



انجمن علوم و مهندسی منابع آب ایران

## ارزیابی عملکرد مدل یادگیری ماشین تقویت گرادیان شدید در پیش‌بینی زمانی ارتفاع بارش با هدف بهبود دقت تخمین بارش در مناطق بدون داده

امیرحسین حدادی<sup>۱</sup> - محمد دانش یزدی<sup>۲\*</sup>

<sup>۱</sup> دانشجوی کارشناسی مهندسی عمران، دانشکده مهندسی عمران، دانشگاه صنعتی شریف.

<sup>۲\*</sup> دانشیار، گروه مهندسی آب و محیط‌زیست، دانشکده مهندسی عمران، دانشگاه صنعتی شریف. ایمیل: danesh@sharif.edu

### چکیده

تخمین ارتفاع بارش در مناطق فاقد اندازه‌گیری میدانی، به دلیل کاربرد وسیع آن در موضوعات مرتبط با مدیریت منابع آب، اهمیت فراوانی دارد. در این پژوهش، کارایی الگوریتم یادگیری ماشین تقویت گرادیان شدید (XGBoost) برای پیش‌بینی ارتفاع بارش در افق‌های پیش‌بینی کوتاه‌مدت، از مقیاس روزانه تا میانگین هفت‌روزه در حوضه آبریز کرخه ارزیابی شده است. برای این منظور، از داده‌های سه‌ساعته بارش، دمای هوا و رطوبت نسبی ثبت‌شده در ایستگاه‌های سینوپتیک حوضه در بازه زمانی دی‌ماه ۱۳۷۹ تا بهمن‌ماه ۱۴۰۲ استفاده شد. سپس مراحل پیش‌پردازش داده شامل تکمیل داده‌های ثبت نشده توسط ایستگاه‌ها، تبدیل داده‌های سه‌ساعته‌ی بارش، رطوبت نسبی و دمای هوای به روزانه، و حذف داده‌های پرت انجام شد. همچنین برای لحاظ کردن اثر تاریخی بارش، رطوبت نسبی و دمای هوا در پیش‌بینی بارش روز جاری، وقفه‌های زمانی یک تا هفت روز گذشته به داده‌ها اعمال شد و در قالب هفت سناریوی مختلف، این داده‌ها به‌عنوان ورودی‌های مدل یادگیری ماشین آماده شدند. نتایج بخش آزمون نشان داد که دقت پیش‌بینی مدل با استفاده‌ی هر چه بیشتر از اطلاعات تاریخی افزایش می‌یابد؛ به‌طوری‌که در سناریوی هفت‌روزه، مدل با مقدار  $R^2=0.93$ ،  $RMSE=0.41$  میلی‌متر و  $MAE=0.19$  میلی‌متر نسبت به سناریوی یک‌روزه با شاخص‌های  $R^2=0.46$ ،  $RMSE=1.13$  میلی‌متر و  $MAE=0.61$  میلی‌متر عملکرد دقیق‌تری در پیش‌بینی زمانی بارش‌ها نشان داد.

**کلمات کلیدی:** پیش‌بینی ارتفاع بارش، یادگیری ماشین، تقویت گرادیان شدید (XGBoost)، حوضه آبریز کرخه.

پیش‌بینی هر چه دقیق‌تر ارتفاع بارش در کوتاه‌مدت و بلندمدت، نقش کلیدی در کاربردهای مختلف مرتبط با مدیریت منابع آب مانند برآورد حجم منابع آب تجدیدپذیر، برنامه‌ریزی برای تخصیص بهینه منابع، توسعه سامانه‌های پیش‌بینی و هشدار زودهنگام سیل، توسعه انواع مدل‌های هیدرولوژیکی، و ارزیابی تأثیر تغییرات اقلیمی بر چرخه آب ایفا می‌کند (Latif et al., 2023; Yu et al., 2025). کیفیت داده‌های بارش، به‌ویژه در مناطق با توپوگرافی پیچیده، تأثیر قابل توجهی بر دقت پیش‌بینی شدت رواناب حاصل از انواع مختلف فرایندها مانند ذوب برف و نهایتاً کاهش عدم قطعیت مرتبط با آن دارد (Ougahi and Rowan, 2025).

در سال‌های اخیر، روش‌های مبتنی بر یادگیری ماشین به عنوان ابزاری کارا برای پیش‌بینی زمانی بارش مطرح شده‌اند و قادرند الگوهای پنهان در داده‌های تاریخی آب‌وهوا را استخراج کنند (Rahman et al., 2022). این روش‌ها در غلبه بر چالش‌های مدل‌های سنتی پیش‌بینی عددی آب‌وهوا، مانند مدل عددی گردش عمومی جو (GCAMs)، به ویژه در مناطق با الگوهای اقلیمی پیچیده، امیدبخش بوده‌اند (Anochi et al., 2021). به طور مشخص، روش‌های مختلفی از جمله درخت‌های تصمیم ( $DT^1$ )، بیز ساده ( $NB^2$ )، نزدیک‌ترین همسایه ( $KNN^3$ )، ماشین‌های بردار پشتیبان ( $SVM^4$ ) و درخت‌های تصمیم با تقویت گرادیان در پیش‌بینی باران مورد استفاده قرار گرفته‌اند (Monego et al., 2022; Rahman et al., 2022). علاوه بر این، برخی مدل‌های یادگیری ماشینی مانند شبکه‌های عصبی مصنوعی ( $ANN^5$ ) و SVM به‌عنوان رقیبی برای مدل‌های سنتی مانند مدل‌های آماری مثل رگرسیون خطی، کرایجینگ و مدل‌های فرایندی (مانند  $NWP^6$ ) پیشنهاد شده‌اند (Chen et al., 2023). به عنوان نمونه، نتایج پیش‌بینی بارش‌ها برای سال‌های ۲۰۱۸ و ۲۰۱۹ در برزیل نشان می‌دهد که استفاده از یادگیری ماشین و شبکه‌های عصبی موجب کاهش خطای جذر میانگین مربعات ( $RMSE^7$ ) پیش‌بینی در فصول مختلف سال شده است. این نتایج نشان می‌دهند که مدل‌های یادگیری ماشین قادر به کاهش خطاهای پیش‌بینی در شرایط مختلف آب و هوایی بوده و عملکرد بهتری نسبت به مدل سنتی ارائه داده‌اند (Anochi et al., 2021). در پژوهش دیگری در اسپانیا، عملکرد الگوریتم‌های یادگیری ماشین جنگل تصادفی ( $RF^8$ ) و گرادیان تقویت‌شده شدید ( $XGBoost^9$ ) مقابل مدل‌های آماری خطی سنتی ( $GLA^{10}$  و  $LDA^{11}$ ) و همچنین مدل‌های طبقه‌بندی متعارف Logistic Model Tree و SVM مقایسه گردید؛ نتایج مجموعه آزمون نشان داد دقیق‌ترین الگوریتم، یعنی  $XGBoost$ ، نسبت به بهترین مدل خطی ( $LDA$ ) خطای طبقه‌بندی را توانسته است بیش از ۱۰ درصد کاهش دهد (Aguasca-Colomo et al., 2019). در مناطقی مانند اتیوپی که الگوهای بارش ناپایدار بر کشاورزی تأثیر قابل توجهی می‌گذارند، مدل‌های یادگیری ماشینی مانند  $RF$  و  $XGBoost$  به‌طور موفقیت‌آمیز برای پیش‌بینی مقادیر روزانه بارش اعمال شده‌اند و بهبود برنامه‌ریزی کشاورزی و مدیریت منابع آبی را فراهم کرده‌اند (Liyew and Melese, 2021).

علی‌رغم مزیت‌های مدل‌های مذکور، پیش‌بینی متغیرهای هیدرولوژیکی به دلیل ماهیت غیرخطیشان، همواره با چالش‌های جدی مواجه بوده است. یکی از روش‌های مواجهه با این چالش، افزودن وقفه‌های زمانی و ویژگی‌های مشتق‌شده از ساختار زمانی داده‌های ورودی می‌باشد که باعث می‌شود مدل توانایی آموزش با داده‌های مرتبط با روزهای گذشته و الگوهای گذشته را داشته باشد (Aderyani et al., 2022). به عنوان مثال، در پژوهش Kumar et al., (2023) ساختار ورودی تمامی مدل‌ها بر پایه داده‌های تاریخی بارش تنظیم شده است؛ به‌گونه‌ای



که برای پیش‌بینی بارش به صورت روزانه، مدل‌ها از مقادیر بارش در روزهای گذشته و برای پیش‌بینی بارش به صورت هفتگی از مقادیر بارش در هفته‌های گذشته استفاده شده است. الگوریتم‌های مبتنی بر تقویت کننده‌ها<sup>۱۳</sup> مانند CatBoost و XGBoost با استخراج روابط غیرخطی میان این وقفه‌ها توانستند به دقت زیاد دست یابند. در کنار پیش‌پردازش<sup>۱۴</sup> ورودی‌ها، هموارسازی<sup>۱۵</sup> سری زمانی متغیر هدف نیز در برخی مطالعات نقش مهمی در بهبود دقت مدل‌های داده‌محور داشته است. نوسانات شدید، مقادیر پرت و خطاهای اندازه‌گیری در سری‌های زمانی، اغلب باعث می‌شود مدل‌های یادگیری ماشین به جای یادگیری الگوی اصلی، بر نویزهای کوتاه‌مدت متمرکز شوند. به‌عنوان مثال، Yang et al., (2023) با هدف ارائه‌ی یک چهارچوب داده‌محور برای پیش‌بینی شاخص‌های کیفیت آب در یک تالاب مصنوعی، رفتار آلاینده‌ها (مانند  $\text{NH}_4^+-\text{N}$ ، COD و TP) در سری زمانی‌شان را بسیار پرنوسان، ناپایدار و غیرخطی وصف کرده و برای پیش‌بینی دقیق آن‌ها، ترکیبی از مدل‌های یادگیری ماشین، روش‌های یادگیری عمیق و یک فرایند پیش‌پردازش مبتنی بر هموارسازی داده‌ها را مورد استفاده قرار داده‌اند. اعمال روشی مشابه برای سری‌های زمانی بارش می‌تواند موجب کاهش اثرگذاری نویزها بر فرایند آموزش، برجسته‌سازی روند اصلی و جلوگیری از تمرکز مدل بر تغییرات لحظه‌ای می‌شود و نهایتاً عملکرد و دقت مدل‌های یادگیری ماشین را ارتقا دهد.

