

## بررسی مدل تلفیقی هوشمند MetNet-2-SwinTransformer به منظور مدل سازی دبی پیک سیلاب (مطالعه موردی: حوزه آبخیز کرج)

رامتین طاوسی‌راد<sup>۱</sup>، محمد انصاری قوجقار<sup>۲\*</sup>، حسن خسروی<sup>۳</sup>

### چکیده

پیش‌بینی جریان‌های سیلاب، نقشی حیاتی در مدیریت منابع آب در حوزه‌های آبخیز با پیچیدگی‌های هیدرولوژیک بالا ایفاء می‌کند. مدل‌های هیدرولوژیک اغلب در بازسازی تعاملات غیرخطی میان تغییرات جوی و پاسخ‌های پیچیده توپوگرافیک با چالش روبرو هستند. این پژوهش با هدف رفع این محدودیت‌ها، مدل هیبریدی نوین تحت عنوان MetNet-2-SwinTransformer پیشنهاد می‌دهد که بر پایه تلفیق قابلیت‌های استخراج ویژگی‌های زمانی مدل MetNet-2 و مدل‌سازی سلسله‌مراتبی مکانی در معماری Swin Transformer بنا شده است. عملکرد این مدل با استفاده از داده‌های دبی بیشینه ماهانه حوزه آبخیز کرج جهت ارزیابی توانایی آن در بازسازی پویایی‌های پیچیده جریان و رخداد‌های حدی هیدرولوژیک مورد ارزیابی قرار گرفت. عملکرد مدل هیبریدی پیشنهادی با استفاده از شاخص‌های آماری  $R$ ،  $NSE$  و  $RMSE$  به‌طور دقیق با مدل‌های انفرادی MetNet-2 و Swin Transformer مقایسه شد. نتایج نشان داد که مدل هیبریدی با برتری مطلق بر مدل‌های پایه، به دقت بسیار بالایی دست یافته و مقادیر  $NSE$  و  $R$  آن بیش از ۰/۹۵ به ثبت رساند. در حالی که مدل‌های انفرادی در بازسازی پیک‌های سیلاب و مدیریت نوسانات شدید جریان به‌ویژه در ایستگاه‌های با تغییرپذیری بالای دبی دچار محدودیت‌های جدی بودند، مدل هیبریدی موفق شد از طریق ایجاد اثر هم‌افزایی میان ویژگی‌های زمانی و مکانی، این خطاها را به‌طور مؤثری جبران کند. مدل هیبریدی توانست بر پدیده صاف‌شدگی پیک‌ها که در مدل‌های استاندارد ترنسفورمر رایج است، غلبه کرده و منحنی‌های هیدروگراف سیلاب را با دقت بسیار بالا بازسازی نماید. یافته‌های این پژوهش تأیید می‌کند که ادغام مکانیزم پنجره‌های لغزان با پیش‌بینی‌های زمانی، مدل را قادر می‌سازد تا اثرات مکانی کوچک‌مقیاس و تأثیرات توپوگرافیک پیچیده را با دقت بالا یعنی همبستگی و  $NS$  بالای ۰/۹۵ استخراج کند و همچنین مقدار خطا را در ایستگاه‌های با دبی بیشینه کمتر به زیر ۰/۱ برساند. اگرچه در سایر ایستگاه‌ها مقدار خطا به نسبت ۳ ایستگاه بیشتر بود اما به دلیل ذات داده‌های هیدرولوژیک این امر قابل قبول است. این تحقیق نشان می‌دهد که رویکرد هیبریدی پیشنهادی، چارچوبی بسیار پایدار و دقیق برای پیش‌بینی سیلاب در حوضه‌های پیچیده فراهم می‌آورد و می‌تواند مبنای قابل‌اعتمادی برای توسعه سیستم‌های هشدار زودهنگام و بهبود فرآیندهای تصمیم‌گیری در مدیریت منابع آب باشد.

### واژگان کلیدی:

پیش‌بینی سیلاب، یادگیری عمیق هیبریدی، ترنسفورمر، بازسازی هیدروگراف.



### مقاله پژوهشی

۱. دانشجوی کارشناسی ارشد علوم آبخیزداری، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران.

[ramtintavosirad@ut.ac.ir](mailto:ramtintavosirad@ut.ac.ir)

۲. استادیار، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران.

[ansari.ghojghar@ut.ac.ir](mailto:ansari.ghojghar@ut.ac.ir)

\* نویسنده مسئول

۳. استاد، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران.

[hakhosravi@ut.ac.ir](mailto:hakhosravi@ut.ac.ir)

۱۱۶۸-۲۶۰۵

شناسه مقاله:

۱۳۳۶-۱۳۱۶

شماره صفحه پایایی:

۱۴۰۵/۰۲/۲۱

تاریخ دریافت:

۱۴۰۵/۰۴/۰۲

تاریخ پذیرش:

۱۴۰۵/۰۴/۱۵

انتشار آنلاین:

۴۴ روز

زمان پذیرش:

استناددهی:

طاوسی‌راد، ر.، انصاری قوجقار، م.، و خسروی، ح. (۱۴۰۵). بررسی مدل تلفیقی هوشمند MetNet-2-SwinTransformer به منظور مدل‌سازی دبی پیک سیلاب (مطالعه موردی: حوزه آبخیز کرج). مدیریت اکوسیستم‌های طبیعی، ۶(۱)، ۶۷-۵۷.

## ۱- مقدمه

تغییر اقلیم می‌تواند باعث ایجاد تغییر در رژیم هیدرولوژی در سطح جهان شود به گونه‌ای که احتمال مواجهه با رخداد‌های اقلیمی مانند سیلاب افزایش یابد. از آن‌جا که افزایش این احتمال برای دوره‌های آتی می‌تواند آثار زیان‌باری را برای جوامع بشری در پی داشته باشد، الزام است تا وضعیت سیلاب حوضه‌ها در دوره‌های آتی تحت تأثیر پدیده تغییر اقلیم مورد بررسی و پیش‌بینی قرار گیرد (بشیر گنبد، ۱۴۰۱). پیش‌بینی سیلاب به‌عنوان یکی از مؤثرترین روش‌های غیر سازه‌ای مدیریت سیلاب در کاهش خطرات و خسارات ناشی از این پدیده حدی اقلیمی مطرح شود (آذری و همکاران، ۱۳۸۸). مدل سازی به‌عنوان یکی از ابزارهای کلیدی در مدیریت بحران‌های شهری، نقش مهمی در افزایش تاب‌آوری شهرها در برابر مخاطرات طبیعی ایفاء می‌کند (نصیری و همکاران، ۱۴۰۳). مدل‌های داده‌محور دارای توانایی یادگیری وابستگی‌های زمانی بلندمدت در داده‌ها می‌باشند که این امر منجر به پیش‌بینی‌های دقیق دبی جریان رودخانه شده است. مدل‌های شبکه عصبی مصنوعی؛ درخت تصمیم<sup>۲</sup> و ماشین بردار پشتیبان<sup>۳</sup> از جمله مدل‌های داده‌محور می‌باشند که برای تخمین دبی و جریان رودخانه‌ها مورد استفاده قرار گرفته‌اند (شیرازی و همکاران، ۱۴۰۲). ادغام هوش مصنوعی در مدل سازی هیدرولوژیکی یک پیشرفت چشم‌گیر است که ارزش قابل توجهی به مدیریت و تجزیه و تحلیل مقادیر زیاد داده اضافه می‌کند. این ادغام به مدل‌ها امکان می‌دهد از طریق یادگیری مستمر، خود را بهبود بخشند. در زمینه یادگیری عمیق، شبکه‌های عصبی بازگشتی<sup>۴</sup> و همچنین انواع آن‌ها مانند واحدهای دروازه‌ای بازگشتی، به دلیل توانایی‌شان در ارائه پیش‌بینی‌های نزدیک به واقعیت مورد ارزیابی قرار می‌گیرند که برای پیش‌بینی هیدرولوژیکی و مدیریت منابع آب ضروری است. مدل‌های شبکه عصبی حافظه کوتاه مدت بلند<sup>۵</sup> برای پیش‌بینی آسیب‌پذیری در برابر سیل در نظر گرفته شده‌اند و علاوه بر این که باعث بهبود دقت پیش‌بینی رواناب شده، هزینه‌ها و زمان آموزش مدل را کاهش می‌دهند (Obada et al., 2025).

