می‌شود. در نهایت، با مقایسه عملکرد مدل‌ها و تحلیل موازنه میان پیچیدگی الگوریتم و دقت پیش‌بینی و مقایسه با مطالعات پیشین، رویکردهای عملی برای کاربردهای میدانی پیشنهاد می‌گردد.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

استان خراسان رضوی با مساحت تقریبی 103×118.8 کیلومتر مربع، در شمال شرقی ایران واقع شده است (شکل ۱). (Error! Reference source not found.)




Figure 1. Location of the study area and measurement sites

این استان از شمال با ترکمنستان، از شرق با افغانستان و از غرب با استان‌های خراسان شمالی، سمنان و خراسان جنوبی هم‌مرز است. استان خراسان رضوی به ترتیب در غرب، شمال غربی، جنوب و جنوب غربی آن واقع شده است. این استان شامل منطقه وسیعی از مناطق خشک و نیمه‌خشک است که میانگین بارندگی آن حدود ۲۱۰ میلی‌متر است. اکوسیستم‌های متنوع استان به عوامل مختلفی مانند کوه‌های مرتفع، مناطق پست، عدم نزدیکی به دریاها و برخورد جبهه‌های مختلف آب و هوایی که از غرب، شمال، شمال غربی، شمال شرقی و جنوب وارد منطقه می‌شوند، نسبت داده می‌شود. تقریباً ۶۰ درصد از مساحت استان را مناطق بیابانی و نیمه‌بیابانی تشکیل می‌دهد (Karrabi and Tabatabai, 2025).

۲-۲- مشاهدات و اندازه‌گیری‌های میدانی

در این تحقیق، انتخاب ۱۵ رودخانه با بستر شنی بر اساس طیف وسیعی از عوامل از جمله دسترسی به محل، محدوده دبی آب ۳۰۰ تا ۵۰۰ لیتر در ثانیه با ویژگی‌های مورفولوژیکی متنوع شامل مناطق مرتفع، میانی و پست انجام شد. ۲۰ نمونه از ۱۵ رودخانه در ۷۸ منطقه با مجموع ۳۰۰ نمونه تهیه شد. برای بررسی تنوع شرایط بستر و پیچیدگی پشته‌های رسوبی در هر محل نمونه‌برداری، از اواخر بهار تا اواخر زمستان از سال ۲۰۱۹ تا ۲۰۲۲، ۱۰ نمونه از هر کانال اصلی و پشته‌های رسوبی جمع‌آوری شد. تحقیقات قابل توجهی در مورد توزیع اندازه دانه در پلان‌فرم‌های بستر بزرگ مانند پشته‌های رسوبی

Bridge and Lunt, 2006; Hassan, 2005; Kleinhans et al., 2002; Lunt and Bridge, 2004; Rice) et al., 2009) و کانال‌ها (Hassan and Church, 2000; Mao, 2012; Wittenberg and Newson, 2005). انجام شده است. اندازه‌گیری‌های میدانی در شرایط جریان کم انجام شد تا دسترسی آسان‌تر به بستر رودخانه‌ها تسهیل شود. انتخاب هر مکان بر اساس معیارهایی بود که باید در یک مسیر مستقیم از رودخانه قرار می‌گرفتند و فاصله‌ای معادل ۲۰ برابر عرض کامل رودخانه را هم در بالادست و هم در پایین‌دست از نقطه انتخاب شده تضمین می‌کردند. با توجه به ویژگی‌های رودخانه‌های با بستر شنی و قلوه‌سنگی در محدوده مورد مطالعه، نمونه‌برداری مطابق با روش پیشنهادی (Bunte and Abt, 2001) انجام شد. این شامل ارزیابی دانه‌بندی لایه سطحی بستر با تعیین کمیت فراوانی ذرات در هر دسته بود.




Figure 2. Schematic diagram of different bed layers (Bunte and Abt, 2001)

۳-۲- اندازه‌گیری K_v

آزمایش نفوذسنج با هد افتان برای تعیین K_v رسوبات بستر رودخانه استفاده شد. این آزمایش معمولاً در مطالعات رودخانه‌ای برای اندازه‌گیری K_v استفاده می‌شود (Chen, 2005; Chen et al., 2010;) (Korus et al., 2018, 2020; Sebok et al., 2015; Song et al., 2018; Wang et al., 2016). این روش برای اندازه‌گیری K_v با قرار دادن لوله‌های فلزی ایستاده در رسوبات بستر رودخانه اعمال شد. در ابتدا، یک لوله عمودی به طول ۱۶۰ سانتی‌متر و قطر داخلی ۷ سانتی‌متر با دقت در رسوب بستر رودخانه قرار داده شد (Error! Reference source not found.). مقدار K_v با استفاده از روش شرح داده شده توسط Hvorslev (1951) تعیین شد.

$$K_v = \frac{\pi D}{11m} + L_v \ln \left(\frac{h_1}{h_2} \right) \quad (1)$$




Figure 3. Schematic diagram showing in situ permeameter tests for measuring K_v in study area (Karrabi and Tabatabai, 2025).

که در آن h_1 و h_2 به ترتیب هد هیدرولیکی مشاهده شده در لوله مربوط به زمان‌های اندازه‌گیری t_1 و t_2 هستند، m جذر نسبت هدایت هیدرولیکی افقی K_h به هدایت هیدرولیکی عمودی K_v (یعنی $m = \sqrt{K_h/K_v}$)، D قطر داخلی لوله، L_v طول ستون رسوب در لوله است. (Chen 2005) پیشنهاد کرد که اگر طول ستون رسوب (L_v) پنج برابر بزرگتر از قطر لوله باشد، معادله (۱) را می‌توان به صورت زیر ساده کرد:

$$K_v = \frac{L_v}{t_2 - t_1} \ln(h_1 / h_2) \quad (2)$$

در این مطالعه، میانگین طول ستون رسوب اندازه‌گیری شده (L_v) در لوله بین ۳۰ تا ۵۰ سانتی‌متر است؛ بنابراین، نسبت L_v/D معمولاً بیشتر از پنج است، از این رو خطاهای اندازه‌گیری کاهش می‌یابد (Wang et al., 2016). بر اساس نتایج تخمینی برای مقادیر K_v از رسوبات با عمق ۰ تا ۳۰ سانتی‌متر و ۰ تا ۵۰ سانتی‌متر، مقادیر K_{v2} لایه رسوب پایین‌تر با عمق ۳۰ تا ۵۰ سانتی‌متر را می‌توان با استفاده از معادله زیر محاسبه کرد (Freeze and Cherry, 1979):

$$K_{v2} = L_2 / (L / K_v - L_1 / K_{v1}) \quad (3)$$

که در آن K_v و K_{v2} ، K_{v1} به ترتیب نشان‌دهنده هدایت هیدرولیکی عمودی برای ستون‌های رسوب L_1 (۰-۳۰ سانتی‌متر)، L_2 (۳۰-۵۰ سانتی‌متر) و L (۰-۵۰ سانتی‌متر) هستند (Error! Reference source not found.).

مطالعه حاضر متغیرهایی از جمله d_{10} ، d_{16} ، d_{35} ، d_{50} ، d_{65} ، d_{84} و d_{90} (به ترتیب نشان‌دهنده قطر دانه‌ها در ۱۰٪، ... و ۹۰٪ وزنی عبوری)، ضریب یکنواختی ($U_c = d_{60}/d_{10}$)، تخلخل (n)، نسبت جورشدگی (d_{84}/d_{16})، نسبت زره (d_{is}/d_{iss})، درصد گل (رسوب عبوری از الک ۰.۰۶۲۵ میلی‌متر) و

نسبت تخلخل ($e=n/1-n$) را بررسی می‌کند. بر این اساس، (Vukovic and Soro 1992) دریافتند که تخلخل n تابعی از U_c است که به صورت تجربی توسط رابطه زیر داده می‌شود:

$$n=\alpha(1+\beta^{U_c}) \quad (4)$$

که در آن α (۰/۲۵۵) و β (۰/۸۳) ثابت‌های بدون واحد هستند (Devlin, 2015). نسبت بین اندازه دانه مشخصه (معمولاً اندازه میانه) در توزیع اندازه دانه سطحی (d_{i_s}) و همان اندازه دانه مشخصه در توزیع اندازه دانه زیرسطحی ($d_{i_{ss}}$) (Bunte and Abt, 2001).