اگر چه نتایج تحقیقات پیشین نشان می‌دهند که یادگیری ماشین رویکردی موفقیت‌آمیز برای بهبود پیش‌بینی متغیرهای آب و هوایی مانند بارش در مناطق جغرافیایی مختلف است (Shah et al., 2018)، اما چالش‌های جدی و عدم قطعیت‌هایی در این زمینه همچنان وجود دارد. از این چالش‌ها می‌توان به نیاز به داده‌های کافی و با کیفیت برای آموزش مدل‌ها، امکان بیش‌برازش مدل به‌ویژه در صورت کمبود داده یا وجود خطا در داده‌ای آموزشی، تفسیرناپذیری فیزیکی، و عدم امکان ارائه‌ی پیش‌بینی قابل اعتماد تحت شرایطی که مدل با آن آموزش داده نشده است، اشاره نمود. به عبارت دیگر، عملکرد این مدل‌ها ممکن است در شرایط جغرافیایی، اقلیمی یا زمانی متفاوت کاهش یابد، چرا که به داده‌های آموزشی حساس بوده و تعمیم‌پذیری محدودی در مواجهه با الگوهای جدید یا نادیده دارند (Bochenek and Ustrnul, 2022). تاکنون از منابع داده‌ی متنوعی برای توسعه‌ی مدل‌های یادگیری ماشین استفاده شده است. این ورودی‌ها شامل داده‌های بازتحلیل مانند ERA5، NCEP/NCAR، MERRA-2، داده‌های هواشناسی ثبت شده توسط ایستگاه‌های زمینی نظیر دمای هوا، رطوبت نسبی هوا، فشار هوا، سرعت و جهت باد، بارش، پوشش ابر و میزان تابش خورشیدی می‌باشند. ترکیب این ورودی‌ها با هدف بهبود پیش‌بینی بارش، تشخیص الگوهای اقلیمی و افزایش دقت مدل‌های پیش‌بینی کوتاه‌مدت و بلندمدت آب‌وهوایی به کار گرفته شده‌اند.

این پژوهش با بررسی عملکرد مدل یادگیری ماشین تقویت‌گرایان شدید (XGBoost) و در نظر گرفتن تأثیر بارش روزهای گذشته بر دقت پیش‌بینی زمانی بارش در حوضه آبریز کرخه، توانایی یکی از مدل‌های پیشرفته یادگیری ماشین در پیش‌بینی روزانه تا میانگین هفت روزه بارش را ارزیابی می‌کند. تکمیل داده‌های ثبت‌نشده بارش در ایستگاه‌های مختلف و به‌کارگیری روش میانگین متحرک برای هموارسازی بارش هدف، به ترتیب به بهبود کیفیت داده‌های ورودی و کاهش نویزهای کوتاه‌مدت منجر شده و زمینه را برای بهبود عملکرد مدل‌های پیش‌بینی فراهم می‌کند. همچنین، سناریوهای مختلفی برای در نظر گرفتن تأثیر تاریخچه بارش، رطوبت نسبی و دمای هوا بر دقت پیش‌بینی مدل در نظر گرفته شد، به طوری که این متغیرها با تأخیر زمانی یک تا هفت روز به‌عنوان ورودی مدل استفاده شدند. به این ترتیب، مجموعه رویکردهای به‌کاررفته در این پژوهش چهارچوبی فراهم می‌آورد که در مطالعات مشابه به‌صورت یکپارچه انجام نشده است. هدف از طراحی

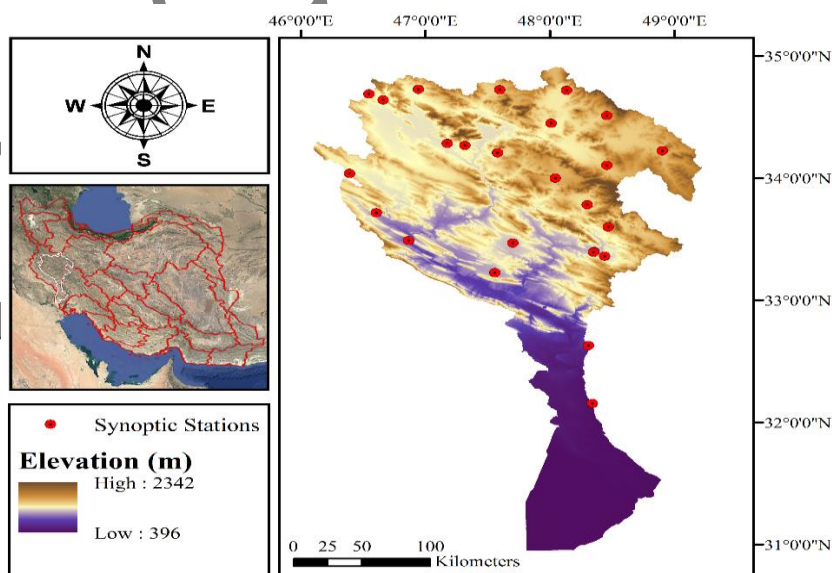
این سناریوها، درک و تحلیل روابط میان عوامل محیطی مانند دمای هوا و رطوبت نسبی با بارش است تا توانایی مدل یادگیری ماشین مورد نظر را متناسب با شرایط توپوگرافی و بارش حوضه آبریز کرخه ارزیابی و مقایسه نموده و در نهایت پیش‌بینی بارش را با کمترین خطا و بیشترین دقت انجام دهد.

## ۲ روش تحقیق

### ۲-۱ منطقه مورد مطالعه

حوضه آبریز کرخه که به نام کرخه بزرگ نیز شناخته می‌شود، حوضه آبریز درجه دو و از زیرمجموعه‌ی حوضه‌های آبریز خلیج فارس و دریای عمان محسوب می‌شود. از نظر موقعیت مکانی، این حوضه در غرب کشور و در نواحی میانی و جنوب غربی رشته کوه‌های زاگرس واقع شده است و از نظر مختصات جغرافیایی، در محدوده طول‌های شرقی ۴۶ درجه و ۶ دقیقه تا ۴۹ درجه و ۱۰ دقیقه و عرض‌های شمالی ۳۰ درجه و ۵۸ دقیقه تا ۳۴ درجه و ۵۶ دقیقه قرار دارد. مناطق مرتفع عمدتاً در قسمت شمال شرقی این زیرحوضه قرار دارند، در حالی که مناطق پست‌تر در نواحی غربی و جنوبی واقع شده‌اند این حوضه با میانگین بارندگی و تبخیر-تعرق ۵۲۵ میلی‌متر در سال و ۱۳۳ میلی‌متر در سال در رده اقلیم نیمه‌خشک قرار می‌گیرد (Bayat-Afshary et al., 2022). حوضه آبریز کرخه بخش‌های زیادی از استان‌های لرستان و کرمانشاه و نواحی از استان‌های کردستان، همدان، ایلام و خوزستان را در بر می‌گیرد. موقعیت جغرافیایی حوضه آبریز کرخه و ایستگاه‌های سینوپتیک واقع در آن در

شکل ۱ نشان داده شده است.