مدل‌های عصبی روابط بین مشاهدات ورودی و متغیرهای خروجی را مستقیماً از داده‌ها یاد می‌گیرند. شبکه‌های عصبی قادرند در عرض چند ثانیه روی سخت‌افزار موازی اجرا شده و می‌توانند پیش‌بینی‌ها را با تناوب بیشتر و با تفکیک مکانی بالاتری تولید کنند. این شبکه‌ها همچنین به‌طرز قابل توجهی ساده بوده و با مازول‌های عمومی در چند ده خط کد بدون روال‌های تنظیم‌شده دستی برای یک کار خاص می‌توان شبکه‌های موجود را مشخص نمود. این ویژگی‌ها نه تنها می‌توانند پیش‌بینی‌های بهبودیافته‌ای را ارائه دهند، بلکه پیش‌بینی‌های مکرر و شخصی‌سازی‌شده را نیز ارائه داده و راهکارهای جدیدی را برای کاربردهایی که متکی به کارایی و انعطاف‌پذیری مدل‌ها هستند، باز می‌کنند (Espoholt et al., 2021). تکنیک‌های مبتنی بر یادگیری عمیق به‌منظور پیش‌بینی سری‌های زمانی به‌عنوان یک نقطه عطف مهم در پیش‌بینی‌ها عمل کرده‌اند (An et al., 2025). Transformer. یک مدل یادگیری عمیق برجسته است که به‌طور گسترده در زمینه‌های مختلف، مانند پردازش زبان طبیعی<sup>۶</sup>، بینش کامپیوتر<sup>۷</sup> و پردازش گفتار به‌کار گرفته شده است. Transformer در ابتدا به‌عنوان یک مدل برای ترجمه ماشینی پیشنهاد شد. آثار بعدی نشان می‌دهند که مدل‌های از پیش آموزش داده شده مبتنی بر Transformer می‌توانند به عملکرد موفقی در امور مختلف دست یابند. در نتیجه، Transformer به معماری اصلی در پردازش زبان طبیعی، به‌ویژه برای مدل‌های از پیش آموزش دیده تبدیل شده است. علاوه بر برنامه‌های کاربردی مرتبط با زبان، Transformer در بینایی رایانه‌ای، پردازش صدا و حتی رشته‌های دیگر، مانند شیمی و علوم زیستی نیز مورد استفاده قرار گرفته است (Lin et al., 2021). ستون فقرات Transformer، به نام Swin Transformer، که نقشه‌های ویژگی سلسله‌مراتبی را می‌سازد و پیچیدگی محاسباتی خطی نسبت به اندازه تصویر دارد. Swin Transformer یک نمایش سلسله‌مراتبی را با شروع از تکه‌های کوچک و ادغام تدریجی تکه‌های مجاور در لایه‌های عمیق‌تر Transformer می‌سازد. تعداد تکه‌ها در هر پنجره ثابت است و بنابراین پیچیدگی نسبت به اندازه تصویر خطی می‌شود. این مزایا Swin Transformer را به یک ستون فقرات با کاربرد عمومی برای وظایف مختلف بینایی تبدیل می‌کند، برخلاف معماری‌های مبتنی بر Transformer قبلی که نقشه‌های ویژگی با یک وضوح واحد تولید می‌کنند و دارای پیچیدگی درجه دوم هستند (Liu and Zhang, 2025).

MetNet-2 و مدل‌های پیش‌بینی عددی وضع هوا<sup>۸</sup> مشاهدات تجربی را جمع‌آوری می‌کنند تا یک حالت اولیه از جو را به‌عنوان مبنایی برای پیش‌بینی‌های خود به‌دست آورند. مشاهدات از انواع سنسورهایی می‌آیند که در ایستگاه‌های هواشناسی زمینی، ماهواره‌ها، هواپیماها، بالن‌ها و همچنین شناورهای اقیانوسی و غیره قرار دارند. یک منبع مهم مشاهدات در چارچوب حاضر، مشاهداتی است که از رادارهای زمینی به‌دست می‌آید. بازتابندگی که توسط این رادارها اندازه‌گیری می‌شود، میزان بارش را در یک زمان و مکان معین تخمین می‌زند (Espoholt et al., 2021).

با توجه به مطالعات صورت گرفته در زمینه پیش‌بینی سیلاب به‌وسیله الگوریتم‌های نوین هوش مصنوعی، مقایسه و ترکیب مدل‌های پیش‌بینی هواشناسی و مدل‌های ترنسفورمر صورت نگرفته است. پژوهش حاضر تلاش می‌کند تا با ارائه چارچوبی نوین، باعث بهبود وضعیت پیش‌بینی مقادیر سیلابی گردد. همچنین با توجه به نیاز روزافزون به مدل‌هایی با دقت بالا، سهولت در اجرا و بروزرسانی سریع در سامانه‌های هشدار سیلاب،

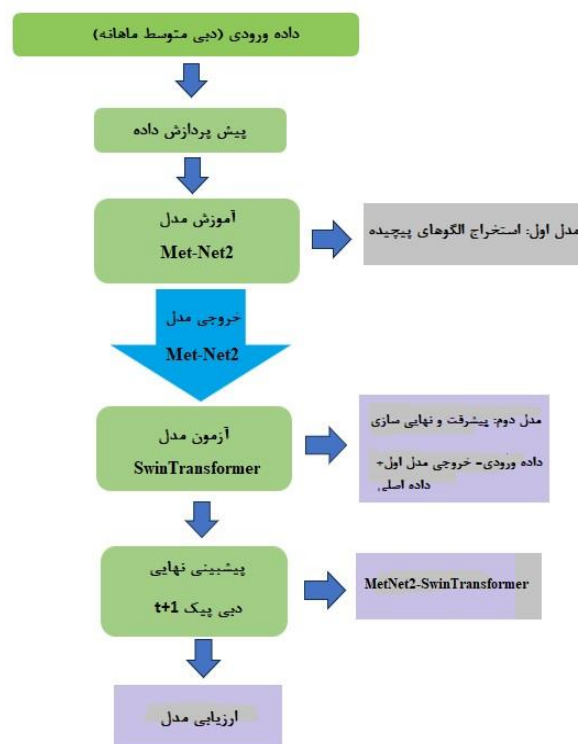
1. Artificial Neural Network
2. Decision Tree
3. Support Vector Machine
4. Recurrent Neural Network (RNN)
5. Long Short-Term Memory (LSTM)

6. Deep Learning (DL)
7. Natural Language Process (NLP)
8. Computer Vision (CV)
9. Numerical Weather Prediction (NWP)

رویکرد ارائه شده در این تحقیق، ضمن پاسخ‌گویی به این نیاز می‌تواند به‌عنوان الگویی برای توسعه مدل‌های هوشمند و کارآمد در مدیریت منابع آب کشور مورد استفاده قرار گیرد.

## ۲- مواد و روش‌ها

فرآیند آماده‌سازی داده‌ها شامل مراحل کنترل کیفیت، حذف داده‌های پرت، نرمال‌سازی، آزمون ایستایی و بازآرایی ساختاری جهت انطباق با معماری مدل‌های یادگیری عمیق انجام گرفت. داده‌ها نیز با نسبت ۸۰ به ۲۰ به دو مجموعه آموزشی و آزمون تقسیم شدند. در مرحله نخست، مدل‌های MetNet-2 و Swin Transformer به‌صورت مجزا جهت شبیه‌سازی دبی سیلاب به‌کار گرفته شدند و متعاقباً، یک چارچوب هیبریدی مبتنی بر تلفیق ویژگی‌های استخراج‌شده از هر دو مدل جهت ارتقاء دقت پیش‌بینی توسعه یافت. ارزیابی عملکرد مدل‌ها مبتنی بر شاخص‌های آماری  $RMSE$ ،  $R$ ،  $MAE$  و  $NSE$  صورت گرفت. نمودار جریان مراحل روش‌شناسی در شکل (۱) ترسیم شده است. تمامی مراحل پیاده‌سازی، آموزش شبکه‌ها و تنظیم پارامترها در محیط نرم‌افزار R انجام شد که امکان مقایسه دقیق و شناسایی بهینه‌ترین ساختار هوشمند را برای پیش‌بینی سیلاب فراهم آورد.



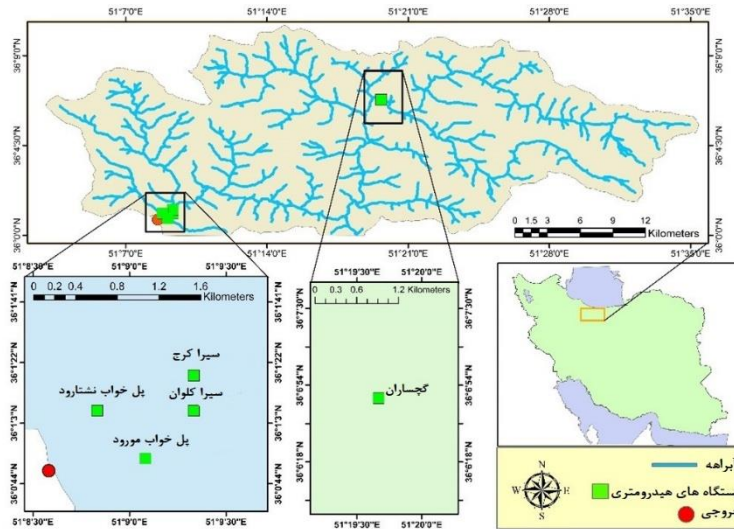
شکل (۱): فلوچارت مراحل انجام پژوهش

### ۲-۱- منطقه مورد مطالعه

در پژوهش حاضر عملکرد دو مدل پیشرفته MetNet-2 و Swin Transformer به‌صورت انفرادی و همچنین چارچوب هیبریدی MetNet-2-Swin Transformer به‌منظور توانایی این مدل‌ها در پیش‌بینی سیلاب در حوزه آبخیز کرج مورد ارزیابی قرار گرفت. بدین منظور، داده‌های مربوط به دبی بیشینه ماهانه ثبت‌شده در ایستگاه‌های هیدرومتری واقع در حوزه آبخیز کرج طی یک دوره آماری ۳۰ ساله (۱۴۰۰-۱۳۷۱) گردآوری و مورد استفاده قرار گرفت.