۲-۴- الگوریتم‌های ML

بسیاری از مطالعات از این الگوریتم‌های یادگیری ماشین در مشکلات مختلف مرتبط با خواص هیدرولیکی خاک استفاده کرده‌اند. چندین مطالعه از نوع ANN یادگیری ماشین برای پیش‌بینی خواص هیدرولیکی خاک استفاده کرده‌اند (Botula et al., 2013; Nemes et al., 2008). Elshorbagy et al. (2010)، KNN را به عنوان یک تکنیک مدل‌سازی جذاب برای کاربردهای هیدرولوژی شناسایی می‌کنند. بسیاری از مطالعات از الگوریتم SVM برای مدل‌سازی خواص هیدرولیکی خاک استفاده کرده‌اند (Kaingo et al., 2018; Kotlar et al., 2019; Mady and Shein, 2018). اخیراً، برخی مطالعات دریافته‌اند که مدل‌های SVM خواص هیدرولیکی خاک را دقیق‌تر از مدل‌های شبکه عصبی مصنوعی پیش‌بینی کرده‌اند (Khlosi et al., 2016; Twarakavi et al., 2009). هر دو الگوریتم جنگل تصادفی (RF) و درخت رگرسیون تقویت شده (BRT^{27}) از مجموعه‌ای از درختان رگرسیون به عنوان یادگیرنده‌های پایه خود استفاده می‌کنند، و چندین مطالعه قدرت این الگوریتم‌ها را در پیش‌بینی خواص خاک به طور کلی و خواص هیدرولیکی به طور خاص برجسته کرده‌اند. برای مثال، Hengl et al. (2017) از RF و BRT در میان مجموعه‌ای از مدل‌های دیگر برای ساخت نقشه جهانی خاک استفاده کردند. Chaney et al. (2019) به طور مشابه از RF برای ساخت نقشه خواص پیش‌بینی‌شده خاک در ایالات متحده استفاده کردند. اخیراً PTF Szabó et al. (2019) هایی مبتنی بر RF و BRT برای بررسی خواص هیدرولیکی خاک در سراسر یک حوضه آبریز توسعه داده‌اند. Koestel and Jorda (2014) نشان دادند که الگوریتم RF می‌تواند برای مدل‌سازی دقیق انتقال ترجیحی املاح خاک استفاده شود. Jorda et al. (2015) از مدل‌های BRT برای پیش‌بینی K_s و کاوش متغیرهای مهم که آن را کنترل می‌کنند استفاده کردند.

۲-۴-۱- رگرسیون خطی (LR)

به عنوان یک مدل پایه‌ای و تفسیرپذیر که روابط خطی بین متغیرها را برآورد می‌کند، در بسیاری از مطالعات اولیه مورد استفاده قرار گرفته است. اگرچه این مدل قادر به شناسایی روابط غیرخطی پیچیده

نیست، اما به عنوان یک معیار مقایسه‌ای مفید عمل می‌کند.

۲-۴-۲- درخت تصمیم (DT)

درخت تصمیم (DT) یکی از الگوریتم‌های یادگیری ماشین نظارت‌شده است که با تقسیم‌بندی بازگشتی فضای ویژگی‌ها بر اساس معیارهایی مانند کاهش واریانس، ساختاری سلسله‌مراتبی ایجاد می‌کند (Breiman et al., 2017). این الگوریتم قادر به مدل‌سازی روابط غیرخطی بدون نیاز به فرضیات پیشین درباره توزیع داده‌ها است (Hastie et al., 2009). مزیت اصلی این روش تفسیرپذیری بالا است، اما مستعد بیش‌برازش می‌باشد که منجر به توسعه روش‌های ترکیبی مانند RF و BRT شده است (Breiman, 2001).

۲-۴-۳- جنگل تصادفی (RF)

مدل‌های RF مدل‌های محبوبی هستند که آموزش و تنظیم آنها نسبتاً ساده است (Hastie et al., 2009). آنها با میانگین‌گیری از تعداد زیادی از مدل‌های مبتنی بر درخت تصمیم، از تکنیک‌های گروهی استفاده می‌کنند. مدل‌های درختی با جستجوی یک پیش‌بینی‌کننده که بهترین تقسیم را تضمین می‌کند و منجر به کمترین خطای مدل می‌شود، رشد می‌کنند. درخت‌های منفرد در گروه RF بر روی نمونه آموزشی بوت‌استرپ شده ساخته شده‌اند و تنها گروه کوچکی از متغیرهای پیش‌بینی‌کننده در هر تقسیم در نظر گرفته می‌شوند. این امر تضمین می‌کند که درختان با یکدیگر ناهمبسته هستند (Breiman, 2001; James et al., 2013).

۲-۴-۴- ماشین بردار پشتیبان رگرسیونی (SVR)

ماشین بردار پشتیبان رگرسیونی (SVR) اقتباسی از ماشین بردار پشتیبان (SVM) برای مسائل رگرسیون است که با نگاشت متغیرهای ورودی به فضای ویژگی با ابعاد بالا از طریق توابع هسته (مانند تابع پایه شعاعی، RBF)، یک ابرصفحه بهینه برای رگرسیون می‌سازد (Cortes and Vapnik, 1995). این الگوریتم با تعریف یک حاشیه تحمل (ϵ -insensitive) تنها خطاهای بزرگ‌تر از آستانه مشخص را جریمه می‌کند، که موجب مقاومت بالا در برابر نویز و داده‌های پرت می‌شود (Smola and Schölkopf, 2004).

۲-۴-۵- گرادیان تقویت شده (Boost)

Boost یک روش یادگیری گروهی مقیاس‌پذیر مبتنی بر درخت است که بر پایه نظریه تقویت گرادیان بنا شده و برای دستیابی به دقت پیش‌بینی بالا و کارایی محاسباتی طراحی شده است (Chen and Guestrin, 2016b). این روش با برآزش هر درخت جدید به شبه‌باقی‌مانده‌های تابع زیان، مدل‌های درخت تصمیم‌گیری افزایشی را به صورت متوالی می‌سازد و از بسط تیلور مرتبه دوم که هم اطلاعات

گرایان و هم اطلاعات هسیان را برای هدایت بهینه‌سازی در بر می‌گیرد، استفاده می‌کند (Friedman, 2001).

۲-۴-۶- شبکه عصبی مصنوعی (ANN)

ANN ابزارهای مدل‌سازی غیرخطی و مبتنی بر داده هستند که از ساختار سیستم‌های عصبی بیولوژیکی الهام گرفته شده‌اند و به دلیل توانایی‌شان در ثبت روابط پیچیده ورودی-خروجی، به طور گسترده در مدل‌سازی هیدرولوژیکی کاربرد دارند (ASCE Task Committee, 2000). در این مطالعه، از معماری پرسپترون چندلایه پیش‌خور (MLP) استفاده شد که شامل یک لایه ورودی، یک یا چند لایه پنهان با توابع فعال‌سازی غیرخطی و یک لایه خروجی است. به دلیل انعطاف‌پذیری و قابلیت تقریب قوی، ANN‌ها به طور گسترده برای مدل‌سازی بارش-رواناب، پیش‌بینی جریان رودخانه و تخمین سطح آب‌های زیرزمینی مورد استفاده قرار گرفته‌اند (Dawson and Wilby, 2001).

۲-۵- بهینه‌سازی پارامترهای مدل‌های یادگیری ماشین

در این مطالعه، برای جلوگیری از بیش‌برازش و افزایش تعمیم‌پذیری، پارامترهای مدل‌های یادگیری ماشین به‌جای استفاده از مقادیر ثابت، به‌صورت تطبیقی و بر مبنای حجم و ویژگی‌های آماری هر زیرمجموعه از داده‌ها تنظیم شدند. بدین ترتیب، در مدل‌های درختی (RF و Boost) پارامترهایی مانند تعداد درختان، عمق و اندازه برگ حداقل با توجه به تعداد نمونه‌های آموزشی مقیاس‌بندی شد، در SVR پارامترهای C ، γ و ϵ متناسب با دامنه و پراکندگی متغیرهای ورودی و خروجی تعیین گردید، و در شبکه عصبی نیز معماری شبکه و فرایارامترهای آموزش (تعداد لایه‌ها، نرون‌ها، دوره‌ها و نرخ یادگیری) با حجم داده‌ها سازگار شد تا از بیش‌برازش جلوگیری شده و ظرفیت مدل به‌تناسب افزایش یابد (Goodfellow et al., 2016). کلیه این فرایندها در چارچوب اعتبارسنجی متقابل تودرتو و با الهام از مطالعات پیشین به‌کمک جعبه‌ابزارهای یادگیری ماشین MATLAB پیاده‌سازی شدند (Bischl et al., 2019; Probst et al., 2023) و به مدلهایی با پایداری و قابلیت تعمیم بالاتر نسبت به مدل‌های با پارامتر ثابت انجامیدند (Cawley and Talbot, 2010).