**Fig .1- Geographical location of the Karkheh River basin and the encompassing synoptic stations**

شکل ۱. موقعیت جغرافیایی حوضه آبریز کرخه و ایستگاه‌های سینوپتیک واقع در آن

در این پژوهش، سری زمانی روزانه بارش، دمای هوا و رطوبت نسبی از ۲۷ ایستگاه سینوپتیک واقع در حوضه آبریز کرخه از دی‌ماه ۱۳۷۹ تا بهمن‌ماه ۱۴۰۲ از سازمان هواشناسی کشور دریافت شد)

شکل ۱). از آنجایی که داده‌های دریافتی از جمله بارش به صورت سه ساعته بود، پس از محاسبه مقدار تجمعی بارش‌های سه ساعته در هر روز، روزهای بدون داده‌ی ثبت شده توسط ایستگاه‌های بارش با استفاده از روش وزنی ضرایب همبستگی (Woldesenbet et al., 2017) و به کمک داده‌های ثبت شده توسط ایستگاه‌های اطراف پُر شدند، این روش تکمیل داده‌ها مشابه روش وزنی معکوس فاصله است، با این تفاوت که به جای معکوس فاصله از ضریب همبستگی بارش ایستگاه‌های مجاور (ایستگاه معرف یا شاخص) با ایستگاه هدف استفاده می‌شود. این ضریب به صورت زیر محاسبه می‌شود:

$$W_i = \frac{r_{it}}{\sum_{i=1, i \neq t}^N F_{it}} \quad (1)$$

که در آن، که در آن،  $r_{it}$  ضریب همبستگی بین سری زمانی روزانه ایستگاه هدف  $t$  و ایستگاه مجاور  $i$  ام، و  $N$  تعداد ایستگاه‌های مجاور برای آن زمان مشخص است. از آنجا که روش وزنی ضرایب همبستگی بر مبنای ایستگاه‌های مجاور است، انتخاب و تعداد ایستگاه‌های پیرامون برای افزایش دقت نتایج ضروری است. به منظور تکمیل داده‌های بارش در یک ایستگاه فاقد داده بارش در زمان مشخص به عنوان ایستگاه هدف، ایستگاه‌هایی که فاصله‌ی آن‌ها از این ایستگاه کمتر از ۱۵۰ کیلومتر بود، به عنوان ایستگاه‌های همسایه در نظر گرفته شدند. با توجه به فواصل اغلب زیاد ایستگاه‌های سینوپتیک در این حوضه، شعاع ۱۵۰ کیلومتری ایستگاه هدف انتخاب شد تا همیشه حداقل ۳ ایستگاه همسایه موجود باشد. سپس برای تعیین میزان شباهت یا ارتباط بین داده‌های ایستگاه هدف و ایستگاه‌های همسایه، از دو شاخص آماری ضریب همبستگی پیرسون<sup>۱۵</sup> و ضریب همبستگی کندال<sup>۱۶</sup> استفاده گردید. در این پژوهش، تنها ایستگاه‌های همسایه‌ای که ضریب کندال آن‌ها با ایستگاه هدف بیشتر از ۰.۳۵ بود، برای تخمین مقادیر ثبت نشده مورد استفاده قرار گرفتند. انتخاب این آستانه بر مبنای نتایج پژوهش (Woldesenbet et al., 2017) با هدف حفظ تعداد کافی ایستگاه‌های معتبر و درعین حال اطمینان از مشابهت زمانی قابل قبول متناسب با حوضه کرخه انجام گرفته است. قابل ذکر است که هر چه مقدار رتبه‌ای کندال بیشتر باشد، ارتباط قوی‌تری بین ایستگاه هدف و ایستگاه مجاور برقرار است. اما از آنجا که ممکن است با افزایش این مقدار برای برخی ایستگاه‌ها هیچ ایستگاهی در این معیار قرار نگیرد، نمی‌توان آن را بسیار بزرگ در نظر گرفت. سپس، فرآیند تکمیل داده‌های ثبت نشده به روش میانگین وزنی انجام شد. در این روش، برای هر مقدار ثبت نشده، از داده‌های ایستگاه‌های همسایه استفاده شده و به هر یک از آن‌ها وزنی بر اساس ضریب همبستگی پیرسون اختصاص داده شده است؛ به گونه‌ای که ایستگاه‌هایی با همبستگی بزرگتر، تأثیر بیشتری در مقدار نهایی برآورد شده دارند. استفاده از ضریب پیرسون به عنوان وزن بر اساس نتایج مطالعات پیشین مانند (Woldesenbet et al., 2017)، انتخاب شده است که در آن نشان داده شد روش وزن‌دهی مبتنی بر همبستگی ( $^{17}CCWM$ ) نسبت به روش‌های جایگزین مانند  $^{18}NRM$ ،  $^{19}MNRM$  و  $^{20}IDWM$  عملکرد دقیق‌تری در تخمین داده‌های بارش و دما دارد و می‌تواند همخوانی مکانی و کیفیت سری زمانی بازسازی شده را بهبود دهد. پس از حذف مقادیر ثبت



نشده و یا مقادیر با خطاهای اندازه‌گیری زیاد در داده‌های سه ساعته‌ی رطوبت نسبی و دمای هوا، این داده‌ها به مقیاس میانگین روزانه تبدیل شدند.

پس از آماده‌سازی داده‌های بارش، رطوبت نسبی و دمای هوا به صورت روزانه، برای در نظر گرفتن تأثیر تاریخی این سه متغیر در پیش‌بینی بارش، هفت دسته‌بندی زمانی صورت گرفت. این دسته‌بندی زمانی به‌ترتیب شامل داده‌های روز فعلی و روز گذشته تا روز فعلی و هفت روز گذشته است. در جدول ۱، P و U و T به‌ترتیب بیانگر بارش، رطوبت نسبی و دمای هوا به‌صورت روزانه هستند و اندیس lag(i) برای هر متغیر، نشان‌دهنده مقدار آن پارامتر در i امین روز قبل روز جاری می‌باشد. هدف هر سناریو در این رویکرد، پیش‌بینی بارش هموارشده در آینده به میزان تعداد روز در نظر گرفته شده در وقفه‌ی زمانی متغیرهای ورودی است (رابطه ۱). این هموارسازی به مدل کمک می‌کند تا تغییرات کوتاه‌مدت و نوسانات زیاد در بارش را کاهش داده و الگوهای کوتاه‌مدت تک روزه تا هفت روزه را بهتر استخراج کند. برای مثال، در سناریوی ۷ روزه، وقتی ورودی‌ها دارای وقفه ۷ روزه هستند، مدل در واقع مقدار بارش هموارشده در ۷ روز آینده را پیش‌بینی می‌کند. در نتیجه، مدل قادر است الگوهای زمانی پایدارتر را یاد بگیرد و عملکرد پیش‌بینی در افق‌های زمانی مختلف بهبود یابد.

$$P_{smooth(i)} = (P_0 + \sum_{i=1}^n P_{lag(i)}) / (n+1) \quad (2)$$

در رابطه‌ی بالا،  $P_0$  مقدار بارش روز جاری، n تعداد روزهای گذشته مورد نظر، i شماره روز قبل از روز جاری و  $P_{lag(i)}$  معادل بارش آن روز است. در نهایت، وقفه‌های زمانی یک تا هفت روزه در تمامی داده‌های بارش و دمای هوا و رطوبت نسبی اعمال شد و داده‌ها آماده‌ی ورود به مدل XGBoost شدند.

**Table 1- Model input scenarios based on multiple lags in precipitation, relative humidity and air temperature**

جدول ۱- چینش سناریوهای ورودی مدل بر حسب بارش، رطوبت نسبی و دمای هوا

Scenario	Inputs	Target
1-day lag	$P_{lag(1)}, U_{lag(1)}, T_{lag(1)}$	$P_{smooth(1)}$
2-day lag	$P_{lag(1)}, U_{lag(1)}, T_{lag(1)}, P_{lag(2)}, U_{lag(2)}, T_{lag(2)}$	$P_{smooth(2)}$
3-day lag	$P_{lag(1)}, U_{lag(1)}, T_{lag(1)} \dots P_{lag(3)}, U_{lag(3)}, T_{lag(3)}$	$P_{smooth(3)}$
4-day lag	$P_{lag(1)}, U_{lag(1)}, T_{lag(1)} \dots P_{lag(4)}, U_{lag(4)}, T_{lag(4)}$	$P_{smooth(4)}$
5-day lag	$P_{lag(1)}, U_{lag(1)}, T_{lag(1)} \dots P_{lag(5)}, U_{lag(5)}, T_{lag(5)}$	$P_{smooth(5)}$
6-day lag	$P_{lag(1)}, U_{lag(1)}, T_{lag(1)} \dots P_{lag(6)}, U_{lag(6)}, T_{lag(6)}$	$P_{smooth(6)}$
7-day lag	$P_{lag(1)}, U_{lag(1)}, T_{lag(1)} \dots P_{lag(7)}, U_{lag(7)}, T_{lag(7)}$	$P_{smooth(7)}$

### ۲-۳ الگوریتم یادگیری ماشین تقویت‌گرایان شدید

مدل تقویت‌گرایان، یک الگوریتم یادگیری ماشین است که با ترکیب چندین مدل ضعیف (معمولاً درختان تصمیم) و بهبود تدریجی آنها بر اساس خطاهای مدل‌های قبلی، عملکرد کلی را ارتقا می‌دهد. در این روش، هر مدل جدید سعی می‌کند خطاهای مدل‌های قبلی را جبران کند، و در نتیجه دقت و قدرت پیش‌بینی مدل نهایی افزایش می‌یابد (Friedman, 2001). مدل XGBoost نسخه‌ای پیشرفته و بهینه‌شده



از الگوریتم تقویت گرادینان محسوب می‌شود که با هدف افزایش سرعت، دقت و کارایی در مسائل یادگیری ماشین طراحی شده است (شکل ۲). این مدل با بهره‌گیری از تکنیک‌های پیشرفته‌ای مانند منظم‌سازی<sup>۲۱</sup> (برای جلوگیری از یادگیری بیش از حد مدل از جزئیات غیرضروری در داده‌ها)، یادگیری تدریجی بهینه‌شده (به منظور کاهش سریع‌تر خطا در هر مرحله)، پردازش موازی (برای افزایش سرعت اجرای الگوریتم با استفاده هم‌زمان از چند هسته پردازشی) و مدیریت خودکار داده‌های مفقود (بدون نیاز به حذف یا جایگزینی دستی)، عملکردی بسیار دقیق و کارآمد در مسائل طبقه‌بندی و پیش‌بینی عددی ارائه می‌دهد (Karbassiyazdi et al., 2022). در شکل ۲، شماتیک الگوریتم مدل XGBoost از اطلاعات ورودی تا پیش‌بینی نهایی نشان داده شده است.