حوضه آبخیز کرج، به‌عنوان یکی از مهم‌ترین زیرحوضه‌های جنوبی رشته‌کوه البرز، نقشی کلیدی در تأمین منابع آب سطحی و پایداری رژیم جریان در حوضه مرکزی ایران ایفاء می‌کند. ویژگی‌های توپوگرافیک کوهستانی، شیب‌های تند، بارش‌های رگباری و تنوع کاربری اراضی، این منطقه را به کانون رخدادهای سیلاب ناگهانی تبدیل کرده است. تغییرات مکانی-زمانی الگوهای بارش در کنار گسترش فعالیت‌های انسانی، موجب تشدید نوسانات دبی و افزایش فراوانی سیلاب‌ها در دهه‌های اخیر شده است. با توجه به رژیم جریان عمدتاً برفی-بارانی در این حوزه و نقش اساسی ذوب برف در تغذیه جریان پایه، به‌ویژه در فصول گرم، وقوع بارش‌های شدید در فصول سرد، پیش‌بینی دقیق پاسخ‌های هیدرولوژیکی را به چالشی بنیادین در مدیریت منابع آب بدل ساخته است. در پژوهش حاضر، داده‌های مربوط به دبی بیشینه ماهانه از پنج ایستگاه هیدرومتری فعال شامل گچسر، سیرا-کلوان، سیرا-کرج، نشتارود و پل خواب-دورود استخراج گردید. میانگین دبی بیشینه در این ایستگاه‌ها به ترتیب برابر با ۲۲/۱۷، ۵۶/۱۶، ۱۱/۱۲، ۳۶/۰ و

۲۸/۰ مترمکعب بر ثانیه برآورد شد که بیانگر ناهمگونی در رفتار هیدرولوژیکی زیرحوضه‌های مورد مطالعه است (موقعیت ایستگاه‌ها در شکل (۲) مشخص شده است).



شکل (۲): ایستگاه‌های مورد مطالعه

## ۲-۲- مدل SwinTransformer

ترنسفورمرها بر پایه مکانیزم خود-توجه به منظور پردازش داده‌ها استفاده می‌کند. فرمول کلی مکانیزم خود-توجه در رابطه (۱) نشان داده شده است. مدل Swin Transformer یکی از پیشرفته‌ترین معماری‌های مبتنی بر ترنسفورمر در پردازش داده‌های مکانی محسوب می‌شود که به منظور غلبه بر محدودیت‌های محاسباتی ترنسفورمرهای استاندارد در داده‌های تصویری و شبکه‌ای توسعه یافته است. این ویژگی موجب می‌شود که مدل بتواند اطلاعات مکانی را با دقت بالاتری حفظ نماید و همزمان پیچیدگی محاسباتی کاهش یابد. در این معماری، داده ورودی ابتدا به مجموعه‌ای از تکه‌های غیرهمپوشان تقسیم شده و هر تکه به یک بردار تعبیه تبدیل می‌شود. سپس این بردارها به‌عنوان دنباله‌ای از نشانه‌ها وارد بلوک‌های ترنسفورمر می‌شوند. یکی از مهم‌ترین نوآوری‌های Swin Transformer استفاده از مکانیزم توجه خودکار محلی مبتنی بر پنجره‌های لغزان است که در آن عملیات توجه به‌جای کل تصویر، تنها در محدوده پنجره‌های محلی محاسبه می‌شود که با رابطه (۲) تعریف می‌شود. این امر سبب کاهش چشمگیر پیچیدگی محاسباتی از مرتبه مربعی به مرتبه خطی نسبت به اندازه ورودی می‌شود. ساختار یک بلوک Swin Transformer شامل دو بخش اصلی ماژول توجه چندسری مبتنی بر پنجره و یک شبکه پرسپترون چندلایه است. در این ساختار، قبل از هر ماژول از یک لایه نرمال‌سازی استفاده شده و پس از هر بخش نیز اتصال باقی‌مانده اعمال می‌شود تا پایداری آموزش افزایش یابد. ساختار بلوک‌ها در رابطه (۳) نمایش داده شده است (Liu et al., 2021). Swin Transformer با جایگزینی ماژول استاندارد توجه به خود چندگانه در یک بلوک ترنسفورمر با ماژولی بر اساس پنجره‌های لغزان ساخته می‌شود و این امر درحالی است که سایر لایه‌ها یکسان نگه داشته می‌شوند (Liu and Zhang, 2025). در برخی مطالعات جدید، از Swin Transformer در ترکیب با ماژول‌های تولید نقشه فعال‌سازی کلاس (CAM) استفاده شده است تا بتوان از توکن‌های خروجی برای استخراج نقشه‌های ویژگی مکانی بهره گرفت. در این فرآیند، توکن‌های خروجی ابتدا به یک نقشه ویژگی دوبعدی تبدیل شده و پس از اعمال تابع ReLU و نرمال‌سازی، نقشه‌های فعال‌سازی کلاس تولید می‌شوند که نقش مهمی در تحلیل ویژگی‌های مکانی دارند و در رابطه (۴) مشخص شده است (Ahmadi and Kasaei, 2025).

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_{attn}}}\right)V \quad \text{رابطه (۱)}$$

که در آن،  $Q$  ماتریس پرس و جو،  $K$  ماتریس کلید و ماتریس ارزش است.  $d_{attn}$  نیز بعد بردار کلید است.

$$W - MSA(X) = Attention(XW_Q, XW_K, XW_V) \quad \text{رابطه (۲)}$$

$$\hat{X} = W - MSA(LN(X)) \quad \text{رابطه (۳)}$$

$$X' = MLP(LN(\hat{X})) + \hat{X} \quad \text{رابطه (۳)}$$

در روابط (۲) و (۳)،  $LN$  نشان‌دهنده لایه نرمال‌سازی و  $W - MSA$  بیان گر ماژول توجه چندسری مبتنی بر پنجره است.  $MLP$  نیز شبکه پرسپترون چندلایه را نشان می‌دهد.

$$C_{out} = Norm(ReLU(FOUT)) \quad \text{رابطه (۴)}$$

## ۲-۳- مدل MetNet-2

مدل MetNet یکی از نخستین چارچوب‌های یادگیری عمیق توسعه‌یافته توسط گوگل برای پیش‌بینی کوتاه‌مدت بارش محسوب می‌شود که با هدف ارائه پیش‌بینی‌های احتمالاتی بارش در مقیاس مکانی با تفکیک بالا طراحی گردید. نسخه اولیه این مدل قادر بود بارش را در بازه زمانی حدود ۸ ساعت آینده پیش‌بینی کند و نسبت به روش‌های عددی هواشناسی دقت بالاتری در پیش‌بینی رخداد‌های بارش شدید نشان داد (Sønderby et al., 2021). در ادامه، مدل MetNet-2 به‌عنوان نسخه پیشرفته این معماری معرفی شد که با گسترش افق پیش‌بینی تا ۱۲ ساعت و افزایش ظرفیت پردازش داده‌های چندمنبعی، توانست عملکرد قابل توجهی در پیش‌بینی فضایی-زمانی بارش ارائه دهد. این مدل با بهره‌گیری از داده‌های راداری، ماهواره‌ای و متغیرهای جوی، قادر است الگوهای پیچیده دینامیک اتمسفر را در مقیاس مکانی بزرگ‌تر یاد بگیرد (Espenholt et al., 2022). از نظر ساختاری، MetNet-2 یک معماری عمیق ترکیبی مبتنی بر کانولوشن و حافظه زمانی است که برای استخراج همزمان وابستگی‌های مکانی و زمانی طراحی شده است. در این مدل، به‌جای استفاده گسترده از مکانیزم‌های توجه، از ترکیب کانولوشن‌های استاندارد و کانولوشن تأخیری همراه با بلوک‌های استفاده می‌شود تا میدان دید شبکه افزایش یابد بدون آنکه تعداد پارامترها به‌طور چشمگیری رشد کند. کانولوشن تأخیری در رابطه (۵) و بلوک‌های ConvLSTM در رابطه (۶) مشخص شده است. این ویژگی باعث می‌شود مدل بتواند روابط بلندمدت فضایی-زمانی را به‌صورت کارآمد استخراج کند (Espenholt et al., 2022). MetNet-2 از یک چارچوب پیش‌بینی دو مرحله‌ای فضایی-زمانی نیز بهره می‌برد که در آن فرآیند یادگیری شامل یک بخش ترجمه ویژگی‌ها و یک بخش رمزگذاری-رمزگشایی است. این طراحی با هدف کاهش ناسازگاری بین نمایش ویژگی‌ها و اهداف یادگیری ارائه شده است. در این ساختار، بخشی از پارامترها در مراحل مختلف آموزش به‌صورت موقت ثابت نگه داشته می‌شوند و به‌روزرسانی آن‌ها با استفاده از روش‌های مبتنی بر Momentum انجام می‌شود تا پایداری آموزش حفظ گردد (Liu and Zhang, 2025). علاوه بر این، MetNet-2 از یک تابع هزینه پیش‌بینی در فضای نهفته استفاده می‌کند که به شبکه اجازه می‌دهد به‌طور مستقیم بر یادگیری دینامیک آینده سیستم تمرکز کند. این راهبرد موجب می‌شود مدل به‌جای تمرکز صرف بر بازسازی داده‌ها، توانایی پیش‌بینی دقیق‌تری در سیستم‌های پیچیده فضایی-زمانی داشته باشد. همچنین استفاده از رمزگذارها و رمزگشاهای اختصاصی برای متغیرهای مختلف هواشناسی امکان حفظ ویژگی‌های فیزیکی هر متغیر و ادغام مؤثر اطلاعات چندمتغیره را فراهم می‌سازد (Liu and Zhang, 2025). در مجموع، ترکیب ساختار کانولوشنی چندمقیاسی، حافظه زمانی ConvLSTM و یادگیری در فضای نهفته باعث شده است MetNet-2 به یکی از پیشرفته‌ترین مدل‌های یادگیری عمیق برای پیش‌بینی پدیده‌های جوی و فرآیندهای هیدرولوژیکی تبدیل شود.