۲-۶- اعتبارسنجی و ارزیابی مدل‌ها

برای اطمینان از قابلیت تعمیم و ارزیابی بی‌طرفانه عملکرد مدل‌های توسعه‌یافته، از یک چارچوب اعتبارسنجی جامع و چندسطحی استفاده شد. این رویکرد مبتنی بر بهترین شیوه‌های موجود در ادبیات یادگیری ماشین و مدل‌سازی هیدرولوژیکی است (James et al., 2013; Hastie et al., 2009). سه روش مختلف اعتبارسنجی متقابل به منظور بررسی پایداری و استحکام نتایج به کار گرفته شد.

اعتبارسنجی K-Fold با ۵ فولد به صورت تصادفی و با حفظ نسبت‌های اصلی کلاس‌ها (در صورت وجود) اجرا شد. این روش که به طور گسترده در مطالعات مشابه استفاده شده است (Refaailzadeh et al., 2009)، تخمین معتبری از خطای تعمیم ارائه می‌دهد. روش مونت کارلو با ۳۰ تکرار مستقل و با تقسیم‌بندی تصادفی ۷۰-۳۰ (آموزش-آزمون) در هر تکرار انجام شد.

عملکرد هر مدل با سه معیار استاندارد و پرکاربرد در مسائل رگرسیون هیدرولوژیکی ارزیابی شد. ضریب تعیین (R^2) که میزان تناسب مدل با داده‌ها را نشان می‌دهد، به عنوان معیار اصلی انتخاب شد. ریشه میانگین مربعات خطا (RMSE) برای سنجش دقت پیش‌بینی‌ها و میانگین خطای مطلق (MAE) برای ارزیابی خطای سیستماتیک محاسبه گردید. این معیارهای تکمیلی، دیدگاه جامع‌تری از نقاط قوت و ضعف هر مدل ارائه می‌دهند (Chai and Draxler, 2014). تمامی معیارها هم بر روی مجموعه آموزش و هم بر روی مجموعه آزمون محاسبه شدند تا امکان تشخیص بیش‌برازش فراهم شود.

عملکرد مدل‌ها در سه روش اعتبارسنجی مختلف با یکدیگر مقایسه شد تا حساسیت نتایج به روش تقسیم‌بندی داده ارزیابی گردد. این تحلیل به شناسایی مدل‌های پایدارتر که عملکرد خوبی در شرایط مختلف تقسیم‌بندی داده دارند، کمک کرد. مطالعاتی مانند Vabalas et al. (2019) نشان داده‌اند که چنین تحلیلی برای اطمینان از پایداری مدل‌های یادگیری ماشین ضروری است.

۷-۲- تحلیل حساسیت مبتنی بر SHAP

برای تفسیر مدل نهایی و تحلیل کمی تأثیر هر یک از متغیرهای مستقل بر پیش‌بینی نفوذپذیری بستر (K_v)، از چارچوب SHAP (SHapley Additive exPlanations) استفاده شد. SHAP یک روش مبتنی بر نظریه بازی‌های کوپراسیونی^{۲۸} است که سهم هر ویژگی را در پیش‌بینی مدل به صورت افزودنی و عادلانه تخصیص می‌دهد (Lundberg and Lee, 2017). این چارچوب به طور فزاینده‌ای در مطالعات برای تفسیر مدل‌های جعبه‌سیاه پیچیده مورد استفاده قرار گرفته است (Mangalathu et al., 2020). مدل جنگل تصادفی (RF) بهینه‌شده به عنوان مدل پایه برای محاسبه مقادیر SHAP انتخاب شد.

در این مطالعه از یک روش تقریبی مبتنی بر جایگزینی^{۲۹} برای محاسبه مقادیر SHAP استفاده شد. برای هر نمونه پیش‌زمینه و هر ویژگی، مقدار SHAP به عنوان تفاوت بین پیش‌بینی مدل زمانی که آن ویژگی حضور دارد (با مقدار اصلی نمونه) و زمانی که غایب است (با مقدار جایگزین شده از نمونه‌های پس‌زمینه) محاسبه شد. به بیان ریاضی، مقدار SHAP برای ویژگی j در نمونه i به صورت زیر برآورد شد:

$$\phi_j^{(i)} = f(x_{\text{with } j}^{(i)}) - f(x_{\text{without } j}^{(i)}) \quad (5)$$

که در آن f مدل جنگل تصادفی است و $x_{with,j}^{(i)}$ نمونه i با مقدار اصلی ویژگی j و $x_{without,j}^{(i)}$ نمونه i با مقدار جایگزین شده ویژگی j از مجموعه پس‌زمینه است. این روش تقریبی مبتنی رویکرد مونت‌کارلو است که در کتابخانه SHAP استاندارد استفاده می‌شود (Lundberg et al., 2020).

۲-۷-۱- استخراج شاخص‌های تحلیل حساسیت

از ماتریس مقادیر SHAP سه شاخص اصلی استخراج شد:

۱. اهمیت کلی ویژگی (Mean Absolute SHAP): میانگین قدر مطلق مقادیر SHAP برای هر ویژگی در تمام نمونه‌های پیش‌زمینه. این شاخص معیاری از متوسط تأثیر هر متغیر بر پیش‌بینی مدل، صرف‌نظر از جهت آن، ارائه می‌دهد.

۲. جهت اثر (Mean SHAP): میانگین حسابی مقادیر SHAP برای هر ویژگی. مقادیر مثبت نشان‌دهنده رابطه مثبت با متغیر وابسته و مقادیر منفی نشان‌دهنده رابطه منفی است. این شاخص ماهیت (افزاینده یا کاهنده) تأثیر هر متغیر را مشخص می‌کند.

۳. همبستگی SHAP-مقدار (SHAP-Value Correlation): ضریب همبستگی پیرسون بین مقادیر اصلی هر ویژگی و مقادیر SHAP مربوطه. این شاخص نشان می‌دهد که آیا تأثیر یک ویژگی به صورت یکنواخت (خطی) با مقدار آن تغییر می‌کند یا رابطه پیچیده‌تری وجود دارد.

۲-۷-۲- مقایسه با روش‌های سنتی تحلیل حساسیت

برای اعتبارسنجی و زمینه‌سازی نتایج SHAP، این نتایج با سه روش سنتی‌تر تحلیل حساسیت مقایسه شد: اهمیت متغیرهای جنگل تصادفی: بر اساس کاهش میانگین خطای خارج از کیس (OOB^{30} Error) هنگام تصادفی‌سازی هر متغیر (Breiman, 2001).

همبستگی پیرسون: اندازه‌گیری رابطه خطی ساده بین هر متغیر مستقل و متغیر وابسته.

همبستگی اسپیرمن: اندازه‌گیری رابطه یکنوا (غیرخطی) بین متغیرها.

این مقایسه جامع، دیدگاهی از سازگاری و تکمیل‌کنندگی روش‌های مختلف تحلیل حساسیت ارائه داد و صحت یافته‌های SHAP را در چارچوب روش‌های شناخته‌شده تأیید کرد. چنین مقایسه‌ای در مطالعاتی مانند Nohara et al. (2022) نیز برای تفسیر مدل‌های پیش‌بینی در علوم آب انجام شده است. در شکل (۴) بطور خلاصه فرایند تحقیق نشان داده شده است.




Figure 4: Research methodology flowchart for predicting streambed hydraulic conductivity (K_v) using machine learning.

۳- نتایج

جدول (۱) خلاصه‌ای از ویژگی‌های آماری اندازه‌گیری‌های K_v ، نسبت زره و درصد گل در بارها و کانال‌های اصلی را نشان می‌دهد.