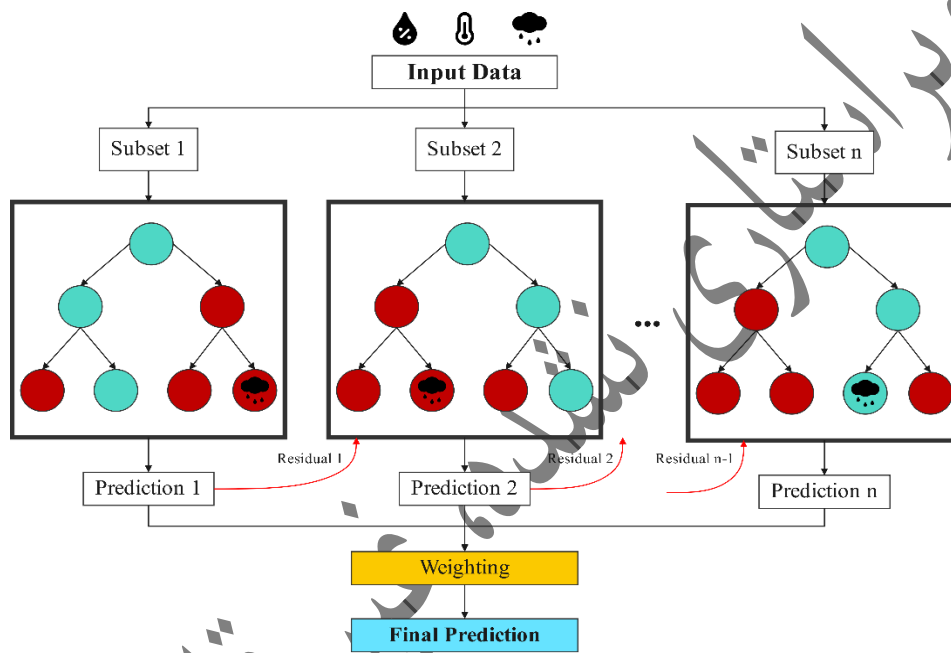


Fig .2- The XGBoost model's algorithm from input data to final prediction

شکل ۲. شماتیک الگوریتم مدل XGBoost از اطلاعات ورودی تا پیش‌بینی نهایی

### ۱-۳-۲- ابرپارامترهای مورد استفاده

ابریارامترها، مقادیری هستند که پیش از شروع آموزش مدل تعیین می‌شوند (مانند نرخ یادگیری، تعداد درخت‌ها، یا عمق درخت در مدل‌های تقویتی). با تنظیم صحیح ابریارامترها، مدل بدون آن که دچار بیش‌برازش<sup>۲۲</sup> یا کم‌برازش<sup>۲۳</sup> شود بهتر آموزش داده می‌شود و بنابراین عملکرد دقیق‌تری روی داده‌های جدید (ناشناخته) دارد. دامنه‌ی مقادیر در نظر گرفته شده برای ابریارامترهای مدل XGBoost در جدول ۲ ارائه شده است. یکی از این ابریارامترها،  $n\_estimators$  است که تعداد درخت‌های تصمیم ساخته شده در فرایند یادگیری را مشخص می‌کند. افزایش این مقدار می‌تواند دقت مدل را بهبود بخشد؛ اما در عین حال، خطر بیش‌برازش را نیز افزایش می‌دهد. پارامتر  $max\_depth$  نیز حداکثر عمق هر درخت تصمیم را تعیین می‌کند و عمق بیشتر درخت، امکان یادگیری روابط پیچیده‌تر را فراهم می‌آورد، اما احتمال بیش‌برازش را نیز بالا می‌برد. پارامتر  $learning\_rate$  یا نرخ یادگیری، سرعت به‌روزرسانی وزن‌ها را در هر مرحله مشخص می‌کند. مقادیر پایین‌تر این پارامتر منجر به یادگیری تدریجی‌تر و بهبود تعمیم‌پذیری مدل می‌شود؛ هرچند که ممکن است نیاز به تعداد درخت بیشتری ( $n\_estimators$ ) داشته باشد.



پارامتر `colsample_bytree` درصدی از ویژگی‌ها را که در هر درخت مورد استفاده قرار می‌گیرند، تعیین می‌کند که به کاهش همبستگی بین درخت‌ها و بهبود توان تعمیم مدل کمک می‌کند. در نهایت، پارامتر `subsample` درصد نمونه‌های داده را که در هر درخت برای یادگیری مورد استفاده قرار می‌گیرند، مشخص می‌کند و این امر به جلوگیری از بیش‌برازش و بهبود تعمیم‌پذیری مدل می‌انجامد. به طور کلی، تنظیم بهینه این ابرپارامترها موجب بهبود کارایی و دقت مدل XGBoost در مسائل مختلف یادگیری ماشین می‌شود.

**Table 2- The employed hyperparameters in the XGBoost machine learning model**

**جدول ۲- ابرپارامترهای به کار رفته در مدل یادگیری ماشین XGBoost**

Hyperparameter	Parameter's range
n_estimators	[100, 200, 500, 1000, 1200, 1500]
max_depth	[2, 3, 5, 10]
learning_rate	[0.001, 0.01, 0.1, 0.2]
colsample_bytree	[0.6, 0.8, 1]
subsample	[0.6, 0.7, 0.8, 1]

### ۲-۳-۲- بهینه‌سازی ابرپارامترها

بسته به نوع ابرپارامتر (گسسته، پیوسته یا دسته‌ای)، روش‌های بهینه‌سازی می‌توانند متفاوت باشند. به دلیل تنوع بالای ترکیب‌های ممکن و نیاز به اجرای مکرر مدل‌ها، این فرآیند از نظر منابع محاسباتی معمولاً بسیار زمان‌بر و پرهزینه است. در میان روش‌های موجود، جست‌وجوی شبکه‌ای<sup>۲۴</sup> به‌عنوان روش استاندارد مورد استفاده قرار گرفته است (Belete and Huchaiiah, 2022). در این روش، مجموعه‌ای از مقادیر از پیش تعیین‌شده برای هر ابرپارامتر مشخص می‌شود و سپس تمامی ترکیب‌های ممکن از این مقادیر به‌صورت سیستماتیک مورد ارزیابی قرار می‌گیرند تا بهترین ترکیب انتخاب شود. در این پژوهش، از این روش برای یافتن مقدار بهینه‌ی ابرپارامترها استفاده شده است. در پیاده‌سازی این بهینه‌سازی، تنظیم ابرپارامترهای مدل XGBoost با استفاده از روش جست‌جوی شبکه‌ای مبتنی بر اعتبارسنجی متقاطع ۱۰ تایی<sup>۲۵</sup> انجام شده است. تابع هدف در فرآیند بهینه‌سازی، کمینه‌سازی خطای میانگین مربعات (MSE) بوده که در چهارچوب جست‌وجوی شبکه‌ای پیاده‌سازی شده است؛ بدین معنا که ترکیب‌های مختلف ابرپارامترها بر اساس مقدار منفی MSE ارزیابی شده و مدلی که کمترین مقدار خطای مربع میانگین بر روی داده‌های اعتبارسنجی را دارد به‌عنوان ترکیب بهینه انتخاب می‌شود. این رویکرد تضمین می‌کند که فرآیند انتخاب ابرپارامترها بر پایه یک معیار کمی صریح مبتنی بر خطا انجام شود. هم‌زمان، به‌منظور کاهش خطر بیش‌برازش، در پیاده‌سازی از سازوکار توقف زودهنگام<sup>۲۶</sup> بهره گرفته شده است. در این روش، در هر تکرار آموزش، عملکرد مدل بر روی یک مجموعه اعتبارسنجی مستقل پایش می‌شود و در صورتی که پس از تعداد معینی از تکرارها (۵ تکرار) بهبود معناداری در تابع هدف مشاهده نشود، فرآیند آموزش به‌طور خودکار متوقف می‌گردد. به این ترتیب، از افزایش بیش از حد پیچیدگی مدل و انطباق آن با نویز داده‌ها جلوگیری شده و تعادلی میان دقت بر روی داده‌های آموزشی و قابلیت تعمیم مدل برقرار می‌شود.