$$y(i) = \sum_k x(i + r \cdot k)w(k) \quad \text{رابطه (۵)}$$

$$\begin{aligned} i_t &= \sigma(W_i * X_t + U_i * H_{t-1}) \\ f_t &= \sigma(W_f * X_t + U_f * H_{t-1}) \\ C_t &= f_t \odot C_{t-1} + i_t \odot \tan h(W_c * X_t) \\ H_t &= O_t \odot \tan h(C_t) \end{aligned} \quad \text{رابطه (۶)}$$

در روابط (۵) و (۶)  $X_t$  بردار ورودی در گام زمانی،  $H_{t-1}$  حالت پنهان از گام زمانی قبلی،  $C_{t-1}$  حالت سلول از گام زمانی قبلی که حافظه بلندمدت را حفظ می‌کند  $i_t$  گیت ورودی است که وظیفه آن تصمیم‌گیری در مورد مقادیر جدیدی است که قرار است ذخیره شوند،  $f_t$  گیت فراموشی که وظیفه آن تعیین میزان اطلاعاتی است که باید از حالت سلول قبلی حذف شود،  $C_t$  حالت سلول که خط اصلی انتقال اطلاعات در طول زمان است،  $O_t$  گیت خروجی که تعیین می‌کند چه بخشی از حالت سلول به عنوان خروجی (حالت پنهان جدید) ارسال شود،  $\tan h$  تابع فعال‌ساز تانژانت هائپربولیک که مقادیر را بین -۱ و ۱ تنظیم می‌کند و  $W$  و  $U$  ماتریس‌های وزن مربوط به ورودی و حالت پنهان قبلی هستند.

## ۲-۴- معیارهای ارزیابی مدل

ارزیابی مدل نیز یک جزء کلیدی در پیش‌بینی آب و هوا مبتنی بر هوش مصنوعی است. معیارهای بسیاری برای تعیین کمیت مهارت مدل‌ها استفاده می‌شود، از جمله معیارهای پیش‌بینی قطعی و معیارهای پیش‌بینی گروهی (Zhang et al., 2025). ارزیابی مدل‌های مورد پژوهش با معیارهای RMSE، MAE، NS و ضریب همبستگی مورد ارزیابی قرار گرفتند.

## ۲-۵- مدل‌های پیش‌بینی

در پژوهش حاضر، به‌منظور شبیه‌سازی و پیش‌بینی رواناب ماهانه در حوزه آبخیز کرج، عملکرد سه معماری یادگیری عمیق شامل Swin Transformer، MetNet2-SwinTransformer و ساختار هیبریدی SwinTransformer مورد ارزیابی قرار گرفت. داده‌های ورودی بر پایه سری‌های زمانی دبی بیشینه ماهانه حاصل از ایستگاه‌های هیدرومتری منطقه تدوین گردید. در این راستا، جهت پیش‌بینی دبی ماه آتی  $\{Q_{t+1}\}$ ، از مقادیر گذشته رواناب به‌عنوان متغیرهای تأخیری استفاده شد. با هدف تحلیل نقش حافظه زمانی سیستم هیدرولوژیکی و تعیین تأثیر طول بازه زمانی اطلاعات گذشته بر دقت پیش‌بینی، چهار سناریوی متمایز بر پایه یک فصل تأخیر طراحی شد. در سناریوی نخست، از دبی متوسط سه ماه اخیر به‌عنوان بردار ورودی جهت

ارزیابی توانایی مدل ها در استخراج ویژگی های حافظه کوتاه مدت استفاده گردید. در سناریوی دوم، با افزایش طول تاخیر به شش ماه، تأثیر اطلاعات تاریخی گسترده تر بر فرآیند پیش بینی مورد واکاوی قرار گرفت. سناریوی سوم با تعریف ورودی بر اساس سه فصل متوالی (نه ماه گذشته)، بر ارزیابی قابلیت مدل ها در بازشناسی الگوهای فصلی رواناب تمرکز داشت. در نهایت، در سناریوی چهارم با در نظر گرفتن چهار فصل متوالی (دوازده ماه گذشته)، نقش حافظه بلندمدت حوزه در ارتقاء دقت پیش بینی بررسی شد. به طور کلی، این رویکرد با تعریف ساختار ورودی- خروجی در قالب ترکیب های تأخیری مختلف (از یک تا چهار دوره فصلی)، امکان مقایسه جامع عملکرد مدل ها را تحت سطوح مختلف اطلاعات زمانی فراهم آورده و میزان حساسیت هر معماری را نسبت به حافظه هیدرولوژیکی سیستم مشخص می سازد.

$$Q_{(t+1)} = f(Q_{(t)}) \quad \text{ترکیب (۱)}$$

$$Q_{(t+1)} = f(Q_{(t)} \cdot Q_{(t-1)}) \quad \text{ترکیب (۲)}$$

$$Q_{(t+1)} = f(Q_{(t)} \cdot Q_{(t-1)} \cdot Q_{(t-2)}) \quad \text{ترکیب (۳)}$$

$$Q_{(t+1)} = f(Q_{(t)} \cdot Q_{(t-1)} \cdot Q_{(t-2)} \cdot Q_{(t-3)}) \quad \text{ترکیب (۴)}$$

### ۳- بحث و نتایج

جدول های (۱) تا (۳)، نتایج حاصل از تحلیل عملکرد سه مدل MetNet-2, SwinTransformer و مدل هیبریدی MetNet2-SwinTransformer به منظور پیش بینی سیلاب ماهانه حوزه آبخیز کرج را نشان می دهد. با توجه به نتایج به دست آمده، مشخص شد که مدل هیبریدی ارائه شده از ترکیب دو مدل مورد مطالعه، به طور قابل توجهی دقت بالاتری را به ثبت رساند و قادر است الگوهای پیچیده و غیرخطی جریان را با دقتی بسیار بالاتر نسبت به مدل های انفرادی بازسازی کند. مدل های MetNet-2 و SwinTransformer به طور انفرادی عملکردی ضعیف را ارائه دادند. مقدار NS کمتر از ۰/۶ و ۰/۵ و همبستگی کمتر از ۰/۵ برای هر دو مدل نشان داد که این مدل ها در پیش بینی روند کلی جریان عملکرد قابل قبولی داشتند اما با پیچیده شدن ساختار پیش بینی، مقابله با سیلاب های ناگهانی و بازسازی رفتار ساختارهای سری زمانی ناموفق بوده اند. در پژوهش حاضر، با توجه به جدول (۱)، مدل هیبریدی MetNet2-SwinTransformer با دستیابی به مقادیر نش سائکلیف (NS) بیش از ۰/۹۵۹ و ضریب همبستگی بیش از ۰/۹۵۱، نزدیک ترین برآورد را به مقادیر مشاهداتی فراهم کرد که نشان دهنده توانایی بالای مدل در بازسازی و استخراج روابط پیچیده غیرخطی و پویایی آب در داده های هیدرولوژیکی است. همچنین مقادیر خطای ثبت شده در دو ایستگاه پل خواب- نشتارود و پل خواب- درورد مقادیر ۰/۰۲۲ تا ۰/۰۴۴ به ثبت رسید که در مدل سازی سیلاب، بازسازی بسیار موفق و انحراف بسیار ناچیز در روند بازسازی رفتار سری زمانی را نشان می دهد. هر چند در سه ایستگاه دیگر که میانگین دبی و نوسانات دبی بیشتر و وجود داشت، میزان خطای بالاتر نسبت به سایر ایستگاه ها به ثبت رسید. در ایستگاه های گچسرو سیرا- کلوان مقادیر RMSE بیش از ۱/۳۱۴ و برای ایستگاه سیرا- کرج، RMSE بیش از ۰/۸ گزارش شد. همچنین در این ایستگاه ها، مقادیر MAE مشابهی به ثبت رسید. این افزایش ناشی از ویژگی های ساختاری داده ها و نوسانات هیدرولوژیکی ایستگاه ها بوده و ضعف مدل را ثابت نمی کند زیرا این ایستگاه ها دبی بیشینه ماهانه بیشتری دارند و تغییرات شدیدتری در رژیم جریان ثبت می کنند که شناسایی کامل آن ها حتی برای مدل های پیشرفته با چالش همراه است و همچنین با توجه به نوسانات بالای دبی در این ایستگاه ها، مقادیر خطای ثبت شده نیز به همراه آن افزایش می یابد. لازم به ذکر است که خطای ثبت شده برای مدل هیبریدی به نسبت سایر مدل ها، بهتر عمل کرده است.