Table 1. Statistical Summary of Streambed K_v , Armor Ratio, and Mud Percentage in Bars vs. Main Channels

Variables	K_v (m/d)			Armor ratio			Mud percentage		
	Bar	Main-channel	All	Bar	Main-channel	All	Bar	Main-channel	All
Total tests	150	150	300	150	150	300	150	150	300
Average	27.1	23.5	25.3	2.55	2.56	2.55	0.60	0.74	0.67
Minimum	0.8	0.7	0.7	0.90	0.90	0.90	0.01	0.01	0.01
Maximum	125.6	96.0	125.6	6.20	6.20	6.20	6.05	7.80	7.80
St. dev	26.9	20.7	24.07	1.01	1.05	1.03	1.06	1.41	1.25
Coefficient of variation (CV)	0.99	0.88	0.95	0.40	0.41	0.40	1.77	1.89	1.86
Skewness	1.20	0.85	1.16	0.92	0.88	0.90	3.12	3.29	3.35
Kurtosis	0.90	0.16	1.09	0.88	0.50	0.65	10.52	11.22	12.13

شش الگوریتم یادگیری ماشین با پارامترهای تطبیقی (بر اساس حجم نمونه، پراکندگی داده و پیچیدگی گروه مورفولوژیکی) و سه روش اعتبارسنجی متقابل ارزیابی شدند. معیارهای اصلی شامل R^2 (Train/Test)، RMSE، MAE، بازه اطمینان ۹۵٪ برای R^2 Test و نرخ برنده شدن (Win Rate) بودند (جدول ۲؛ شکل‌های ۵ تا ۷). در گروه کل داده‌ها (All، $n=300$)، مدل Boost به‌طور مداوم بهترین

عملکرد را نشان داد (Test R^2 میانگین 0.93 ± 0.18 در K-Fold ، 0.9 ± 0.18 در Monte Carlo ، 0.877 ± 0.22 در Bootstrap).

Table 2. Comprehensive performance metrics of the Boost model across different data groups and cross-validation methods.

CV Method	Data Group	Best Model	Train R^2 (Mean $\pm$ Std)	Test R^2 (Mean $\pm$ Std)	Test R^2 95% CI	Win Rate (%)
KFold	All	Boost	0.971 ± 0.004	0.903 ± 0.018	$0.874 - 0.933$	93.3
	Channel	Boost	0.984 ± 0.003	0.872 ± 0.039	$0.792 - 0.920$	70.0
	Bar	Boost	0.980 ± 0.003	0.865 ± 0.019	$0.828 - 0.898$	93.3
MonteCarlo	All	Boost	0.971 ± 0.003	0.900 ± 0.018	$0.856 - 0.924$	100.0
	Channel	Boost	0.985 ± 0.002	0.872 ± 0.031	$0.808 - 0.922$	90.0
	Bar	Boost	0.980 ± 0.004	0.862 ± 0.025	$0.807 - 0.900$	86.7
Bootstrap	All	Boost	0.983 ± 0.003	0.877 ± 0.022	$0.829 - 0.918$	96.7
	Channel	Boost	0.993 ± 0.002	0.842 ± 0.047	$0.732 - 0.919$	90.0
	Bar	Boost	0.991 ± 0.003	0.818 ± 0.043	$0.701 - 0.876$	73.3




Figure 5. Model comparison bar charts (Test R^2 (a), Win Rate (b) and c:uncertainty (c)) for K-Fold cross-validation




Figure 6. Model comparison bar charts (Test R^2 (a), Win Rate (b) and c:uncertainty (c)) for Monte Carlo cross-validation




Figure 7. Model comparison bar charts (Test R^2 (a), Win Rate (b) and c:uncertainty (c)) for Bootstrap cross-validation

Win Rate آن بین ۹۳/۳٪ (K-Fold) تا ۱۰۰٪ (Monte Carlo) بوده و بازه اطمینان ۹۵٪ $Test R^2$ عموماً بالای ۰/۸۲ است. RF دومین مدل قوی بود ($Test R^2 \approx ۰/۸۸ - ۰/۸۴$), در حالی که LR ضعیف‌ترین عملکرد را داشت ($Test R^2 \approx ۰/۷۱ - ۰/۶۷$). ANN و DT عملکرد متوسطی نشان دادند اما به دلیل پیچیدگی بالا (High) و واریانس بیشتر، کمتر پایدار بودند. SVR در $Train R^2$ بالا بود (۰/۹۶ – ۰/۹۴) اما در Test افت قابل توجهی داشت (Overfitting نسبی). شکل‌های (۸) تا (۱۰) شامل نمودار مقایسه مدل پیش‌بینی و مقادیر مشاهداتی، نمودار باقیمانده‌ها، توزیع فراوانی باقی‌مانده‌ها و بارچارت مقایسه معیارهای ارزیابی عملکرد برای گروه‌های داده‌ای سه گانه و هر CV را برای بهترین تکرار نشان می‌دهد. در همه روش‌های CV، مدل‌های مبتنی بر درخت (RF/Boost)، به‌طور معناداری بهتر از مدل‌های خطی و ساده (DT/LR) عمل کردند. تفاوت $Train/Test R^2$ در Boost کمترین است، که نشان‌دهنده تعمیم‌پذیری خوب است. در گروه کل داده‌ها RMSE و MAE نیز با Boost کمترین بودند (۰/۱۹ – ۰/۱۶ $Test RMSE \approx ۰/۱۵ - ۰/۱۲$ MAE). این نتایج با بهینه‌سازی تطبیقی پارامترها مانند تعداد چرخه‌ها و نرخ یادگیری در Boost همخوانی دارد.

شکل (۸) نمودارهای تشخیصی دقیق مدل بهترین عملکرد Boost (تکرار انتخاب‌شده) تحت اعتبارسنجی متقابل K-Fold را در سه گروه داده ارائه می‌دهد. پنل‌های (a, e, i) نمودارهای پراکندگی مقادیر مشاهده‌شده در مقابل پیش‌بینی‌شده $\log_{10}(K_v)$ را نشان می‌دهند (نقاط آموزش به صورت دایره خاکستری




Figure 8. Diagnostic plots for the best-performing Boost model (selected repetition) under K-Fold cross-validation. (a–d) All data; (e–h) Main channel; (i–l) Bar. (a, e, i) Scatter plot of observed vs. predicted $\log_{10}(K_v)$. (b, f, j) Residual plot (observed – predicted) vs. observed $\log_{10}(K_v)$. (c, g, k) Histogram of residuals. (d, h, l) Bar chart of performance metrics (R^2 train/test, RMSE train/test, MAE train/test).

و نقاط آزمون به صورت مربع قرمز). مدل مقادیر R^2 آزمون بالایی برابر $0/934$ (کل داده‌ها)، $0/920$ (کانال

اصلی) و $0/898$ (پشته رسوبی) به دست آورد که بیانگر دقت پیش‌بینی قوی و بایاس ناچیز است.

نمودارهای باقیمانده (b, f, j) توزیع تصادفی باقیمانده‌ها حول صفر بدون الگوهای سیستماتیک را نشان می‌دهند، در حالی که هیستوگرام‌های باقیمانده (c, g, k) تقریباً متقارن و زنگوله‌ای شکل هستند. میله‌های معیارهای عملکرد (d, h, l) مقادیر RMSE پایین ($0/1374$ – $0/1240$) و MAE ($0/0727$ – $0/0518$) را در مجموعه آزمون تأیید می‌کنند.

شکل (۹) نمودارهای تشخیصی دقیق مدل بهترین عملکرد Boost (تکرار انتخاب‌شده) تحت اعتبارسنجی متقابل Monte Carlo را در سه گروه داده ارائه می‌دهد. مدل مقادیر R^2 آزمون برابر $0/925$ (کل داده‌ها)، $0/925$ (کانال اصلی) و $0/901$ (پشته رسوبی) به دست آورد. نمودارهای باقیمانده (b, f, j) توزیع تصادفی باقیمانده‌ها حول صفر بدون الگوهای سیستماتیک را نشان می‌دهند، در حالی که هیستوگرام‌های باقیمانده




Figure 9. Diagnostic plots for the best-performing Boost model (selected repetition) under Monte Carlo cross-validation. (a–d) All data; (e–h) Main channel; (i–l) Bar. (a, e, i) Scatter plot of observed vs. predicted $\log_{10}(K_v)$. (b, f, j) Residual plot (observed – predicted) vs. observed $\log_{10}(K_v)$. (c, g, k) Histogram of residuals. (d, h, l) Bar chart of performance metrics (R^2 train/test, RMSE train/test, MAE train/test).

(c, g, k) تقریباً متقارن و زنگوله‌ای شکل هستند. میله‌های معیارهای عملکرد (d, h, l) مقادیر RMSE

پایین (۰/۱۷۶–۰/۱۴۴) و MAE (۰/۱۴۳–۰/۱۱۹) را در مجموعه آزمون تأیید می‌کنند.