## ۲-۳-۳- ارزیابی مدل

عملکرد مدل یادگیری ماشین XGBoost در پیش‌بینی بارش از طریق اعتبارسنجی متقابل ۱۰-گانه ارزیابی شد. اعتبارسنجی متقابل ۱۰-گانه روشی برای برآورد دقت مدل روی داده‌های نادیده است. کل مجموعه داده ابتدا به ۱۰ بخش ۳۷ هم‌حجم تقسیم می‌شود. در هر تکرار، ۹ بخش برای آموزش و یک بخش برای آزمون انتخاب می‌شود. این چرخه ۱۰ بار تکرار می‌شود تا هر بخش، یک بار در نقش داده‌ی آزمون قرار گیرد. میانگین شاخص‌های ارزیابی عملکرد به‌دست‌آمده در این ۱۰ آزمون، شاخص نهایی کارایی مدل به‌شمار می‌رود. به این ترتیب، همه‌ی نمونه‌ها هم در آموزش و هم در ارزیابی به کار می‌روند، بدون آنکه مدل هرگز داده‌ی آزمون همان تکرار را دیده باشد. در این پژوهش، سه شاخص ضریب تبیین ( $R^2$ )، میانگین خطای مطلق ( $MAE^{28}$ )، خطای جذر میانگین مربعات (RMSE) و شاخص کارایی کلینگ-گوپت ( $KGE^{29}$ ) به‌عنوان معیار ارزیابی قرار گرفته شدند.

$$R^2 = 1 - \frac{\sum_{i=1}^n (P_i - P_{s_i})^2}{\sum_{i=1}^n (P_i - \bar{P})^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - P_{s_i}| \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - P_{s_i})^2} \quad (5)$$

$$KGE = 1 - \sqrt{(r-1)^2 + \left(\frac{\sigma_{s_i}}{\sigma_i} - 1\right)^2 + \left(\frac{\bar{P}_{s_i}}{\bar{P}_i} - 1\right)^2} \quad (6)$$


در روابط بالا،  $P_i$  مقادیر مشاهداتی،  $P_{s_i}$  مقادیر خروجی مدل و  $\bar{P}_i$  میانگین مقادیر مشاهداتی،  $\bar{P}_{s_i}$  میانگین مقادیر خروجی مدل،  $\sigma_i$  انحراف معیار مقادیر مشاهداتی،  $\sigma_{s_i}$  انحراف معیار مقادیر خروجی مدل در روز  $i$  و  $r$  ضریب همبستگی خطی میان داده‌های مشاهداتی و خروجی مدل است. کارایی مدلی بیشتر است که دارای  $R^2$  و  $KGE$  بالاتر و  $MAE$  و  $RMSE$  کمتری داشته باشد.

## ۲-۴- تعیین اهمیت نسبی متغیرهای ورودی به مدل

سنجش اهمیت نسبی متغیرهای ورودی به مدل، یکی از ابزارهای کلیدی در تحلیل مدل‌های یادگیری ماشین، به‌ویژه در مسائل مبتنی بر داده‌های جدولی<sup>۳۰</sup> است. این مفهوم به تعیین میزان تأثیر هر ویژگی در فرآیند پیش‌بینی مدل کمک می‌کند و نه تنها درک بهتری از عملکرد مدل فراهم می‌آورد، بلکه به تشخیص ویژگی‌های کم‌اثر یا بی‌اثر نیز منجر می‌شود. این امر موجب ساده‌سازی داده‌ها، کاهش ابعاد، افزایش سرعت آموزش، و در بسیاری از موارد، کاهش خطر بیش‌برازش خواهد شد. در این بخش، اهمیت نسبی ویژگی‌های ورودی برای مدل‌های مختلف یادگیری ماشین توسط روش Permutation feature importance مورد بررسی قرار گرفت. در این روش، ابتدا مدل بر اساس داده‌های اصلی ارزیابی می‌شود، سپس مقادیر یک ویژگی خاص به‌صورت تصادفی جابجا می‌شود و مدل دوباره اجرا می‌گردد. کاهش دقت مدل پس از این جابجایی نشان‌دهنده اهمیت آن ویژگی است. این روش نسبت به بسیاری از روش‌های دیگر برتری دارد، زیرا نه تنها مستقل از نوع مدل بوده و برای انواع مدل‌ها از جمله درختی، خطی و عصبی قابل استفاده است، بلکه به‌طور مستقیم نشان می‌دهد که هر ویژگی چه نقشی در پیش‌بینی نهایی ایفا می‌کند.

### ۱-۳ بررسی بلندمدت تغییرات بارش، دما و رطوبت نسبی در حوضه کرخه

بررسی روندهای بلندمدت بارش، دما و رطوبت نسبی در کرخه نشان می‌دهد که این حوضه طی دهه‌های اخیر با تغییرات قابل توجهی در الگوی فصلی و سالانه مواجه شده است؛ تغییراتی که بیش از همه در زمستان نمود پیدا کرده و پیامدهای مهمی برای منابع آب منطقه به همراه دارد. برای بررسی روند تغییرات بارش، دما و رطوبت نسبی در این حوضه، از شیب سن (Sen's slope) و ضریب همبستگی پیرسون استفاده گردید. شیب سن معیاری ناپارامتری است که مقدار نرخ تغییر روند را در یک سری زمانی برآورد می‌کند و نشان می‌دهد متغیر موردنظر به‌طور متوسط چند واحد افزایش یا کاهش یافته است. برای اطمینان از معنادار بودن ضریب همبستگی، مقدار p-value نیز در سطح اهمیت ۵ درصد محاسبه شده است. در این حوضه، الگوی تغییرات بارش نشان می‌دهد که مهم‌ترین کاهش معنادار مربوط به بارش‌های زمستانه است. شیب سن حدود ۱۵۷ میلی‌متر در سال همراه با میانگین بارش زمستانه نزدیک به ۲۰۷ میلی‌متر بیانگر آن است که طی یک بازه ۵۰ ساله، زمستان‌ها به‌طور پیوسته خشک‌تر شده‌اند. از آنجا که بخش عمده تغذیه رواناب سطحی و مخازن سدها در این حوضه از بارش‌های زمستانه تأمین می‌شود، این روند کاهشی می‌تواند مستقیماً به کاهش آورد رودخانه، افزایش خطر کم‌آبی و تشدید رقابت بین بخش‌های مختلف مصرف آب منجر شود. در مقیاس سالانه نیز شیب منفی حدود ۰.۸۶ میلی‌متر در سال مشاهده می‌شود که به معنای کاهش تجمعی در حدود ۴۰ تا ۴۵ میلی‌متر طی چند دهه و معادل حدود ۹ درصد میانگین بارش سالانه (نزدیک به ۴۶۹ میلی‌متر) است. این موضوع نشان می‌دهد که گرچه تغییرات بارش در فصول بهار، تابستان و پاییز عمدتاً به صورت نوسانات بین‌ساله و بدون روند معنادار است، اما کاهش بارش زمستانه آن‌قدر قوی بوده که خود را در مقیاس سالانه نیز نشان داده است. شکل به‌صورت کلی نشان می‌دهد که حوضه کرخه طی چند دهه اخیر در تمامی فصول سال با روند گرمایش معنادار روبه‌رو بوده است. خطوط روند افزایشی و مقدار مثبت شیب سن در چهار فصل نشان می‌دهد که افزایش دما فقط محدود به یک فصل خاص نیست، بلکه یک الگوی حرارتی پیوسته و گسترده در کل سال شکل گرفته است. چنین الگوی گرمایشی، اثرات مهمی بر چرخه آب دارد: افزایش تبخیر و تعرق در تمام سال، کاهش پتانسیل ذخیره برفی در زمستان و رواناب بهاره، تشدید تنش آبی و افزایش نیاز آبی کشاورزی، طولانی‌تر شدن دوره‌های گرم سال نمونه‌هایی از اثرات این رخداد است.



**Fig .3-** The mean temperature of the Karkheh River Basin across different seasons during the years 1973 to 2023

شکل ۳. دمای متوسط حوضه آبریز کرخه در فصول مختلف طی سال‌های ۱۳۵۲ تا ۱۴۰۲



نمودارهای مربوط به تغییرات رطوبت نسبی در حوضه آبریز کرخه (شکل ۴) نشان می‌دهند که این متغیر طی چند دهه اخیر عمدتاً روندی کاهشی را تجربه کرده است. این کاهش در برخی فصول از نظر آماری معنادار بوده و در برخی دیگر به صورت نوسانات بین‌سالی بدون روند مشخص ظاهر شده است. در فصل زمستان، رطوبت نسبی با شیب منفی و معنادار کاهش یافته است؛ موضوعی که بیانگر خشک‌تر شدن تدریجی هوای زمستان در این حوضه بوده و می‌تواند با پیامدهایی نظیر افزایش دما، کاهش بارش برف و افت رطوبت خاک همراه باشد. روند کاهشی رطوبت نسبی در فصل تابستان نیز از نظر آماری معنادار است و می‌تواند نقش مهمی در تشدید تنش آبی، افزایش تبخیر و تقویت شرایط خشکی و فرسایش در نیمه گرم سال ایفا کند. در مقابل، فصول پاییز و بهار با وجود نوسانات قابل توجه، فاقد روند معنادار هستند؛ به طوری که پاییز تنها افزایش جزئی و غیرمعنادار و بهار کاهش ملایم اما غیرمعنادار نشان می‌دهد. در مجموع، یافته‌ها بیانگر خشک‌تر شدن اقلیم حوضه کرخه به‌ویژه در فصول زمستان و تابستان هستند که این امر می‌تواند تأثیرات قابل توجهی بر توازن آبی و پویایی اکولوژیک منطقه داشته باشد.