جدول (۱): نتایج آماری داده های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل MetNet-2-SwinTransformer

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
گچسرو	۴	۰/۹۹۶	۱/۳۱۴	۱/۲۵۴	۰/۹۹۱	۱/۲۵۴	۱/۳۱۴	۰/۹۹۶	
	۳	۰/۹۹۱	۱/۳۱۷	۱/۲۵۹	۰/۹۸۴	۱/۲۵۹	۱/۳۱۷	۰/۹۹۱	
	۲	۰/۹۸۷	۱/۳۱۸	۱/۲۶۱	۰/۹۸۱	۱/۲۶۱	۱/۳۱۸	۰/۹۸۷	
سیرا- کلوان	۱	۰/۹۸۳	۱/۳۲۱	۱/۲۶۴	۰/۹۷۸	۱/۲۶۴	۱/۳۲۱	۰/۹۸۳	
	۴	۰/۹۹۵	۱/۳۲۳	۱/۲۶۵	۰/۹۸۹	۱/۲۶۵	۱/۳۲۳	۰/۹۹۵	
	۳	۰/۹۸۹	۱/۳۲۷	۱/۲۶۷	۰/۹۸۴	۱/۲۶۷	۱/۳۲۷	۰/۹۸۹	
	۲	۰/۹۸۵	۱/۳۲۹	۱/۲۷۱	۰/۹۷۹	۱/۲۷۱	۱/۳۲۹	۰/۹۸۵	
سیرا- کرج	۱	۰/۹۸۳	۱/۳۳۱	۱/۲۷۴	۰/۹۷۶	۱/۲۷۴	۱/۳۳۱	۰/۹۸۳	
	۴	۰/۹۹۴	۰/۸۴۶	۰/۷۵۶	۰/۹۸۸	۰/۷۵۶	۰/۸۴۶	۰/۹۹۴	
	۳	۰/۹۸۹	۰/۸۴۸	۰/۷۵۹	۰/۹۸۳	۰/۷۵۹	۰/۸۴۸	۰/۹۸۹	
	۲	۰/۹۸۴	۰/۸۴۹	۰/۷۶۱	۰/۹۷۷	۰/۷۶۱	۰/۸۴۹	۰/۹۸۴	
پل خواب- نشتارود	۱	۰/۹۸۲	۰/۸۵۲	۰/۷۶۴	۰/۹۷۵	۰/۷۶۴	۰/۸۵۲	۰/۹۸۲	
	۴	۰/۹۹۳	۰/۰۱۱	۰/۰۰۶	۰/۹۸۶	۰/۰۰۶	۰/۰۱۱	۰/۹۹۳	
	۳	۰/۹۸۷	۰/۰۱۳	۰/۰۰۷	۰/۹۸۲	۰/۰۰۷	۰/۰۱۳	۰/۹۸۷	
	۲	۰/۹۸۳	۰/۰۱۷	۰/۰۰۹	۰/۹۷۶	۰/۰۰۹	۰/۰۱۷	۰/۹۸۳	
پل خواب- مورود	۱	۰/۹۸۱	۰/۰۱۹	۰/۰۱۱	۰/۹۷۴	۰/۰۱۱	۰/۰۱۹	۰/۹۸۱	
	۴	۰/۹۹۲	۰/۰۲۱	۰/۰۱۴	۰/۹۸۵	۰/۰۱۴	۰/۰۲۱	۰/۹۹۲	
	۳	۰/۹۸۷	۰/۰۲۲	۰/۰۱۸	۰/۹۸۱	۰/۰۱۸	۰/۰۲۲	۰/۹۸۷	
	۲	۰/۹۸۲	۰/۰۲۳	۰/۰۱۸	۰/۹۷۵	۰/۰۱۸	۰/۰۲۳	۰/۹۸۲	
۱	۰/۹۷۹	۰/۰۲۷	۰/۰۲۴	۰/۹۷۳	۰/۰۲۴	۰/۰۲۷	۰/۹۷۹		

جدول (۲): نتایج آماری داده‌های ورودی جهت مدل‌سازی و پیش‌بینی سیلاب با مدل SwinTransformer

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
گچسر	۴	۰/۴۶۳	۰/۸۰۲	۰/۸۲۳	۰/۴۸۴	۰/۴۶۸	۰/۸۱۱	۰/۸۵۶	۰/۴۴۸
	۳	۰/۴۵۷	۰/۸۰۲	۰/۸۲۷	۰/۴۷۸	۰/۴۷۳	۰/۸۱۲	۰/۸۵۹	۰/۴۴۲
	۲	۰/۴۵۴	۰/۸۰۶	۰/۸۳۱	۰/۴۷۳	۰/۴۶۸	۰/۸۱۳	۰/۸۶۳	۰/۴۳۹
	۱	۰/۴۵۱	۰/۸۰۷	۰/۸۳۷	۰/۴۶۹	۰/۴۶۲	۰/۸۱۷	۰/۸۶۶	۰/۴۳۶
سیرا-کلوان	۴	۰/۴۶۲	۰/۸۰۹	۰/۸۴۱	۰/۴۸۳	۰/۴۷۸	۰/۸۲۱	۰/۸۷۱	۰/۴۴۷
	۳	۰/۴۵۶	۰/۸۱۲	۰/۸۴۲	۰/۴۷۷	۰/۴۷۲	۰/۸۲۳	۰/۸۷۳	۰/۴۴۱
	۲	۰/۴۵۳	۰/۸۱۷	۰/۸۴۳	۰/۴۷۲	۰/۴۶۶	۰/۸۲۷	۰/۸۷۷	۰/۴۳۸
	۱	۰/۴۵۱	۰/۸۱۹	۰/۸۴۷	۰/۴۶۸	۰/۴۶۱	۰/۸۲۳	۰/۸۸۱	۰/۴۳۵
سیرا-کرج	۴	۰/۴۶۱	۰/۲۳	۰/۳۵۴	۰/۴۸۲	۰/۴۷۷	۰/۴۰۲	۰/۴۷۷	۰/۴۴۶
	۳	۰/۴۵۵	۰/۳۱	۰/۳۵۷	۰/۴۷۶	۰/۴۷۱	۰/۴۰۷	۰/۴۷۱	۰/۴۳۹
	۲	۰/۴۵۲	۰/۳۷	۰/۳۵۹	۰/۴۷۱	۰/۴۶۵	۰/۴۱۲	۰/۴۶۵	۰/۴۳۷
	۱	۰/۴۴۹	۰/۴۲	۰/۳۶۲	۰/۴۶۷	۰/۴۶۱	۰/۴۱۶	۰/۴۶۱	۰/۴۳۴
پل خواب-نشتارود	۴	۰/۴۵۸	۰/۲۳۴	۰/۲۸۶	۰/۴۸۱	۰/۴۷۵	۰/۳۰۹	۰/۴۷۶	۰/۴۴۵
	۳	۰/۴۵۴	۰/۲۳۶	۰/۲۸۸	۰/۴۷۵	۰/۴۶۹	۰/۳۱۲	۰/۴۶۹	۰/۴۳۸
	۲	۰/۴۵۱	۰/۲۳۸	۰/۲۸۹	۰/۴۶۹	۰/۴۶۶	۰/۳۱۸	۰/۴۶۴	۰/۴۳۵
	۱	۰/۴۴۷	۰/۲۴۱	۰/۲۹۳	۰/۴۶۶	۰/۴۶۶	۰/۳۱۹	۰/۴۵۹	۰/۴۳۲
پل خواب-مورود	۴	۰/۴۵۷	۰/۲۴۲	۰/۲۹۴	۰/۴۷۹	۰/۴۷۴	۰/۳۳۳	۰/۴۷۵	۰/۴۴۴
	۳	۰/۴۵۳	۰/۲۴۴	۰/۲۹۵	۰/۴۷۴	۰/۴۶۸	۰/۳۲۷	۰/۴۶۸	۰/۴۳۷
	۲	۰/۴۴۷	۰/۲۴۶	۰/۲۹۸	۰/۴۶۸	۰/۴۶۸	۰/۳۲۱	۰/۴۶۳	۰/۴۳۴
	۱	۰/۴۴۶	۰/۲۴۸	۰/۳۰۱	۰/۴۶۵	۰/۴۶۵	۰/۳۳۴	۰/۴۵۸	۰/۴۲۸

جدول (۳): نتایج آماری داده‌های ورودی جهت مدل‌سازی و پیش‌بینی سیلاب با مدل MetNet-2