شکل (۱۰) نمودارهای تشخیصی مدل بهترین عملکرد Boost (تکرار انتخاب‌شده) تحت اعتبارسنجی متقابل Bootstrap را در سه گروه داده ارائه می‌دهد. مدل مقادیر R^2 آزمون بالایی برابر ۰/۹۲۱ (کل داده‌ها)، ۰/۹۲۲ (کانال اصلی) و ۰/۸۷۷ (پشته رسوبی) به دست آورد که بیانگر دقت پیش‌بینی قوی و بایاس ناچیز است.

نمودارهای باقیمانده (b, f, j) توزیع تصادفی باقیمانده‌ها حول صفر بدون الگوهای سیستماتیک را نشان می‌دهند، در حالی که هیستوگرام‌های باقیمانده (c, g, k) تقریباً متقارن و زنگوله‌ای شکل هستند. میله‌های معیارهای عملکرد (d, h, l) مقادیر RMSE پایین (۰/۱۵۲–۰/۱۹۹) و MAE (۰/۱۲۳–۰/۱۵۵) را در مجموعه آزمون تأیید می‌کنند.




Figure 10. Diagnostic plots for the best-performing Boost model (selected repetition) under Monte Carlo cross-validation. (a-d) All data; (e-h) Main channel; (i-l) Bar. (a, e, i) Scatter plot of observed vs. predicted $\log_{10}(K_v)$. (b, f, j) Residual plot (observed - predicted) vs. observed $\log_{10}(K_v)$. (c, g, k) Histogram of residuals. (d, h, l) Bar chart of performance metrics (R^2 train/test, RMSE train/test, MAE train/test).

۴- بحث

۴-۱- عملکرد مدل در واحدهای مورفولوژیکی مختلف (کانال اصلی و پشته رسوبی)

مدل Boost عملکرد متفاوتی در واحدهای مورفولوژیکی کانال اصلی و پشته رسوبی نشان داد که بیانگر تأثیر قوی ناهمگنی ساختاری بستر است. در کانال اصلی، R^2 Test میانگین به 0.872 ± 0.039 (K_v Fold)، 0.872 ± 0.031 (Monte Carlo) و 0.842 ± 0.047 (Bootstrap) رسید، در حالی که در پشته رسوبی این مقادیر به 0.865 ± 0.019 ، 0.862 ± 0.025 و 0.818 ± 0.043 کاهش یافت. Win Rate نیز در کانال اصلی بالاتر (۷۰-۹۰ درصد) بود و RMSE/MAE آزمون به طور معنادار افزایش یافت (تا 0.224 و 0.179 در Bootstrap). شکل‌های (۸) تا (۱۰) این تفاوت را به صورت بصری تأیید می‌کنند: در کانال اصلی پراکندگی نقاط آزمون کمتر، باقیمانده‌ها متمرکزتر و هیستوگرام residuals باریک‌تر است،

در مقابل پشته رسوبی که پراکندگی بیشتر و R^2 آزمون پایین تر (۰/۸۷۷-۰/۸۹۸) مشاهده می‌شود. از نظر فیزیکی، کانال اصلی با دانه‌بندی درشت‌تر، زره‌پوشی (armoring) کمتر و جریان‌های سریع‌تر، تخلخل بالاتر و هدایت هیدرولیکی عمودی بیشتری ایجاد می‌کند که روابط پیش‌بینی‌پذیرتری با ویژگی‌های PSD ایجاد می‌نماید (Bridge, 2007; Korus et al., 2020). در مقابل، پشته‌های رسوبی با رسوب‌گذاری ریزتر، درصد گل (m_p) بالاتر و فشردگی بیشتر، فضاهای منفذی را مسدود کرده و ناهمگنی فضایی بیشتری ایجاد می‌کنند که باعث افزایش عدم قطعیت مدل می‌شود (Brunner et al., 2017; Datry et al., 2017). این الگو با مطالعات اخیر در رودخانه‌های فصلی مناطق خشک همخوانی دارد که نشان می‌دهد تفاوت‌های مورفولوژیکی می‌تواند K_v را تا یک مرتبه بزرگی تغییر دهد (Shanafield et al., 2021). این یافته‌ها بر لزوم تفکیک واحدهای مورفولوژیکی در مدل‌سازی K_v در رودخانه‌های فصلی تأکید می‌کند و نشان می‌دهد که نادیده گرفتن این ناهمگنی می‌تواند منجر به تخمین‌های بیش‌ازحد خوش‌بینانه در واحدهای رسوبی شود.

۴-۲- تحلیل حساسیت متغیرها و تفسیر فیزیکی عوامل کنترل‌کننده

به منظور واکاوی ساختار درونی مدل و درک فرایندهای هیدرولوژیکی مؤثر بر هدایت هیدرولیکی بستر (K_v)، از رویکرد SHAP بهره گرفته شد. این متدولوژی با عبور از محدودیت‌های مدل‌های جعبه سیاه، امکان تفسیر روابط غیرخطی و تعاملات پیچیده بین پارامترهای رسوب و جریان را فراهم می‌آورد (Lundberg and Lee, 2017). تحلیل حساسیت مبتنی بر SHAP نشان داد که درصد ذرات ریزدانه (m_p) با امتیاز اهمیت ۰/۲۳۷، مسلط‌ترین عامل در کنترل $\log_{10}(K_v)$ است (شکل ۱۱).




Figure 11. SHAP (SHapley Additive exPlanations) analysis results: (a) feature importance bar plot, (b) effect direction scatter plot, (c) SHAP values versus feature values for top predictors.

این یافته همسو با مطالعات (Datry et al, 2017) است که نشان دادند در رودخانه‌های فصلی (Ephemeral Streams)، دینامیک نفوذپذیری بیش از آنکه تابع اسکلت درشت‌دانه باشد، توسط مقدار ذرات سیلت و رس کنترل می‌شود. پس از آن، نسبت زرهی (A_r) و قطر مؤثر (d_{10}) به ترتیب با امتیازهای ۰/۱۲۳ و ۰/۱۰۱ در رتبه‌های بعدی قرار دارند که بیانگر اهمیت ساختار لایه‌بندی بستر در مناطق خشک است. جهت اثر m_p منفی قوی (میانگین $SHAP \approx -0/012$ ، همبستگی $-0/66$) و A_r عمدتاً مثبت بود. این رتبه‌بندی با روش‌های سستی (اهمیت RF، همبستگی پیرسون و اسپیرمن) همخوانی بالایی داشت (شکل ۱۲).




Figure 12. Comparison of sensitivity analysis methods: (a) normalized feature importance across different predictors for SHAP, Random Forest (RF), Pearson, and Spearman methods; (b) importance heatmap showing normalized scores per predictor and method.

نمودارهای وابستگی SHAP (شکل ۱۳) روابط غیرخطی پیچیده را آشکار کرد m_p رابطه U-shaped با شیب منفی تند در مقادیر بالا نشان داد ($R^2=0/436$)، که با مسدود شدن منافذ توسط رسوبات ریز و کاهش تخلخل مؤثر همخوانی دارد (Rosas et al., 2015; Datry et al., 2017). A_r رابطه مثبت غیرخطی قوی داشت ($R^2=0/901$)، که افزایش K_v را با زره‌پوشی سطحی (دانه‌های درشت‌تر سطح نسبت به زیرسطح) توضیح می‌دهد (Korus et al., 2020; Brunner et al., 2017). d_{10} و u_c بر توزیع اندازه منافذ و ناهمگونی کنترل دارند (Vukovic and Soro, 1992; Shanafield et al., 2021). مقایسه روش‌ها در

شکل (۱۲) تأیید کرد که SHAP برتر از Pearson/Spearman و RF در آشکارسازی روابط غیرخطی و تعاملی است (Lundberg and Lee, 2017; Molnar, 2025).




Figure 13. SHAP dependence plots for the top six predictors: (a) m_p , (b) A_r , (c) d_{10} , (d) u_c , (e) d_{16} , (f) d_{00} .

این تحلیل حساسیت نه تنها رتبه‌بندی متغیرها را ارائه می‌دهد، بلکه مکانیسم‌های فیزیکی زیربنایی K_v را در بستر رودخانه‌های فصلی روشن می‌سازد و مبنای محکمی برای توسعه مدل‌های فیزیکی-ماشینی ترکیبی فراهم می‌کند.