Fig. 4- The mean relative humidity of the Karkheh River Basin across different seasons during the years 1973 to 2023

شکل ۴. رطوبت نسبی متوسط حوضه آبریز کرخه در فصول مختلف طی سال‌های ۱۳۵۲ تا ۱۴۰۲

### ۲-۳ همبستگی متغیرهای ورودی به مدل در وقفه‌های زمانی مختلف

شکل ۲ نشان‌دهنده همبستگی بین دمای هوا (T)، رطوبت نسبی (U) و بارش (P) در وقفه‌های مختلف زمانی است. همان‌طور که مشخص است، بین وقفه‌های متوالی یک متغیر (مانند  $U_{lag}(1)$  تا  $U_{lag}(7)$  یا  $P_{lag}(1)$  تا  $P_{lag}(7)$ )، همبستگی بسیار بالا (نزدیک به ۱ یا -۱) وجود دارد که نشان‌دهنده پیوستگی زمانی در داده‌ها است. وجود همبستگی مثبت بین رطوبت نسبی و بارش در اکثر وقفه‌ها (حدود ۰.۶۵) مؤید افزایش رطوبت نسبی هنگام بارش است. همچنین، همبستگی منفی زیاد بین وقفه‌های زمانی دمای هوا و رطوبت نسبی (حدود -۰.۹) نیز بیانگر کاهش دما در زمان بارش و افزایش رطوبت نسبی می‌باشد. متغیر  $P_{smooth}$  که بارش هموارشده‌ی هفت روزه را نشان می‌دهد، با وقفه‌های بارش و رطوبت همبستگی مثبت دارد که نشان‌دهنده اثرگذاری وقفه‌های گذشته در شکل‌گیری روند میانگین بارش است. این همبستگی بیانگر آن است که مقادیر گذشته بارش و رطوبت در شکل‌گیری روند میانگین بارش کنونی نقش مؤثری دارند و روند بارش در گذر زمان به تأثیرات تجمعی این وقفه‌ها وابسته است.




Fig. 2- The correlation heatmap of the models' input variables

شکل ۲. نقشه حرارتی همبستگی میان متغیرهای ورودی به مدل‌ها

### ۳-۳ مقایسه عملکرد مدل در سناریوهای مختلف

پس از ورود اطلاعات به مدل‌ها در قالب سناریوهای مطرح شده در بخش داده‌ها و بهینه‌سازی ابرپارمترهای آنها، بهترین عملکرد هر مدل در هر سناریو مطابق شکل ۳ و شکل ۷ مشخص شد. نتایج ارزیابی مدل‌ها نشان می‌دهد که بیشترین مقادیر  $R^2$  و KGE، کمترین مقادیر MAE و RMSE در بخش آموزش و آزمون در همه‌ی مدل‌ها متعلق به سناریویی است که هر سه متغیر بارش، دمای هوا و رطوبت نسبی با تأخیر زمانی یک تا هفت روزه به عنوان ورودی مدل استفاده شوند. نتایج حاصل از ارزیابی مدل براساس شاخص‌های خطای MAE، RMSE، KGE و  $R^2$  بیانگر تغییرات قابل توجه در دقت پیش‌بینی مدل با افزایش وقفه در داده‌های ورودی است. نتایج نشان می‌دهد که مقادیر MAE و RMSE چه در مجموعه داده آموزش و چه در داده‌های آزمون، با در نظر گرفتن بیش‌تر وقفه‌های زمانی از یک روز تا هفت روز، روند کاهش معناداری دارند. این کاهش خطاها دلالت بر بهبود عملکرد مدل در سناریوهایی با بهره‌گیری از تاریخچه‌ی طولانی‌تر داده‌ها دارد. همچنین، مقدار  $R^2$  که بیانگر میزان توانایی مدل در تبیین تغییرات داده‌های واقعی است، در هر دو بخش آموزش و آزمون، با افزایش تأخیر زمانی روند افزایشی قابل ملاحظه‌ای را نشان می‌دهد و از مقدار حدود ۰.۵۷ در سناریوی تأخیر یک‌روزه تا بیش از ۰.۹۳ در سناریوی

تأخیر هفت‌روزه افزایش یافته است. این روند به‌طور مشابه در شاخص KGE نیز قابل مشاهده است. این مشاهده دلالت بر افزایش توانایی مدل در پیش‌بینی مقادیر بارش بر اساس داده‌های تاریخی طولانی‌تری و بارش هموار شده‌تر دارد. لازم به ذکر است در این پژوهش، وقفه‌های زمانی بلندمدت‌تری نظیر ۱۰ روز، ۱۵ روز و ۳۰ روز نیز به‌عنوان سناریوهای مکمل مورد آزمایش قرار گرفتند تا بهبود بیشتر مدل در پیش‌بینی افق‌های طولانی‌تر با وقفه‌های زمانی بیشتر نیز مورد بررسی قرار بگیرد و ارزیابی این مدل‌ها نشان داد که استفاده از ویژگی‌های وقفه‌های اضافی و هموارسازی بیشتر لزوماً منجر به بهبود قابل توجهی در دقت مدل نمی‌شود.




Fig .6- Accuracy assessment measures of  $R^2$  and RMSE of the XGBoost model for different scenarios

شکل ۳. نتایج شاخص‌های  $R^2$  و RMSE برای ارزیابی دقت مدل پیش‌بینی بارش بر اساس سناریوهای هفت‌گانه

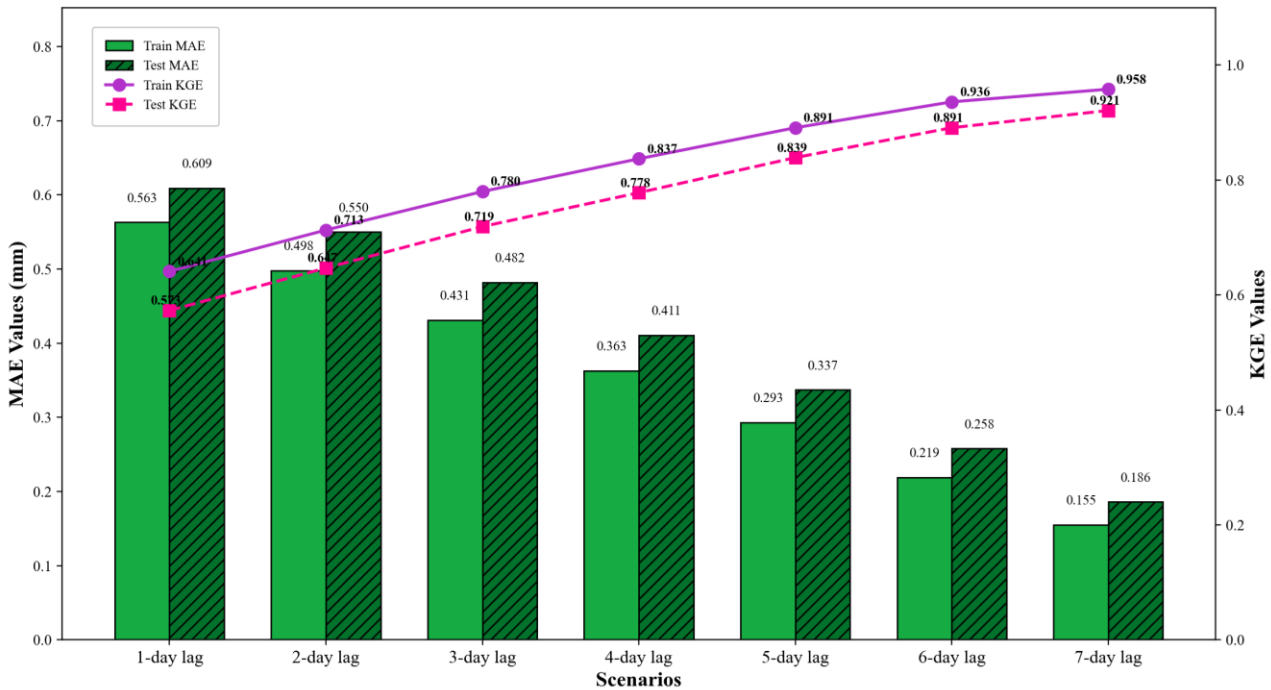


Fig .7- Accuracy assessment measures of KGE and MAE of the XGBoost model for different scenarios

شکل ۴. نتایج شاخص‌های MAE و KGE برای ارزیابی دقت مدل پیش‌بینی بارش بر اساس سناریوهای هفت‌گانه

### ۴-۳ بررسی عملکرد مدل در سناریوی برتر

بر اساس نتایج، دقیق‌ترین عملکرد مدل XGBoost در پیش‌زمانی بارش متعلق به سناریو هفت روز می‌باشد. ابرپارامترهای مدل با استفاده از روش اشاره شده در بخش قبل بهینه شده و مقادیر آن‌ها در جدول ۳ قابل مشاهده است.


Table 3- The optimized hyperparameters in the XGBoost machine learning model

جدول ۳. ابرپارامترهای بهینه شده در مدل یادگیری ماشین XGBoost

Hyperparameter	Value
n_estimators	1000
max_depth	3
learning_rate	0.01
colsample_bytree	1
subsample	0.7

شکل ۵ نمودار پراکندگی داده‌های پیش‌بینی شده توسط مدل در دو بخش آموزش (a) و آزمون (b) در برابر داده‌های مشاهداتی را در سناریو هفت روز، شامل متغیرهای بارش، رطوبت نسبی و دمای هوای از یک تا هفت روز گذشته، نشان می‌دهد. در بخش آموزش، مقدار ضریب تعیین ( $R^2$ ) برابر با ۰.۹۶ و KGE برابر با ۰.۹۶ است که نشان‌دهنده تطابق زیاد مدل با داده‌های مشاهداتی می‌باشد. همچنین، شاخص‌های

خطا شامل RMSE برابر با ۰.۳۲ میلی‌متر و MAE برابر با ۰.۱۵ میلی‌متر است که مقادیر پایین این خطاها دلالت بر دقت بالای مدل در داده‌های آموزش دارد. این نتایج نشان می‌دهند که مدل توانسته الگوهای موجود در داده‌های آموزش را به خوبی یاد بگیرد و آماده بخش آزمون شود. در بخش آزمون، ضریب تعیین  $R^2$  برابر با ۰.۹۳ و KGE برابر با ۰.۹۲ است که همچنان بیانگر کارایی خوب مدل و عدم افت عملکرد قابل توجه نسبت به آموزش است. مقدار RMSE در آزمون برابر ۰.۴۱ میلی‌متر و MAE برابر ۰.۱۹ میلی‌متر است که نسبت به داده‌های آموزش مقداری افزایش یافته است. به طور کلی، این نتایج حاکی از عملکرد بسیار خوب مدل XGBoost در پیش‌بینی بارش با استفاده از تاریخچه داده‌های بارش، دمای هوا و رطوبت نسبی تا هفت روز قبل است.



