

Comparison of Soft Computing-Based Artificial Intelligence Algorithms with the Transformer-Based TFT Model for Flood Modeling

Ramtin Tavooosi Rad¹, Mohammad Ansari ghojghar^{2*}, Arash Malekian²

¹Master Candidate, Department of Reclamation of Arid and Mountainous Regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran.

²Professor, Dry and Mountainous Areas Restoration Engineering Group, Faculty of Natural Resources, University of Tehran, Karaj, Iran.

Article Info	ABSTRACT
Article type: Research Article	Objective: Accurate modeling of runoff processes and prediction of daily peak discharge are major challenges in flood management, water resource allocation, and the design of protective hydraulic structures due to the nonlinear and complex behavior of hydrological systems. This study aimed to evaluate the performance of three advanced data-driven models—Temporal Fusion Transformer (TFT), Gene Expression Programming (GEP), and Adaptive Neuro-Fuzzy Inference System (ANFIS)—for predicting daily peak discharge in the Taleghan Watershed.
Article history: Received 02 April 2026 Revised 30 April 2026 Accepted 30 April 2026 Published online 23 September 2026	Methods: Daily peak discharge data from five hydrometric stations over a 30-year period (1992–2021) were collected, preprocessed, normalized, and provided to the models under four temporal input scenarios, including the previous 3, 6, 9, and 12 months. All models were implemented in the R environment. Model performance was evaluated using four statistical indicators: Nash–Sutcliffe Efficiency (NSE), Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and correlation coefficient (R).
Keywords: GEP ANFIS Data Driven models Flood management	Results: The results showed that the TFT model achieved the highest accuracy among all evaluated models by a considerable margin. The NSE values at most stations exceeded 0.97, while RMSE values were below 0.10. This model accurately reconstructed long-term dependencies, seasonal fluctuations, and complex discharge patterns. The GEP model ranked second, with moderate performance and NSE values ranging from 0.66 to 0.68. In contrast, ANFIS produced the weakest results, with NSE values ranging from 0.60 to 0.63. The superior performance of TFT demonstrates the strong capability of attention-based architectures in extracting long-term temporal dependencies and seasonal flow patterns.
	Conclusions: The results indicate that TFT is the most accurate and reliable model for predicting daily peak discharge in the Taleghan Watershed. However, dependence on large datasets, high computational cost, and the risk of overfitting due to improper hyperparameter tuning are among the limitations of this model. From a practical perspective, TFT can serve as an effective tool in flood early warning systems, reservoir operation management, and the design of flood control structures.

*Corresponding author, Email: ansari.ghojghar@ut.ac.ir

Cite this article: Last Name, Initial., Last Name, Initial., & Last Name, Initial. (2026). Title of paper in lower case letters (except for initial letter of first word, initial of first word after a colon, and proper nouns). *Journal of New Approaches in Water Engineering and Environment*, 5(3), 73-93.
<https://doi.org/10.22034/nawee.2026.564165.1183>



© The Author(s).

Publisher: Gonbad Kavous University.

DOI: <https://doi.org/10.22034/nawee.2026.564165.1183>

Introduction

Precipitation–runoff processes are among the most complex hydrological processes, influenced by various physical and hydrological parameters. Modeling precipitation–runoff processes and predicting river discharge are essential for flood management and control, the design of hydraulic structures in watersheds, and drought management. This study aimed to address the existing research gap by evaluating the accuracy of three algorithms: Temporal Fusion Transformer (TFT), as a representative of the new generation of Transformer-based deep learning models; Gene Expression Programming (GEP), as a symbolic evolutionary algorithm; and Adaptive Neuro-Fuzzy Inference System (ANFIS), as a soft computing model, for predicting daily peak discharge in the Taleghan watershed. In recent years, artificial intelligence-based simulation methods, particularly neural network models, have gained increasing attention in the prediction of water resource parameters.

Methods

Daily peak discharge data from five hydrometric stations over a 30-year period (1992–2021) were collected, refined, normalized, and transformed into four temporal input scenarios based on the previous 3, 6, 9, and 12 months. All models were implemented and trained in the R environment. Model performance was evaluated using four statistical indicators: Nash–Sutcliffe Efficiency (NSE), Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and correlation coefficient (R).

Results

The results indicated that the TFT model significantly outperformed the other models across all stations and input scenarios. NSE values ranged from 0.97 to 0.99, RMSE values were below 0.10, and R values were close to 1, demonstrating the high capability of TFT in accurately reconstructing discharge behavior.

The GEP model showed moderate performance, performing more consistently than ANFIS and demonstrating relative superiority in some long-term prediction horizons. ANFIS showed the weakest overall performance.

Comparison of TFT with the structurally simpler GEP and ANFIS models indicated that the superior performance of TFT was not due to overfitting, but rather to its strong capability in extracting complex temporal patterns and long-term dependencies in discharge data. Furthermore, the variable selection mechanisms, gating networks, and attention mechanisms embedded in the TFT architecture played an important role in reducing input noise and improving generalization.