۳-۴- مقایسه با پژوهش‌های پیشین

به‌منظور ارزیابی عملکرد مدل پیشنهادی در این پژوهش، نتایج به‌دست‌آمده با روابط تجربی و نیمه‌تجربی پیشین برای برآورد هدایت هیدرولیکی بستر رودخانه مقایسه شد. در مطالعه Karrabi and Tabatabai (2025)، معادله پیشنهادی آن پژوهش، با تعدادی از روابط شناخته‌شده پیشین از جمله روابط Hazen, Rosas et al, Chapuis, Beyer, Kozeny–Carman, Terzaghi, Slichter و Wang et al مقایسه شده است. بر اساس نتایج گزارش‌شده توسط آنان، هر یک از روابط تجربی پیشین برای شرایط خاص و دامنه مشخصی از ویژگی‌های دانه‌بندی توسعه یافته‌اند؛ بنابراین، کاربرد آن‌ها در شرایط متفاوت می‌تواند

با خطای قابل توجهی همراه باشد. نتایج آن مطالعه نشان می‌دهد که مقدار RMSE برای روابط تجربی پیشین در بازه‌ای بین ۲۱/۹ تا ۵۵/۱ قرار دارد، در حالی که معادله ارائه‌شده توسط آنان مقدار RMSE برابر با ۵/۱ را به دست آورده است (جدول ۳).

Table 3. A comparison of RMSE values between the validated data analysis in previous research and the values obtained from Boost model

Statistics	Rosas et al.	Wang et al.	Hazen	Slichter	Terzaghi	Beyer	Kozeny-Carman	Chapuis	Karrabi and Tabatabai	Boost model
RMSE	30.7	30	48	28.8	27.4	55.1	21.9	35.1	5.1	2.8

در پژوهش حاضر، مدل یادگیری ماشین منتخب مقدار RMSE برابر ۲/۸ را نشان داد. این مقدار بیانگر بهبود دقت پیش‌بینی هدایت هیدرولیکی بستر رودخانه نسبت به روابط تجربی پیشین و حتی مدل پیشنهادی آن مطالعه است. کاهش مقدار RMSE از ۵/۱ به ۲/۸ نشان می‌دهد که مدل یادگیری ماشین توسعه‌یافته در این پژوهش توانسته است روابط غیرخطی و پیچیده بین ویژگی‌های رسوبی و هدایت هیدرولیکی را با دقت بیشتری شناسایی کند.

۵- نتیجه‌گیری

در این پژوهش، هدایت هیدرولیکی عمودی بستر رودخانه‌های فصلی با استفاده از الگوریتم‌های یادگیری ماشین و با در نظر گرفتن ناهمگنی‌های مورفولوژیکی مدل‌سازی شد. برای آنکه عملکرد مدل تحت تأثیر ناهمگنی ذاتی بسترهای فصلی پنهان نماند، فرآیند آموزش و آزمون به‌طور کاملاً مستقل برای هر واحد مورفولوژیکی (کانال اصلی و پشته رسوبی) تکرار شد تا پایداری پیش‌بینی‌ها در هر رژیم رسوبی ارزیابی گردد. بهینه‌سازی تطبیقی پارامترها نیز برای پاسخ‌گویی به اندازه‌های متفاوت نمونه‌ها و پراکندگی در این دو واحد انجام شده، که یک واکنش مستقیم به ساختار داده‌های ناهمگن رودخانه‌های فصلی است. نتایج نشان داد که مدل مبتنی بر تقویت، قادر است روابط غیرخطی بین ویژگی‌های رسوبی، ساختاری و هیدرولیکی بستر را با دقت و پایداری مناسب بازنمایی کند، مشروط بر آنکه عدم قطعیت ناشی از ناهمگنی فضایی به‌طور صریح مورد ارزیابی قرار گیرد. ارزیابی عملکرد مدل با استفاده از چندین روش اعتبارسنجی متقاطع نشان داد که دقت پیش‌بینی و پایداری مدل به‌طور معناداری به واحد مورفولوژیکی وابسته است. در پشته‌های رسوبی، عملکرد پایدارتر مدل و عدم قطعیت کمتر بیانگر یکنواختی نسبی ساختار رسوبی و مسیرهای جریان عمودی است، در حالی که در کانال اصلی، پیچیدگی‌های هیدرودینامیکی و بازآرایی مداوم بستر منجر به افزایش ناهمگنی مؤثر و کاهش قابلیت

پیش‌بینی‌پذیری K_v می‌شود. این تفاوت‌ها بازتابی از محدودیت‌های فیزیکی فرآیند نفوذ در محیط‌های با تنش برشی متغیر است و لزوماً به ضعف مدل نسبت داده نمی‌شود. تحلیل حساسیت نشان داد که شاخص‌های مرتبط با ساختار تخلخل مؤثر و هندسه مسیرهای جریان، به‌ویژه پارامترهای m_p و A_r ، همراه با صدک ریز دانه‌بندی (d_{10})، نقش غالبی در کنترل هدایت هیدرولیکی عمودی دارند. این یافته‌ها با مبانی هیدرولیکی نفوذ در محیط‌های متخلخل سازگار بوده و نشان می‌دهد که K_v بیش از آنکه تابع تخلخل حجمی یا اندازه متوسط دانه‌ها باشد، تحت تأثیر پیوستگی هیدرولیکی و گلوگاه‌های ریز نفوذپذیری قرار دارد. تفاوت الگوی اهمیت متغیرها بین کانال اصلی و پشته‌های رسوبی نیز بر نقش تعیین‌کننده ناهمگنی مورفولوژیکی در کنترل تبادل جریان سطحی-زیرسطحی تأکید می‌کند.

۶- پانوش‌ها

-
- ¹ flash floods
 - ² Particle Size Distribution
 - ³ Armoring
 - ⁴ Mud percent
 - ⁵ falling-head
 - ⁶ constant-head
 - ⁷ main channel
 - ⁸ bar
 - ⁹ Machine learning
 - ¹⁰ Random forest
 - ¹¹ eXtreme Gradient Boosting (XGBoost)
 - ¹² particle size distributions
 - ¹³ pedotransfer functions
 - ¹⁴ boosted regression tree
 - ¹⁵ source-wise validation
 - ¹⁶ Multilayer perceptron
 - ¹⁷ Support Vector Machine
 - ¹⁸ SHapley Additive exPlanations
 - ¹⁹ Pearson Correlation Coefficient
 - ²⁰ Spearman's rank-order correlation
 - ²¹ Cross-Validation
 - ²² resampling
 - ²³ hyperparameter tuning
 - ²⁴ Bayesian
 - ²⁵ trade-off
 - ²⁶ Artificial Neural Networks
 - ²⁷ Boosting Regression Tree
 - ²⁸ Cooperative Game Theory
 - ²⁹ permutation-based
 - ³⁰ Out-Of-Bag Error