**Fig .8- Scatter plot of the predicted values by the model in the training (a) and testing (b) sections against the actual values in the 7-day scenario**

شکل ۵. نمودار پراکندگی داده‌های پیش‌بینی شده توسط مدل در دو بخش آموزش (a) و آزمون (b) در برابر داده‌های مشاهداتی در سناریو هفت روز

### ۳-۵ اهمیت نسبی متغیرهای ورودی

نتایج حاصل از تحلیل اهمیت متغیرهای ورودی به مدل XGBoost در سناریو هفت روز نشان می‌دهند که متغیر  $P_{lag}(1)$ ، یعنی مقدار بارش در یک گام زمانی گذشته، با اختلاف زیاد مهم‌ترین متغیر در پیش‌بینی خروجی بوده است (شکل ۶). همچنین، متغیرهای بارش تاریخی، نقش غالب و تعیین‌کننده‌ای در پیش‌بینی بارش دارند. در این میان، بارش روز قبل ( $P_{lag}(1)$ ) با امتیاز اهمیت ۰.۱۷۷ بیشترین تأثیر را نشان می‌دهد و به دنبال آن بارش با تأخیرهای ۴ و ۵ روز ( $P_{lag}(4)$ ) و ( $P_{lag}(5)$ ) با امتیازات نزدیک به ۰.۱ قرار دارند. جالب توجه اینکه بارش دو روز قبل ( $P_{lag}(2)$ ) با امتیاز ۰.۰۵۸ اهمیت کمتری نسبت به سایر تأخیرهای بارش دارد که نشان می‌دهد لزوماً نزدیک‌ترین تأخیرهای زمانی بارش، بیشترین سهم را در پیش‌بینی خروجی ندارند. در مقابل، متغیرهای رطوبت نسبی و دمای هوا نقش کم‌رنگ‌تری دارند، به طوری که بالاترین امتیاز در رطوبت مربوط به  $U_{lag}(1)$  با ۰.۰۲۹ و در دما مربوط به  $T_{lag}(1)$  با ۰.۰۰۶ است و سایر متغیرهای این دو دسته عموماً اهمیت نزدیک به صفر دارند. همچنین، الگوی کاهشی اهمیت متغیرهای بارش با افزایش مدت تأخیر مشاهده می‌شود؛ به استثنای  $P_{lag}(2)$  که به طور غیرمنتظره‌ای اهمیت کمتری دارد. این موضوع نشان می‌دهد مدل بیشتر از بارش‌های اخیر برای پیش‌بینی استفاده می‌کند و حافظه کوتاه‌مدت سیستم بارشی قوی‌تر است. در مورد متغیرهای رطوبت نسبی و دمای هوا، این الگوی کاهشی چندان مشهود نیست و اهمیت آنها در تمامی تأخیرها پایین باقی می‌ماند. این نتایج حاکی از آن است که در مقیاس کوتاه‌مدت، بارش عمدتاً تحت تأثیر الگوهای خودهمبستگی زمانی است.




Fig. 3- Feature importance values of model's variable inputs in 7-day scenario

شکل ۶. مقادیر اهمیت متغیرهای ورودی به مدل در سناریو هفت روز

بررسی روندهای بلندمدت در حوضه آبریز کرخه نشان می‌دهد که این منطقه طی چند دهه اخیر با تحولات اقلیمی قابل توجهی مواجه شده است. بارش سالانه و به‌ویژه بارش زمستانه روندی کاهشی و معنادار را تجربه کرده‌اند؛ کاهشی که نقش مستقیم در کاهش آورد رودخانه، افت ذخایر سطحی و افزایش فشار بر منابع آب دارد. هم‌زمان، دما در تمامی فصول به‌طور معنادار افزایش یافته و این گرمایش فراگیر به افزایش تبخیر و تعرق، تشدید خشکی خاک و تغییر زمان‌بندی فرآیندهای هیدرولوژیک منجر شده است. از سوی دیگر، رطوبت نسبی در زمستان و تابستان کاهش معنادار داشته و این کاهش، همراه با افزایش دما، شرایط اقلیمی حوضه را خشک‌تر و ناپایدارتر کرده است. ترکیب این سه تغییر (بارش، افزایش دما و افت رطوبت نسبی) بیانگر ورود کرخه به دوره‌ای از تنش آبی ساختاری است که مدیریت منابع آب را با چالش‌های جدی روبه‌رو می‌کند. در چنین شرایطی، توسعه و به‌کارگیری مدل‌های دقیق پیش‌بینی بارش اهمیت ویژه‌ای پیدا می‌کند. پیش‌بینی معتبر و زمانی مناسب بارش می‌تواند به‌طور مستقیم در سناریوهای بهره‌برداری از مخازن سدها، برنامه‌ریزی تأمین آب شرب و کشاورزی، مدیریت سیلاب و کنترل دوره‌های خشکسالی به کار رود.

در این پژوهش، با بهره‌گیری از الگوریتم یادگیری ماشین XGBoost، امکان پیش‌بینی زمانی بارش در افاق‌های پیش‌بینی روزانه تا میانگین هفت‌روزه در حوضه آبریز کرخه مورد بررسی قرار گرفت. به‌کارگیری روش تکمیل داده‌های مفقود این امکان را به‌وجود آورد تا مقادیر بارش در ساعات ثبت نشده به کمک ایستگاه‌های سینوپتیک اطراف تکمیل شوند. ترکیب داده‌های اقلیمی شامل بارش، دمای هوا و رطوبت نسبی از ۲۷ ایستگاه سینوپتیک در بازه‌ای طولانی مدت و اجرای سناریوهای مبتنی بر وقفه‌های زمانی (lag)، داده‌های لازم برای آموزش مدل‌ها را فراهم ساخت. نتایج حاصل از ارزیابی مدل با استفاده از اعتبارسنجی متقابل ده‌گانه و سه شاخص کلیدی  $R^2$ ، RMSE و MAE نشان داد که مدل در سناریوهای زمانی مختلف، کمترین خطا را در سناریو هفت روز دارد. بیشترین دقت پیش‌بینی در مدل به‌ویژه در بخش آزمون متعلق به همین سناریو بود. این موضوع اهمیت در نظر گرفتن تاریخچه‌ی زمانی متغیرهای اقلیمی در پیش‌بینی بارش را مورد تأکید قرار می‌دهد. این مدل در بخش آموزش توانست با  $R^2=0.96$ ، RMSE=0.32 میلی‌متر و MAE=0.15 میلی‌متر و در بخش آزمون با  $R^2=0.93$ ، RMSE=0.41 میلی‌متر و MAE=0.19 میلی‌متر عملکرد بسیار خوبی را در پیش‌بینی بارش به نمایش بگذارد. از منظر تحلیل اهمیت ویژگی‌ها نیز، متغیر  $P_{lag}(1)$  یعنی بارش در روز گذشته به‌عنوان مهم‌ترین عامل پیش‌بینی‌کننده بارش روز جاری شناسایی شد. به‌طور کلی تحلیل نشان می‌دهد که پیش‌بینی بارش عمدتاً متکی بر داده‌های تاریخی بارش (به‌ویژه با تأخیر ۱، ۴ و ۵ روز) است، درحالی که اهمیت دمای هوا و رطوبت نسبی در مقایسه با بارش کمتر است. البته گفتنی است مقدار رطوبت در روز گذشته از سایر متغیرهای غیربارشی اهمیت بیشتری دارد. در نهایت، یافته‌های این پژوهش حاکی از آن است که مدل XGBoost توسعه داده شده با دقت بالای خود در سناریو هفت روز می‌تواند ابزار مؤثری برای بهبود پیش‌بینی بارش در سامانه‌های هشدار سیلاب، مدیریت لحظه‌ای ورودی مخازن و کاهش ریسک‌های هیدرولوژیکی باشد. پیش‌بینی کوتاه‌مدت میانگین بارش همچنین امکان برنامه‌ریزی دقیق‌تر در تخصیص آب، پایش دوره‌های کم‌بارش و بهینه‌سازی عملیات آبیاری در بخش کشاورزی را فراهم می‌کند. در مجموع، استفاده از این مدل قابلیت ارتقای تصمیم‌سازی عملیاتی در مدیریت منابع آب و آمادگی بهتر در برابر رخدادهای حدی را به‌طور قابل توجهی افزایش می‌دهد. برای ارتقای دقت و قابلیت تعمیم این



چارچوب، پیشنهاد می‌شود که برای بازسازی مقادیر ثبت نشده بارش در ایستگاه‌های یک حوضه، علاوه بر معیارهایی همچون فاصله افقی و همبستگی سری زمانی، از معیارهای افزون‌تری مانند ارتفاع (توپوگرافی)، شباهت اقلیمی یا جهت وزش غالب نیز در انتخاب همسایه در پژوهش‌های آینده استفاده بنمایند. علاوه بر این، از داده‌های راداری و ماهواره‌ای در کنار داده‌های ایستگاهی استفاده شود تا ناهمگنی فضایی بارش بهتر بازنمایی شود. بهره‌گیری از مدل‌های یادگیری عمیق مانند LSTM، CNN می‌تواند وابستگی زمانی بارش را واقعی‌تر مدل‌سازی کند و پیش‌بینی رخدادهای حدی را بهبود دهد. همچنین، استفاده از رویکردهای همادی<sup>۳۱</sup> و تحلیل عدم قطعیت به‌ویژه در پیش‌بینی بارش‌های شدید، موجب افزایش اطمینان‌پذیری نتایج و فراهم‌شدن امکان به‌کارگیری مدل در عملیات تصمیم‌گیری مدیریتی خواهد شد.