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
گچسر	۴	۰/۵۰۸	۷/۴۴۳	۷/۸۵۱	۰/۵۲۸	۰/۴۹۹	۷/۵۵۱	۷/۹۱۳	۰/۵۱۷
	۳	۰/۵۰۳	۷/۴۴۷	۷/۸۵۹	۰/۵۲۴	۰/۴۹۵	۷/۵۵۳	۷/۹۱۷	۰/۵۱۳
	۲	۰/۴۹۷	۷/۴۵۱	۷/۸۶۱	۰/۵۲۱	۰/۴۸۸	۷/۵۵۸	۷/۹۲۱	۰/۵۰۸
	۱	۰/۴۹۴	۷/۴۵۶	۷/۸۶۴	۰/۵۱۷	۰/۴۸۳	۷/۵۶۱	۷/۹۲۳	۰/۵۰۴
سیرا-کلوان	۴	۰/۵۰۷	۷/۴۶۱	۷/۸۶۹	۰/۵۲۷	۰/۴۹۸	۷/۵۶۳	۷/۹۲۷	۰/۵۱۶
	۳	۰/۵۰۲	۷/۴۶۳	۷/۸۷۱	۰/۵۲۴	۰/۴۹۴	۷/۵۶۴	۷/۹۳۱	۰/۵۱۳
	۲	۰/۴۹۶	۷/۴۶۶	۷/۸۷۷	۰/۵۱۹	۰/۴۸۳	۷/۵۶۸	۷/۹۳۷	۰/۵۰۷
	۱	۰/۴۹۳	۷/۴۶۸	۷/۸۸۱	۰/۵۱۶	۰/۴۸۱	۷/۵۷۱	۷/۹۳۹	۰/۵۰۳
سیرا-کرج	۴	۰/۵۰۶	۵/۸۲۴	۶/۱۵۷	۰/۵۲۶	۰/۴۹۷	۵/۹۳۱	۶/۲۰۳	۰/۵۱۵
	۳	۰/۵۰۱	۵/۸۳۱	۶/۱۶۱	۰/۵۲۳	۰/۴۹۳	۵/۹۳۷	۶/۲۰۴	۰/۵۱۲
	۲	۰/۴۹۵	۵/۸۳۸	۶/۱۶۶	۰/۵۱۸	۰/۴۸۲	۵/۹۴۱	۶/۲۰۹	۰/۵۰۶
	۱	۰/۴۹۲	۵/۸۴۴	۶/۱۷۳	۰/۵۱۴	۰/۴۷۹	۵/۹۴۶	۶/۲۱۳	۰/۵۰۲
پل خواب-نشتارود	۴	۰/۵۰۴	۰/۱۸۳	۰/۲۳۱	۰/۵۲۵	۰/۴۹۶	۰/۲۰۶	۰/۲۵۶	۰/۵۱۴
	۳	۰/۵۰۱	۰/۱۸۴	۰/۲۳۴	۰/۵۲۲	۰/۴۹۲	۰/۲۰۸	۰/۲۵۹	۰/۵۱۱
	۲	۰/۴۹۴	۰/۱۸۸	۰/۲۳۷	۰/۵۱۷	۰/۴۸۱	۰/۲۰۹	۰/۲۶۱	۰/۵۰۵
	۱	۰/۴۹۱	۰/۱۹۳	۰/۲۴۱	۰/۵۱۳	۰/۴۷۷	۰/۲۱۳	۰/۲۶۴	۰/۵۰۱
پل خواب-مورود	۴	۰/۵۰۳	۰/۱۹۴	۰/۲۴۳	۰/۵۲۴	۰/۴۹۵	۰/۲۱۶	۰/۲۶۷	۰/۵۱۳
	۳	۰/۴۹۹	۰/۱۹۷	۰/۲۴۸	۰/۵۲۱	۰/۴۹۱	۰/۲۱۷	۰/۲۶۹	۰/۵۰۹
	۲	۰/۴۹۳	۰/۲۰۱	۰/۲۵۳	۰/۵۱۶	۰/۴۷۹	۰/۲۲۱	۰/۲۷۱	۰/۵۰۴
	۱	۰/۴۸۹	۰/۲۰۳	۰/۲۵۴	۰/۵۱۲	۰/۴۷۳	۰/۲۲۴	۰/۲۷۴	۰/۴۹۸

نکته مهم قابل دریافت از نتایج ثبت شده در جدول (۲) و (۳)، ثبت مقادیر خطای بسیار زیاد مدل MetNet-2 در روند بازسازی این رفتارها و در مقابل، عملکرد قابل قبول مدل SwinTransformer در تمامی ایستگاه‌ها به غیر از ایستگاه سیرا-کرج در خطاهای ثبت شده است. در ایستگاه‌هایی که دارای دبی بیشینه ماهانه بالاتری بوده‌اند مانند مدل هیبریدی، خطای بالاتری ثبت شده است. در همین راستا، مقادیر MAE و RMSE در سه ایستگاه گچسر، سیرا-کلوان و سیرا-کرج بین ۴/۳۵۱ تا ۶/۴۰۲ مشاهده شد که نشان‌دهنده حساسیت این مدل به داده‌های پرت و رفتارهای ناپایدار سری زمانی است. با این وجود در دو ایستگاه دیگر که داده‌ها نوسان کمتری داشته‌اند، مقادیر MAE به حدود ۰/۱۲۱ تا ۰/۱۴۱ و مقدار RMSE به حدود ۰/۱۶۳ تا ۰/۱۸۵ کاهش پیدا کرده و عملکرد مدل بسیار خوب بوده و در ایستگاه‌های گچسر و سیرا-کلوان از مدل هیبریدی نیز بهتر عمل کرده است. این پدیده که در نگاه اول برخلاف روند کلی عملکرد مدل هیبریدی به نظر می‌رسد از منظر هیدرولوژیکی قابل توجیه است. در ایستگاه‌هایی که دارای

دبی بیشینه و پویایی آب بیش‌تری بوده، عوامل توپوگرافی تاثیر زیادی در به وقوع پیوستن دارند. این عوامل در منحنی‌های دبی بیشینه ماهانه که به‌عنوان ورودی مدل استفاده شده است به‌صورت روابط ریاضی پیچیده پنهان شده‌اند و از آنجایی که مدل SwinTransformer بر پایه مکانیسم پنجره لغزان و استخراج ویژگی‌های مکانی چند مقیاس بنا شده است در این ایستگاه‌ها توانایی بیشتری در مدل‌سازی رفتار آب و کاهش خطاها نشان داده است. در مقابل مدل هیبریدی ارائه شده به دلیل ترکیب با اجزای MetNet-2، تلاش می‌کند تا الگوهای زمانی مربوط به پیش‌بینی بارش را نیز در محاسبات خود ادغام کند. در ایستگاه‌هایی که دبی به دلیل توپوگرافی شدید، بسیار سریع و مستقل از نوسانات جزئی زمانی بارش است، تمرکز بر توالی‌های زمانی جوی در مدل هیبریدی می‌تواند منجر به نوعی تداخل سیگنال شود. مدل هیبریدی سعی می‌کند الگوهای زمانی متصل به بارش را با پاسخ‌های سریع دبی هماهنگ کند در حالی که در این ایستگاه‌ها، پاسخ دبی صرفاً تابع شدت لحظه‌ای و ساختار مکانی جریان است. بنابراین، برتری Swin Transformer نشان می‌دهد که این مدل در بازشناسی الگوهای حدی استخراج شده از داده‌های دبی بدون نیاز به ورودی‌های فیزیکی مستقیم، عملکردی بسیار دقیق و حساس‌تر از مدل ترکیبی دارد.

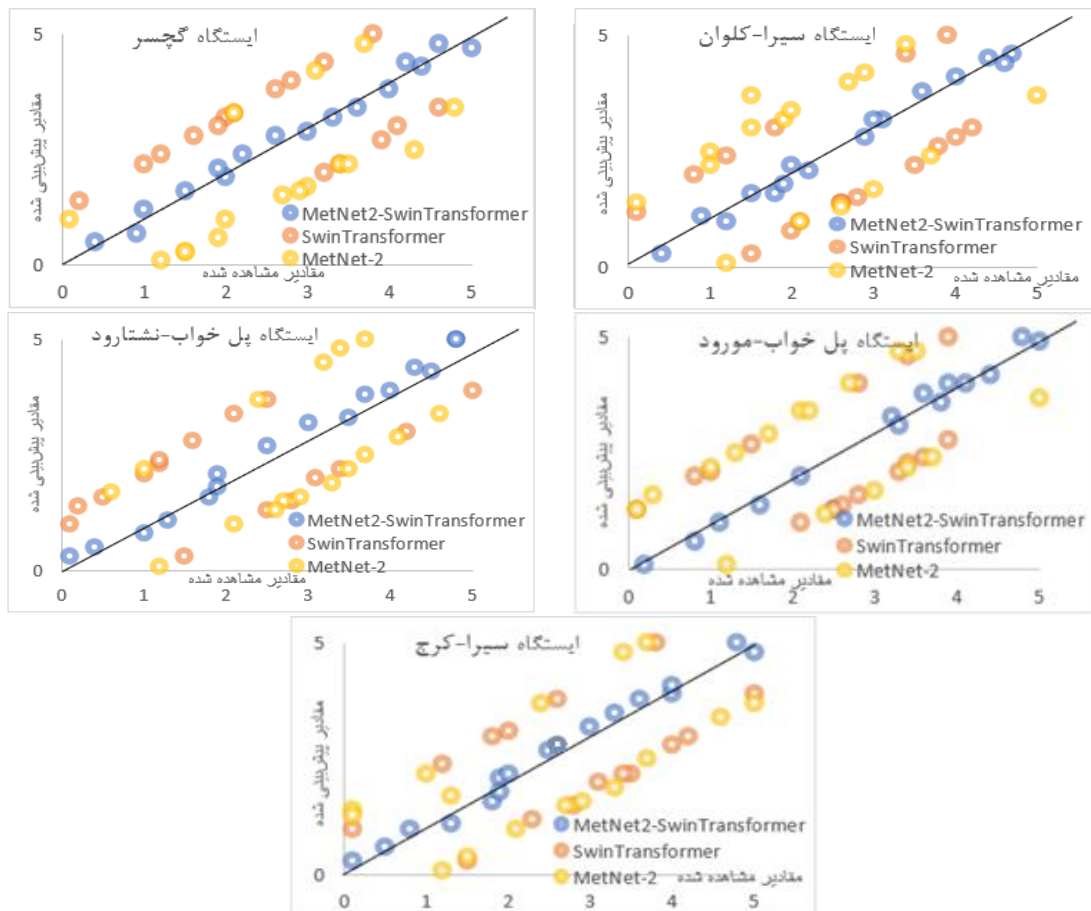
با توجه به نتایج جدول (۳)، مدل MetNet-2 با وجود مزایایی مانند ساختار رمزگزار- رمزگشا و توانایی ویژه در پردازش ویژگی‌های پیچیده با استفاده از پردازش متمرکز در این مطالعه ضعیف‌ترین عملکرد را در میان سه مدل مورد مطالعه داشته است. مقدار NS بین ۰/۴۹۸ تا ۰/۵۱۲ و همبستگی ۰/۴۷۳ تا ۰/۴۹۸ نشان می‌دهد که این مدل به‌منظور شناسایی پویایی‌های سری زمانی رواناب در ایستگاه‌های مورد بررسی ناموفق عمل کرده است. مقادیر MAE بین ۵/۹۳۱ تا ۷/۵۷۱ در سه ایستگاه گچسر، سیرا- کلوان و سیرا- کرج نیز بیان‌گر چالش این مدل در مواجهه با نوسانات شدید، رخدادهای حدی و رفتارهای نوسانی است. با این حال در دو ایستگاه دیگر مقادیر خطا به محدوده ۰/۲۰۶ تا ۰/۲۱۴ کاهش یافته که نشان می‌دهد MetNet-2 در شرایطی که داده‌ها نظم بیشتری دارند و دبی بیشینه کمتری ثبت شده است، قادر به ارائه برآوردهای دقیق‌تری است. بررسی الگوی خطا در سه ایستگاهی که بالاترین RMSE ثبت شده نشان می‌دهد که این ایستگاه‌ها دارای بیشترین حجم داده و متنوع‌ترین رفتار هیدرولوژیک بوده‌اند. در سری‌های زمانی بلندمدت، فراوانی رخدادهای سیلابی، دوره‌های خشکسالی، تغییرات کاربری اراضی و مداخلات انسانی باعث ایجاد نوسانات شدید در رواناب می‌شود؛ امری که موجب افزایش حساسیت مدل‌ها نسبت به داده‌های پرت و تغییرات ناگهانی می‌گردد.