- Araya, S. N., & Ghezzehei, T. A. (2019). Using Machine Learning for Prediction of Saturated Hydraulic Conductivity and Its Sensitivity to Soil Structural Perturbations. *Water Resources Research*, 55(7), 5715–5737. <https://doi.org/10.1029/2018WR024357>
- ASCE Task Committee, N. (2000). Artificial Neural Networks in Hydrology. I: Preliminary Concepts. *Journal of Hydrologic Engineering*, 5(2), 115–123. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2000\)5:2\(115\)](https://doi.org/10.1061/(ASCE)1084-0699(2000)5:2(115))
- Bischl, B., Binder, M., Lang, M., Pielok, T., Richter, J., Coors, S., Thomas, J., Ullmann, T., Becker, M., Boulesteix, A.-L., Deng, D., & Lindauer, M. (2023). Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges. *WIREs Data Mining and Knowledge Discovery*, 13(2), e1484. <https://doi.org/10.1002/widm.1484>
- Botula, Y.-D., Nemes, A., Mafuka, P., Van Ranst, E., & Cornelis, W. M. (2013). Prediction of Water Retention of Soils from the Humid Tropics by the Nonparametric k-Nearest Neighbor Approach. *Vadose Zone Journal*, 12(2), vzj2012.0123. <https://doi.org/10.2136/vzj2012.0123>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, L., Friedman, J., Olshen, R. A., & Stone, C. J. (2017). *Classification and Regression Trees*. Chapman and Hall/CRC. <https://doi.org/10.1201/9781315139470>
- Bridge, J. S. (2007). *Rivers and floodplains: Forms, processes, and sedimentary record* (3. [print.]). Blackwell.
- Bridge, J. S., & Lunt, I. A. (2006). Depositional Models of Braided Rivers. In *Braided Rivers* (pp. 11–50). John Wiley & Sons, Ltd. <https://doi.org/10.1002/9781444304374.ch2>
- Brunner, P., Therrien, R., Renard, P., Simmons, C. T., & Franssen, H.-J. H. (2017). Advances in understanding river-groundwater interactions. *Reviews of Geophysics*, 55(3), 818–854. <https://doi.org/10.1002/2017RG000556>
- Bunte, K., & Abt, S. R. (2001). Sampling surface and subsurface particle-size distributions in wadable gravel- and cobble-bed streams for analyses in sediment transport, hydraulics, and streambed monitoring. *Gen. Tech. Rep. RMRS-GTR-74*. Fort Collins, CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. 428 p., 74. <https://doi.org/10.2737/RMRS-GTR-74>
- Cabalar, A. F., & Akbulut, N. (2016). Evaluation of actual and estimated hydraulic conductivity of sands with different gradation and shape. *SpringerPlus*, 5(1), 820. <https://doi.org/10.1186/s40064-016-2472-2>
- Cawley, G. C., & Talbot, N. L. C. (2010). On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation. *J. Mach. Learn. Res.*, 11, 2079–2107.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Chandel, A., & Shankar, V. (2022). Evaluation of empirical relationships to estimate the hydraulic conductivity of borehole soil samples. *ISH Journal of Hydraulic Engineering*, 28(4), 368–377. <https://doi.org/10.1080/09715010.2021.1902872>
- Chaney, N. W., Minasny, B., Herman, J. D., Nauman, T. W., Brungard, C. W., Morgan, C. L. S., McBratney, A. B., Wood, E. F., & Yimam, Y. (2019). POLARIS Soil Properties: 30-m Probabilistic Maps of Soil Properties Over the Contiguous United States. *Water Resources Research*, 55(4), 2916–2938. <https://doi.org/10.1029/2018WR022797>
- Chen, T., & Guestrin, C. (2016a). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '16*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, T., & Guestrin, C. (2016b). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '16*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, X. (2005). Statistical and geostatistical features of streambed hydraulic conductivities in the Platte River, Nebraska. *Environmental Geology*, 48(6), 693–701.

Chen, X., Song, J., & Wang, W. (2010). Spatial variability of specific yield and vertical hydraulic conductivity in a highly permeable alluvial aquifer. *Journal of Hydrology*, 388(3–4), 379–388. <https://doi.org/10.1016/j.jhydrol.2010.05.017>

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>

Datry, T., Bonada, N., & Boulton, A. (Eds.). (2017). *Intermittent rivers and ephemeral streams: Ecology and management*. Academic Press, an imprint of Elsevier.

Dawson, C. W., & Wilby, R. L. (2001). Hydrological modelling using artificial neural networks. *Progress in Physical Geography: Earth and Environment*, 25(1), 80–108. <https://doi.org/10.1177/030913330102500104>

De Rijk, V., Buma, J., Veldkamp, H., & Zech, A. (2025). Predicting saturated hydraulic conductivity from particle size distributions using machine learning. *Stochastic Environmental Research and Risk Assessment*, 39(2), 423–435. <https://doi.org/10.1007/s00477-024-02861-6>

Devlin, J. F. (2015). HydrogeoSieveXL: An Excel-based tool to estimate hydraulic conductivity from grain-size analysis. *Hydrogeology Journal*, 23(4), 837–844. <https://doi.org/10.1007/s10040-015-1255-0>

Efron, B., & Tibshirani, R. J. (1994). *An Introduction to the Bootstrap*. Chapman and Hall/CRC. <https://doi.org/10.1201/9780429246593>

Elshorbagy, A., Corzo, G., Srinivasulu, S., & Solomatine, D. P. (2010). Experimental investigation of the predictive capabilities of data driven modeling techniques in hydrology - Part 1: Concepts and methodology. *Hydrology and Earth System Sciences*, 14(10), 1931–1941. <https://doi.org/10.5194/hess-14-1931-2010>

Freeze, R. A., & Cherry, J. A. (1979). *Groundwater*. Prentice-Hall.

Genereux, D. P., Leahy, S., Mitsova, H., Kennedy, C. D., & Corbett, D. R. (2008). Spatial and temporal variability of streambed hydraulic conductivity in West Bear Creek, North Carolina, USA. *Journal of Hydrology*, 358(3–4), 332–353. <https://doi.org/10.1016/j.jhydrol.2008.06.017>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. The MIT press.

Granata, F., Nunno, F. D., & Modoni, G. (2022). Hybrid Machine Learning Models for Soil Saturated Conductivity Prediction. *Water*, 14(11). <https://doi.org/10.3390/w14111729>

Hassan, M. A. (2005). Characteristics of Gravel Bars in Ephemeral Streams. *Journal of Sedimentary Research*, 75(1), 29–42. <https://doi.org/10.2110/jsr.2005.004>

Hassan, M. A., & Church, M. (2000). Experiments on surface structure and partial sediment transport on a gravel bed. *Water Resources Research*, 36(7), 1885–1895. <https://doi.org/10.1029/2000WR900055>

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer. <https://doi.org/10.1007/978-0-387-84858-7>

Hazen, A. (1892). *Some Physical Properties of Sands and Gravels, with Special Reference to Their Use in Filtration* (24th Annual Report; pp. 539–556). Massachusetts State Board of Health.

Hengl, T., Jesus, J. M. de, Heuvelink, G. B. M., Gonzalez, M. R., Kilibarda, M., Blagotić, A., Shangguan, W., Wright, M. N., Geng, X., Bauer-Marschallinger, B., Guevara, M. A., Vargas, R., MacMillan, R. A., Batjes, N. H., Leenaars, J. G. B., Ribeiro, E., Wheeler, I., Mantel, S., & Kempen, B. (2017). SoilGrids250m: Global gridded soil information based on machine learning. *PLOS ONE*, 12(2), e0169748. <https://doi.org/10.1371/journal.pone.0169748>

Hiscock, K. M., & Bense, V. F. (2021). *Hydrogeology: Principles and practice* (Third edition). Wiley Blackwell.

Hvorslev, M. J. (1951). *TIME LAG AND SOIL PERMEABILITY IN GROUND-WATER OBSERVATIONS*. <https://trid.trb.org/View/124794>

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning* (Vol. 103). Springer. <https://doi.org/10.1007/978-1-4614-7138-7>

Jorda, H., Bechtold, M., Jarvis, N., & Koestel, J. (2015). Using boosted regression trees to explore key factors controlling saturated and near-saturated hydraulic conductivity. *European Journal of Soil Science*, 66(4), 744–756. <https://doi.org/10.1111/ejss.12249>

Kaingo, J., Tumbo, S. D., Kihupi, N. I., & Mbilinyi, B. P. (2018). Prediction of Soil Moisture-Holding Capacity with Support Vector Machines in Dry Subhumid Tropics. *Applied and Environmental Soil Science*, 2018(1), 9263296. <https://doi.org/10.1155/2018/9263296>

Karrabi, E., & Tabatabai, M. R. M. (2025). Empirical modeling of streambed hydraulic conductivity in ephemeral rivers: Insights from sediment characteristics in arid environments. *Earth Surface Processes and Landforms*, 50(3), e70005. <https://doi.org/10.1002/esp.70005>

Khlosi, M., Alhamdoosh, M., Douaik, A., Gabriels, D., & Cornelis, W. M. (2016). Enhanced pedotransfer functions with support vector machines to predict water retention of calcareous soil. *European Journal of Soil Science*, 67(3), 276–284. <https://doi.org/10.1111/ejss.12345>

Kleinhans, M. G., Wilbers, A. W. E., De Swaaf, A., & Van Den Berg, J. H. (2002). Sediment supply-limited bedforms in sand-gravel bed rivers. *Journal of Sedimentary Research*, 72(5), 629–640.