## ۵ تشکر

این اثر تحت حمایت هادی صندوق حمایت از بنیاد ملی علم ایران (INSF) برگرفته شده از طرح شماره ۴۰۲۲۹۱۴ انجام شده است.

## ۶ پی‌نوشت‌ها

- 1- Decision Tree
- 2- Naïve Bayes
- 3- k-Nearest Neighbors
- 4- Support Vector Machine
- 5- Artificial Neural Networks
- 6- Numerical Weather Prediction
- 7- Root Mean Square Error
- 8- Random Forest
- 9- Xtreme Gradient Boosting
- 10- Generalized Linear Model
- 11- Linear Discriminant Analysis
- 12- Boosting
- 13- Preprocessing
- 14- Smoothing
- 15- Pearson Coefficient
- 16- Kendal Coefficient
- 17- Coefficient of Correlation Weighting Method
- 18- Normal Ratio Method
- 19- Modified Normal Ratio Method
- 20- Inverse Distance Weighting Method
- 21- Regularization
- 22- Overfitting
- 23- Underfitting
- 24- Grid Search Cross Validation
- 25- 10-Fold Cross Validation
- 26- Early-Stopping Mechanism
- 27- Fold
- 28- Mean Absolute Error
- 29- Kling-Gupta Efficiency
- 30- Tabular Data
- 31- Ensemble

- Aderiyani FR, Jamshid Mousavi S and Jafari F (2022) Short-term rainfall forecasting using machine learning-based approaches of PSO-SVR, LSTM and CNN. *Journal of Hydrology* 614:128463. Available at: <https://www.sciencedirect.com/science/article/pii/S0022169422010332>
- Aguasca-Colomo R, Castellanos-Nieves D and Méndez M (2019) Comparative analysis of rainfall prediction models using machine learning in islands with complex orography: Tenerife Island. *Applied Sciences* (Switzerland). MDPI AG 9(22)
- Anochi JA, de Almeida VA and de Campos Velho HF (2021) Machine learning for climate precipitation prediction modeling over South America. *Remote Sensing*. MDPI AG 13(13)
- Bayat-Afshary N, Khoejh S and Danesh Yazdi M (2022) Identification and Analysis of the Dominant Factors Contributing in Intensification of Floods and Damages in the Karkheh Basin in April 2018. *Iran-Water Resources Research* 18(3):92–110. Available at: [https://www.iwrr.ir/article\\_159955.html](https://www.iwrr.ir/article_159955.html)
- Belete DM and Huchaiah MD (2022) Grid search in hyperparameter optimization of machine learning models for prediction of HIV/AIDS test results. *International Journal of Computers and Applications*. Taylor & Francis 44(9):875–886. Available at: <https://doi.org/10.1080/1206212X.2021.1974663>
- Bochenek B and Ustrnul Z (2022) Machine Learning in Weather Prediction and Climate Analyses—Applications and Perspectives. *Atmosphere* 13(2). Available at: <https://www.mdpi.com/2073-4433/13/2/180>
- Chen L, Han B, Wang X, Zhao J, Yang W and Yang Z (2023) Machine Learning Methods in Weather and Climate Applications: A Survey. *Applied Sciences* 13(21). Available at: <https://www.mdpi.com/2076-3417/13/21/12019>
- Friedman JH (2001) Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*. Institute of Mathematical Statistics 29(5):1189 – 1232. Available at: <https://doi.org/10.1214/aos/1013203451>
- Karbassiyazdi E, Fattahi F, Yousefi N, Tahmassebi A, Taromi AA, Manzari JZ, Gandomi AH, Altaee A and Razmjou A (2022) XGBoost model as an efficient machine learning approach for PFAS removal: Effects of material characteristics and operation conditions. *Environmental Research* 215:114286. Available at: <https://www.sciencedirect.com/science/article/pii/S0013935122016139>
- Kumar V, Kedam N, Sharma KV, Khedher KM and Alluqmani AE (2023) A Comparison of Machine Learning Models for Predicting Rainfall in Urban Metropolitan Cities. *Sustainability* 15(18). Available at: <https://www.mdpi.com/2071-1050/15/18/13724>
- Latif SD, Alyaa Binti Hazrin N, Hoon Koo C, Lin Ng J, Chaplot B, Feng Huang Y, El-Shafie A and Najah Ahmed A (2023) Assessing rainfall prediction models: Exploring the advantages of machine learning and remote sensing approaches. *Alexandria Engineering Journal* 82:16–25. Available at: <https://www.sciencedirect.com/science/article/pii/S1110016823008554>
- Liyew CM and Melese HA (2021) Machine learning techniques to predict daily rainfall amount. *Journal of Big Data* 8(1):153. Available at: <https://doi.org/10.1186/s40537-021-00545-4>
- Monego VS, Anochi JA and de Campos Velho HF (2022) South America Seasonal Precipitation Prediction by Gradient-Boosting Machine-Learning Approach. *Atmosphere* 13(2). Available at: <https://www.mdpi.com/2073-4433/13/2/243>
- Ougahi JH and Rowan JS (2025) Enhanced streamflow forecasting using hybrid modelling integrating glacio-hydrological outputs, deep learning and wavelet transformation. *Scientific Reports* 15(1):2762. Available at: <https://doi.org/10.1038/s41598-025-87187-1>

Rahman A, Abbas S, Gollapalli M, Ahmed R, Aftab S, Ahmad M, Khan MA and Mosavi A (2022) Rainfall Prediction System Using Machine Learning Fusion for Smart Cities. *Sensors* 22(9). Available at: <https://www.mdpi.com/1424-8220/22/9/3504>

Shah U, Garg S, Sisodiya N, Dube N and Sharma S (2018) Rainfall Prediction: Accuracy Enhancement Using Machine Learning and Forecasting Techniques. 2018 Fifth International Conference on Parallel, Distributed and Grid Computing (PDGC), 776–782

Woldesenbet TA, Elagib NA, Ribbe L and Heinrich J (2017) Gap filling and homogenization of climatological datasets in the headwater region of the Upper Blue Nile Basin, Ethiopia. *International Journal of Climatology* 37(4):2122–2140. Available at: <https://rmets.onlinelibrary.wiley.com/doi/abs/10.1002/joc.4839>

Yang B, Xiao Z, Meng Q, Yuan Y, Wang W, Wang H, Wang Y and Feng X (2023) Deep learning-based prediction of effluent quality of a constructed wetland. *Environmental Science and Ecotechnology*. Editorial Board, *Research of Environmental Sciences* 13

Yu J, Li Y, Huang X and Ye X (2025) Data quality and uncertainty issues in flood prediction: a systematic review. *International Journal of Digital Earth*. Taylor & Francis 18(1):2495738. Available at: <https://doi.org/10.1080/17538947.2025.2495738>

دانشگاه استناد  
فایبل استناد  
غیر نشده، غیر فایبل استناد

## Performance Assessment of the Extreme Gradient Boosting Machine Model in Forecasting Precipitation Depth to Improve Precipitation Estimation Accuracy in Data-Scarce Regions

Amirhossein Haddadi<sup>1</sup> - Mohammad Danesh Yazdi<sup>2\*</sup>

<sup>1</sup> Undergraduate Student, Department of Civil Engineering, Sharif University of Technology, Tehran, Iran

<sup>2\*</sup> Associate Professor, Department of Civil Engineering, Sharif University of Technology, Tehran, Iran. Email: danesh@sharif.edu

### Abstract

Estimating precipitation height in data-scarce regions is important for its wide application in water resource management-related topics. In this study, the performance of the Extreme Gradient Boosting (XGBoost) model was evaluated for predicting precipitation depth at short-term forecasting horizons, ranging from daily to 7-day averaged precipitation, in the Karkheh River Basin. For this purpose, three-hourly data on precipitation, air temperature, and relative humidity recorded at synoptic stations during the period from January 2001 to February 2024 were used. Then, data preprocessing steps were carried out, including completing missing data recorded by stations and removing outliers. Additionally, to consider the effects of precipitation, relative humidity, and air temperature from previous days on the current day's precipitation prediction, time lags from one to seven past days were applied to the data and prepared as inputs to the machine learning model in seven different scenarios. Test section results showed that the prediction accuracy of the model increased with the use of more historical information; such that in the seven-day scenario, the model demonstrated more accurate precipitation time prediction with  $R^2 = 0.93$ ,  $RMSE = 0.41$  mm, and  $MAE = 0.19$  mm compared to the one-day scenario, which had indices of  $R^2 = 0.46$ ,  $RMSE = 1.13$  mm, and  $MAE = 0.61$  mm.

**Keywords:** Precipitation prediction, Machine learning, XGBoost, Karkheh River Basin.