برتری مدل هیبریدی SwinTransformer-MetNet2 در این ایستگاه‌ها به‌خوبی نشان می‌دهد که ترکیب دو مدل، توانایی مدل در هم‌زمان سازی الگوهای کوتاه‌مدت و بلندمدت را افزایش داده و شناسایی تغییرات غیرخطی را بهبود بخشیده است. در مجموع، نتایج پژوهش حاضر تأکید می‌کند که مدل هیبریدی SwinTransformer-MetNet2 به دلیل ماهیت ترکیبی و ساختار بهینه‌شده، مناسب‌ترین گزینه برای مدل‌سازی رواناب در حوزه آبخیز کرج است. دو مدل انفرادی در پیش‌بینی رواناب عملکردی ضعیف را به ثبت رساندند اما ترکیب این دو مدل انفرادی، باعث رفع خطاهای هر دو مدل، برطرف شدن عیوب و افزایش دقت پیش‌بینی‌ها شد. عملکرد ممتاز مدل هیبریدی به‌ویژه در ایستگاه‌هایی با رفتار پیچیده و متلاطم، نشان می‌دهد که بهره‌گیری از مدل‌های ترکیبی در مطالعات هیدرولوژیک می‌تواند رویکردی پیشرو در افزایش دقت و پایداری پیش‌بینی به‌شمار رود. این یافته‌ها می‌تواند مبنای مناسبی برای توسعه سیستم‌های هشدار سیلاب، مدیریت ریسک و برنامه‌ریزی علمی منابع آب در حوضه‌های مشابه باشد.

با مقایسه نتایج به‌دست آمده با مدل‌های مبتنی بر ترنسفورمرهای ساده مانند مطالعه Lim et al. (۲۰۲۱)، مشاهده می‌شود که اگرچه مدل‌های ترنسفورمر در پیش‌بینی سری‌های زمانی هواشناسی موفق هستند اما به دلیل فقدان ساختار سلسله‌مراتبی مکانی، در تحلیل اثرات محلی مانند تاثیر توپوگرافی و پوشش زمین بر جریان سیلاب، ضعیف عمل می‌کنند. مدل پیشنهادی پژوهش حاضر با بهره‌گیری از معماری Swin Transformer و مکانیزم پنجره‌های لغزان، توانسته اثرات مکانی کوچک‌مقیاس را با دقت بالا استخراج کند و آن‌ها را با داده‌های زمانی MetNet-2 ادغام نماید. این امر باعث می‌شود که مدل هیبریدی ارائه شده برخلاف مدل‌های ذکر شده در مطالعه Shen et al. (۲۰۱۸)، از پدیده صاف‌شدگی پیک‌ها جلوگیری کرده و توانایی فوق‌العاده‌ای در بازسازی دقیق منحنی هیدروگراف سیلاب داشته باشد.

ارزیابی نمودارهای پراکنش در شکل (۳) برای دو مدل انفرادی MetNet-2، Swin Transformer و مدل هیبریدی پیشنهادی MetNet-2-SwinTransformer در شکل (۳)، تفاوت‌های بنیادین در توانایی بازسازی الگوهای پیچیده رواناب را آشکار می‌سازد. مدل هیبریدی با ثبت بالاترین ضریب همبستگی ۰/۹۳ تا ۰/۹۵ و تراکم بسیار بالای نقاط در امتداد خط نیمساز، برتری خود را در استخراج ویژگی‌های غیرخطی و مدیریت نوسانات شدید رواناب اثبات کرد. فشرده بودن توزیع نقاط حول خط نیمساز در این مدل، نه تنها نشان‌دهنده دقت بالا در دوره‌های پایدار است، بلکه گویای توانایی مدل در بازسازی صحیح پیک‌های جریان در دوره‌های با تغییرپذیری بالا می‌باشد. این انطباق بالا، نشان‌دهنده همخوانی استراتژیک معماری هیبریدی با ماهیت غیرخطی و احتمالی داده‌های هیدرولوژیک حوزه آبخیز کرج است. در مقابل، عملکرد مدل‌های پایه نشان‌دهنده محدودیت‌های ساختاری آن‌هاست. مدل MetNet-2 با همبستگی پایین ۰/۴۷ تا ۰/۴۹ و پراکندگی قابل توجه نقاط در فواصل دور از خط ایده‌آل، در بازتولید ساختار داده‌های پیچیده با شکست مواجه شد. این عدم دقت، به‌ویژه در محدوده دبی‌های متوسط و بالا، با مقادیر بالاتر RMSE همخوانی دارد و نشان می‌دهد که این مدل در مواجهه با سری‌های زمانی با پیچیدگی‌های فصلی، فاقد قدرت یادگیری لازم برای پوشش تمام ابعاد داده است. مدل Swin Transformer نیز با کم‌ترین میزان همبستگی ۰/۴۲ تا ۰/۴۵ و گسترده‌ترین پراکندگی، ضعیف‌ترین عملکرد را در بازسازی روند ماهانه رواناب داشت. اگرچه این مدل در تخمین مقادیر دبی پایین عملکرد نسبتاً پایداری نشان داد اما عدم توانایی در مدیریت نوسان و روابط پیچیده بارش- رواناب باعث شد

تا در مقادیر جریان بالا، دچار خطاهای سیستماتیک شود. برتری چشم‌گیر مدل هیبریدی ناشی از اثر هم‌افزایی میان دو معماری است؛ به گونه‌ای که قدرت MetNet-2 در پردازش ویژگی‌های متمرکز و زمانی، با توانایی Swin Transformer در استخراج روابط مکانی- غیرخطی عمیق ترکیب شده است. این ترکیب، منجر به ایجاد یک نگاهت دقیق از ورودی‌ها به خروجی شده که در ایستگاه‌های با دبی بیشینه بالا که دارای پیچیدگی‌های توپوگرافیک و هیدرولوژیک بیشتری هستند نیز به خوبی عمل می‌کند. در واقع، مدل هیبریدی توانسته است الگوهای حدی را که در مدل‌های انفرادی به دلیل نویز یا عدم حساسیت از دست می‌رفتند با دقت بالا بازسازی کند. در نهایت، انطباق کامل میان تحلیل‌های بصری نمودارهای پراکنش و شاخص‌های آماری مورد استفاده در پژوهش حاضر، اعتبار علمی و پایداری نتایج حاصل از مدل پیشنهادی را تأیید می‌کند (شکل ۳).