Koestel, J., & Jorda, H. (2014). What determines the strength of preferential transport in undisturbed soil under steady-state flow? *Geoderma*, 217–218, 144–160. <https://doi.org/10.1016/j.geoderma.2013.11.009>

Korus, J. T., Fraundorfer, W. P., Gilmore, T. E., & Karnik, K. (2020). Transient streambed hydraulic conductivity in channel and bar environments, Loup River, Nebraska. *Hydrological Processes*, 34(14), 3061–3077. <https://doi.org/10.1002/hyp.13777>

Korus, J. T., Gilmore, T. E., Waszgis, M. M., & Mittelstet, A. R. (2018). Unit-bar migration and bar-trough deposition: Impacts on hydraulic conductivity and grain size heterogeneity in a sandy streambed. *Hydrogeology Journal*, 26(2), 553–564. <https://doi.org/10.1007/s10040-017-1661-6>

Kotlar, A. M., Iversen, B. V., & de Jong van Lier, Q. (2019). Evaluation of Parametric and Nonparametric Machine-Learning Techniques for Prediction of Saturated and Near-Saturated Hydraulic Conductivity. *Vadose Zone Journal*, 18(1), 180141. <https://doi.org/10.2136/vzj2018.07.0141>

Kozeny, J. (1953). Das Wasser im Boden. Grundwasserbewegung. In J. Kozeny (Ed.), *Hydraulik: Ihre Grundlagen und praktische Anwendung* (pp. 380–445). Springer. https://doi.org/10.1007/978-3-7091-7592-7_10

Lundberg, S., & Lee, S.-I. (2017). *A Unified Approach to Interpreting Model Predictions* (arXiv:1705.07874). arXiv. <https://doi.org/10.48550/arXiv.1705.07874>

Lunt, I. A., & Bridge, J. S. (2004). Evolution and deposits of a gravelly braid bar, Sagavanirktok River, Alaska. *Sedimentology*, 51(3), 415–432. <https://doi.org/10.1111/j.1365-3091.2004.00628.x>

Mady, A. Y., & Shein, E. V. (2018). Support Vector Machine and Nonlinear Regression Methods for Estimating Saturated Hydraulic Conductivity. *Moscow University Soil Science Bulletin*, 73(3), 129–133. <https://doi.org/10.3103/S0147687418030079>

Mangalathu, S., Hwang, S.-H., & Jeon, J.-S. (2020). Failure mode and effects analysis of RC members based on machine-learning-based SHapley Additive exPlanations (SHAP) approach. *Engineering Structures*, 219, 110927. <https://doi.org/10.1016/j.engstruct.2020.110927>

Mao, L. (2012). The effect of hydrographs on bed load transport and bed sediment spatial arrangement. *Journal of Geophysical Research: Earth Surface*, 117(F3). <https://doi.org/10.1029/2012JF002428>

Molnar, C. (2025). *Interpretable machine learning: A guide for making black box models explainable* (3rd edition). Christoph Molnar.

Nemes, A., Roberts, R. T., Rawls, W. J., Pachepsky, Ya. A., & van Genuchten, M. Th. (2008). Software to estimate –33 and –1500 kPa soil water retention using the non-parametric *k*-Nearest Neighbor technique. *Environmental Modelling & Software*, 23(2), 254–255. <https://doi.org/10.1016/j.envsoft.2007.05.018>

Nohara, Y., Matsumoto, K., Soejima, H., & Nakashima, N. (2022). Explanation of machine learning models using shapley additive explanation and application for real data in hospital. *Computer Methods and Programs in Biomedicine*, 214, 106584. <https://doi.org/10.1016/j.cmpb.2021.106584>

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12(85), 2825–2830.

Probst, P., Wright, M. N., & Boulesteix, A.-L. (2019). Hyperparameters and tuning strategies for

random forest. *WIREs Data Mining and Knowledge Discovery*, 9(3), e1301. <https://doi.org/10.1002/widm.1301>

Refaeilzadeh, P., Tang, L., & Liu, H. (2009). Cross-Validation. In *Encyclopedia of Database Systems* (pp. 532–538). Springer, Boston, MA. https://doi.org/10.1007/978-0-387-39940-9_565

Rice, S. P., Church, M., Wooldridge, C. L., & Hickin, E. J. (2009). Morphology and evolution of bars in a wandering gravel-bed river; lower Fraser river, British Columbia, Canada. *Sedimentology*, 56(3), 709–736. <https://doi.org/10.1111/j.1365-3091.2008.00994.x>

Rosas, J., Jadoon, K. Z., & Missimer, T. M. (2015). New empirical relationship between grain size distribution and hydraulic conductivity for ephemeral streambed sediments. *Environmental Earth Sciences*, 73(3), 1303–1315. <https://doi.org/10.1007/s12665-014-3484-2>

Russell, S. J., & Norvig, P. (with Chang, M., Devlin, J., Dragan, A., Forsyth, D., Goodfellow, I., Malik, J., Mansinghka, V., Pearl, J., & Wooldridge, M. J.). (2021). *Artificial intelligence: A modern approach* (Fourth Edition). Pearson.

Salih, A. M., Raisi-Estabragh, Z., Galazzo, I. B., Radeva, P., Petersen, S. E., Lekadir, K., & Menegaz, G. (2025). A Perspective on Explainable Artificial Intelligence Methods: SHAP and LIME. *Advanced Intelligent Systems*, 7(1), 2400304. <https://doi.org/10.1002/aisy.202400304>

Sebok, E., Duque, C., Engesgaard, P., & Boegh, E. (2015). Spatial variability in streambed hydraulic conductivity of contrasting stream morphologies: Channel bend and straight channel. *Hydrological Processes*, 29(3), 458–472. <https://doi.org/10.1002/hyp.10170>

Shanfield, M., Bourke, S. A., Zimmer, M. A., & Costigan, K. H. (2021). An overview of the hydrology of non-perennial rivers and streams. *WIREs Water*, 8(2), e1504. <https://doi.org/10.1002/wat2.1504>

Shanfield, M., & Cook, P. G. (2014). Transmission losses, infiltration and groundwater recharge through ephemeral and intermittent streambeds: A review of applied methods. *Journal of Hydrology*, 511, 518–529. <https://doi.org/10.1016/j.jhydrol.2014.01.068>

Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222. <https://doi.org/10.1023/B:STCO.0000035301.49549.88>

Song, J., Wang, L., Dou, X., Wang, F., Guo, H., Zhang, J., Zhang, G., Liu, Q., & Zhang, B. (2018). Spatial and depth variability of streambed vertical hydraulic conductivity under the regional flow regimes. *Hydrological Processes*, 32(19), 3006–3018. <https://doi.org/10.1002/hyp.13241>

Szabó, B., Szatmári, G., Takács, K., Laborci, A., Makó, A., Rajkai, K., & Pásztor, L. (2019). Mapping soil hydraulic properties using random-forest-based pedotransfer functions and geostatistics. *Hydrology and Earth System Sciences*, 23(6), 2615–2635. <https://doi.org/10.5194/hess-23-2615-2019>

Tahmasebi, P., Kamrava, S., Bai, T., & Sahimi, M. (2020). Machine learning in geo- and environmental sciences: From small to large scale. *Advances in Water Resources*, 142, 103619. <https://doi.org/10.1016/j.advwatres.2020.103619>

Twarakavi, N. K. C., Šimůnek, J., & Schaap, M. G. (2009). Development of Pedotransfer Functions for Estimation of Soil Hydraulic Parameters using Support Vector Machines. *Soil Science Society of America Journal*, 73(5), 1443–1452. <https://doi.org/10.2136/sssaj2008.0021>

Vabalas, A., Gowen, E., Poliakoff, E., & Casson, A. J. (2019). Machine learning algorithm validation with a limited sample size. *PLOS ONE*, 14(11), e0224365. <https://doi.org/10.1371/journal.pone.0224365>

Vienken, T., & Dietrich, P. (2011). Field evaluation of methods for determining hydraulic conductivity from grain size data. *Journal of Hydrology*, 400(1), 58–71. <https://doi.org/10.1016/j.jhydrol.2011.01.022>

Vukovic, M., & Soro, A. (1992). *Determination of Hydraulic Conductivity of Porous Media from Grain-size Composition*. Water Resources Publications.

Wang, L., Song, J., Zhang, B., Guo, H., Jiang, W., Wen, M., & Zhang, G. (2016). Spatial and Temporal Variations of Streambed Vertical Hydraulic Conductivity in the Weihe River, China. *Water*, 8(3), 70. <https://doi.org/10.3390/w8030070>

Wittenberg, L., & Newson, M. D. (2005). Particle clusters in gravel-bed rivers: An experimental morphological approach to bed material transport and stability concepts. *Earth Surface Processes and Landforms*, 30(11), 1351–1368. <https://doi.org/10.1002/esp.1184>

آگاهانه انتشار