شکل (۳): نمودار مقایسه همبستگی مدل‌ها

#### ۴- نتیجه‌گیری

این پژوهش با هدف توسعه یک مدل پیشرفته برای پیش‌بینی ماهانه جریان‌های سیلابی در حوزه آبخیز پیچیده کرج، به بررسی و مقایسه عملکرد سه معماری مختلف یادگیری عمیق پرداخت. در این راستا، مدل هیبریدی پیشنهادی با تلفیق ویژگی‌های زمانی متمرکز مدل MetNet-2 و توانایی استخراج ویژگی‌های سلسله‌مراتبی و مکانی مدل Swin Transformer، به‌طور موفقیت‌آمیزی توانست چالش‌های ذاتی مدل‌سازی هیدرولوژیک در مناطق با تغییرپذیری شدید را مرتفع سازد. نتایج حاصل از ارزیابی آماری نشان داد که مدل هیبریدی با ثبت بالاترین مقادیر شاخص‌های دقت، از جمله NS فراتر از ۰/۹۵ و ضریب همبستگی بیش از ۰/۹۵، برتری مطلق خود را نسبت به مدل‌های انفرادی MetNet-2 و SwinTransformer به اثبات رساند. در حالی که مدل‌های پایه در بازسازی رخداد‌های حدی و مدیریت نوسانات شدید جریان با چالش‌های جدی روبرو بودند و خطاهای بالایی در ایستگاه‌های با دبی بیشینه بالا نشان دادند، مدل هیبریدی با دقت بسیار بالا، الگوهای پیچیده هیدروگراف را بازسازی نمود. این برتری به دلیل ایجاد یک اثر هم‌افزایی است که منجر به جبران خطاهای متقابل مدل‌ها شده و توانایی مدل را در هم‌زمان‌سازی الگوهای کوتاه‌مدت جوی با پاسخ‌های مکانی-توپوگرافیک حوضه افزایش داده است. یکی از یافته‌های کلیدی این مطالعه، توانایی مدل پیشنهادی در غلبه بر پدیده صاف‌شدگی پیک‌ها بود؛ برخلاف مدل‌های مبتنی بر ترنسفورم ساده که در بازسازی مقادیر حداکثری جریان دچار خطا می‌شوند، معماری پنجره‌های لغزان در مدل هیبریدی، اجازه داد تا اثرات محلی و مقیاس‌های کوچک مکانی که در جریان‌های سیلابی نقش حیاتی دارند، به‌دقت استخراج شوند. این ویژگی، مدل را به ابزاری بسیار حساس و در عین حال پایدار در مواجهه با داده‌های پرت و رفتارهای غیرخطی تبدیل کرده است. از منظر کاربردی، نتایج این پژوهش

نشان می دهد که مدل MetNet-2-SwinTransformer می تواند به عنوان یک ابزار پیشرو در سیستم های هشدار زود هنگام سیلاب و مدیریت ریسک منابع آب در حوضه های آبخیز با توپوگرافی پیچیده مورد استفاده قرار گیرد. مدل پیشنهادی نه تنها دقت پیش بینی را افزایش می دهد، بلکه پایداری مدل سازی را در دوره های تغییر پذیری شدید اقلیمی تضمین می کند. با این حال، پژوهش های آتی پیشنهاد می گردد بر ادغام داده های ماهواره ای با تفکیک پذیری بالاتر و یا ترکیب معماری هیبریدی ارائه شده در پژوهش حاضر با مدل های فیزیکی - آموزشی تمرکز گردد تا دقت مدل در پیش بینی رخداد های حدی و ناگهانی، بیش از پیش ارتقاء یابد.

## منابع

- آذری، ح.، متکان، ع. ا.، شکیب، ع.، و پورعلی، س. ح. (۱۳۸۸). شبیه سازی و هشدار سیل با تلفیق مدل های آشناس در GIS و برآورد بارش از طریق سنجش از دور. زمین شناسی ایران، ۳۹(۳)، ۵۱-۳۹.
- بشیرگنبد، م. (۱۴۰۱). مدل سازی بارش-رواناب به منظور پیش بینی حداکثر جریان روزانه در شرایط تغییر اقلیم. مدیریت حوزه آبخیز، ۱۳(۲۶)، ۱۱۵-۱۲۴.
- شیرازی، ف.، ظهیری، ع.، پیر، ج.، و دهقانی، ع. ا. (۱۴۰۲). توسعه روشی نوین هیدرولیکی برای پیش بینی دبی سیلاب رودخانه. پژوهش های مدیریت حوضه آبخیز، ۱۴(۲۸)، ۱۱۰-۱۲۳.
- نصیری، ع.، سلیمی، ا.، دلفان آذری، م.، یزدی، ج.، و شاهسوندی، م. (۱۴۰۳). پهنه بندی سیلاب شهری با رویکرد مدل سازی توامان هیدرولوژیکی-هیدرولیکی حوضه آبریز، مطالعه موردی: منطقه ۲۱ و ۲۲ شهر تهران. دانش پیشگیری و مدیریت بحران، ۱۴(۴)، ۳۹۲-۴۰۵.
- Ahmadi, R., and Kasaei, S. (2024). Leveraging swin transformer for local-to-global weakly supervised semantic segmentation. In 2024 13th Iranian/3rd International Machine Vision and Image Processing Conference (MVIP) (pp. 1-7). IEEE.
- An, C., Xie, Z., Li, X., Li, L., Zhang, J., Gong, S., ... and Kong, L. (2025). Polaris: A post-training recipe for scaling reinforcement learning on advanced reasoning models, 2025. <https://hkunlp.github.io/blog/2025/Polaris>.
- Espoholt, L., Agrawal, S., Sønderby, C., Kumar, M., Heek, J., Bromberg, C., ... and Kalchbrenner, N. (2022). Deep learning for twelve hour precipitation forecasts. Nature communications, 13(1), 5145.
- Lim, B., Arık, S.Ö., Loeff, N., and Pfister, T. (2021). Temporal fusion transformers for interpretable multi-horizon time series forecasting. International Journal of Forecasting, 37(4), 1748-1764.
- Lin, K., Wang, L., and Liu, Z. (2021). End-to-end human pose and mesh reconstruction with transformers. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 1954-1963).
- Liu, W., and Zhang, A. (2025). Plant Disease Detection Algorithm Based on Efficient Swin Transformer. Computers, Materials & Continua, 82(2), 3045-3068.
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., and Guo, B. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. In Proceedings of the IEEE/CVF International Conference on Computer Vision (pp. 10012-10022).
- Obada, E., Biao, E.I., Zohou, P.J., Yarou, H., Hounnonnaho, F.Z., and Alamou, E.A. (2025). Using machine learning and satellite data to improve flood forecasting: the case of the Ouémé basin at the Bétérou outlet. Hydrology Research, 56(2), 153-166.
- Shen, C. (2018). A transdisciplinary review of deep learning research and its relevance for water resources scientists. Water Resources Research, 54(11), 8558-8593.
- Sønderby, C.K., Espoholt, L., Heek, J., Dehghani, M., Oliver, A., Salimans, T., ... and Kalchbrenner, N. (2020). Metnet: A neural weather model for precipitation forecasting. arXiv:2003.12140.
- Zhang, H., Liu, Y., Zhang, C., and Li, N. (2025). Machine learning methods for weather forecasting: A survey. Atmosphere, 16(1), 82.

## Investigating of the MetNet2-SwinTransformer Intelligent Hybrid Model for Flood Peak Discharge Modeling (Case Study: Karaj Watershed)

Ramtin Tavoosi Rad<sup>1</sup>, Mohammad Ansari ghojghar<sup>2\*</sup>, Hassan Khosravi<sup>3</sup>



### Research Article

1. Master's student in watershed management sciences, Department of Reclamation of Arid and Mountainous Regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran.

[ramtintavosirad@ut.ac.ir](mailto:ramtintavosirad@ut.ac.ir)

2. Assistant Professor, Department of Reclamation of Arid and Mountainous Regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran.

[ansari.ghojghar@ut.ac.ir](mailto:ansari.ghojghar@ut.ac.ir)

\* Corresponding author

3. Professor, Department of Reclamation of Arid and Mountainous Regions, Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran.

[hakhosravi@ut.ac.ir](mailto:hakhosravi@ut.ac.ir)

**Article Code:** 2605-1168  
**Continous Pagination:** 1316-1326

**Received:** 11 May 2026  
**Accepted:** 23 June 2026  
**Online:** 06 July 2026  
**Review speed:** 44 days

### Citation:

Tavoosi Rad, R., Ansari ghojghar, M., and Khosravi, H. (2026). Investigating of the MetNet2-SwinTransformer Intelligent Hybrid Model for Flood Peak Discharge Modeling (Case Study: Karaj Watershed). *Management of Natural Ecosystems*, 6(1), 57-67.

### Abstract

Predicting flood discharge plays a pivotal role in water resource management, particularly within highly complex hydrological basins. Hydrological models frequently encounter significant challenges in replicating the non-linear interactions between atmospheric forcing and complex topographic responses. This study proposes a novel hybrid deep learning architecture, MetNet-2-SwinTransformer, designed to integrate the temporal feature extraction capabilities of MetNet-2 with the multi-scale spatial hierarchical modeling of the Swin Transformer. The model's performance was evaluated using discharge data from the Karaj watershed to assess its performance in capturing complex flow dynamics and extreme hydrological events. The performance of the proposed hybrid model was rigorously compared against individual MetNet-2 and Swin Transformer architectures using multiple statistical metrics, including Nash-Sutcliffe Efficiency (NSE), Coefficient of Determination (R), Root Mean Square Error (RMSE), and Mean Absolute Error (MAE). The results indicate that the hybrid model exhibits absolute superiority over the baseline models, attaining exceptional predictive accuracy with NSE and RRR values surpassing 0.95. While individual models exhibited significant limitations in reconstructing peak flows and managing high-magnitude fluctuations particularly in stations with extreme discharge variability the hybrid model effectively mitigated these errors through a synergistic integration of temporal and spatial features. The hybrid model was able to overcome the peak smoothing phenomenon common in standard transformer models and reconstruct flood hydrograph curves with very high accuracy. The findings indicate that the integration of sliding-window mechanisms with temporal forecasting enables the model to capture small-scale spatial effects and complex topographic influences with high precision, yielding correlations and NSE values exceeding 0.95, while reducing error magnitudes to below 0.1 at stations with lower peak discharges. Although the error amount was higher at other stations than at 3 stations, this is acceptable due to the nature of hydrological data. This research confirms that the proposed hybrid approach offers a robust and highly accurate framework for flood forecasting in complex basins, providing a reliable foundation for developing advanced early warning systems and enhancing water resource decision-making processes.

### Key Words:

Flood Forecasting, Hybrid Deep Learning, Transformer, Hydrograph Reconstruction.