The superiority of TFT remained stable across all temporal scenarios and seasons. Even when longer input periods (9- or 12-month historical data) were used, the model maintained very high predictive accuracy. This indicates that TFT does not suffer from performance degradation as input sequence length increases. Instead, due to its memory-based architecture and ability to learn complex nonlinear relationships, it can better capture long-term trends and temporal continuity than the other models. This strong performance was observed consistently across all studied stations, with TFT clearly ranked as the best-performing model for daily peak discharge prediction.

Conclusions

TFT was identified as the most accurate and reliable model for predicting daily peak discharge in the Taleghan watershed and is strongly recommended for flood-related analyses on long-term time scales. Although GEP demonstrated acceptable performance, it could not compete with attention-based deep learning architectures. ANFIS, despite its capability in modeling nonlinear relationships, showed high sensitivity to temporal fluctuations in this study.

Given the high predictive accuracy of TFT, the findings suggest that this model can be effectively applied in practical flood management. Key applications include flood early warning systems, where accurate prediction of peak discharge can significantly reduce human and economic losses. In addition, TFT outputs can serve as reliable inputs for the design and evaluation of flood control structures such as dams, diversion structures, and river protection systems.

Due to the stable performance of TFT across different temporal horizons, this model can also be considered an efficient tool for long-term water resource planning and flood risk management in mountainous watersheds. The results demonstrate that next-generation deep learning models such as TFT can substantially improve forecasting quality in analyses involving long-term time series and complex hydrological variability.

Future research is recommended to focus on developing hybrid models, incorporating multisource data such as radar-based precipitation and remote sensing datasets, and evaluating the performance of TFT in forecasting extreme hydrological events such as flash floods.



مقایسه الگوریتم‌های هوش مصنوعی مبتنی بر محاسبات نرم با مدل مبتنی بر ترنسفورمر TFT به منظور مدل‌سازی سیلاب

رامتین طاوسی راد^۱، محمد انصاری قوجقار^{۱*}، آرش ملکیان^۱

^۱گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	مدل‌سازی دقیق فرآیند رواناب و پیش‌بینی دبی بیشینه روزانه به‌دلیل رفتار غیرخطی و پیچیده سامانه‌های هیدرولوژیکی از چالش‌های اساسی در مدیریت سیلاب، تخصیص منابع آب و طراحی سازه‌های حفاظتی است. در پژوهش حاضر به‌منظور ارزیابی کارایی مدل‌های نوین داده‌محور، عملکرد سه الگوریتم TFT، GEP و ANFIS در پیش‌بینی دبی بیشینه روزانه حوزه آبخیز طالقان بررسی شد. داده‌های دبی مربوط به پنج ایستگاه هیدرومتری طی دوره ۳۰ ساله (۱۳۷۱-۱۴۰۰) جمع‌آوری و پس از پیش‌پردازش در قالب چهار سناریوی زمانی ورودی شامل ۳، ۶، ۹ و ۱۲ ماه پیشین به مدل‌ها ارائه شد. برای ارزیابی عملکرد مدل‌ها از شاخص‌های RMSE، MAE، NSE و R استفاده شد. نتایج نشان داد که مدل TFT با اختلاف چشمگیر دقیق‌ترین عملکرد را در میان مدل‌های مورد بررسی به‌ثبت رسانده است. مقدار NSE در اغلب ایستگاه‌ها بیش از ۰/۹۷ و RMSE کمتر از ۰/۱۰ بوده است. این مدل وابستگی‌های بلندمدت، نوسانات فصلی و الگوهای پیچیده جریان را با دقت بالا بازسازی نمود. مدل GEP با عملکرد متوسط و مقدار NSE در محدوده ۰/۶۶ تا ۰/۶۸ در رتبه دوم قرار گرفت در حالی که ANFIS ضعیف‌ترین نتایج را با NSE حدود ۰/۶۰ تا ۰/۶۳ ثبت کرد. دقت بالای مدل TFT بیان‌گر توانایی معماری مبتنی بر توجه در استخراج وابستگی‌های زمانی بلندمدت و الگوهای فصلی جریان است. با این حال، وابستگی مدل TFT به حجم داده‌های طولانی، هزینه محاسباتی بالا و احتمال بیش‌برازش در صورت عدم تنظیم مناسب فرآپارامترها از جمله محدودیت‌های این پژوهش به‌شمار می‌رود. از منظر کاربردی، نتایج نشان می‌دهد که از مدل TFT می‌توان به‌عنوان ابزاری کارآمد در سامانه‌های هشدار سریع سیلاب، مدیریت بهره‌برداری مخازن و طراحی سازه‌های کنترلی سیلاب بهره برد.
تاریخ دریافت: ۱۴۰۵/۰۱/۱۳	
تاریخ بازنگری: ۱۴۰۵/۰۲/۱۰	
تاریخ پذیرش: ۱۴۰۵/۰۲/۱۰	
تاریخ انتشار: ۱۴۰۵/۰۷/۰۱	
کلیدواژه‌ها: برنامه‌ریزی بیان ژن سیستم استنتاج عصبی فازی سازگار مدل‌های داده محور مدیریت سیلاب	

*نویسنده مسئول، Email: ansari.ghojghar@ut.ac.ir

استناد: نام خانوادگی، نام؛ نام خانوادگی، نام؛ نام خانوادگی، نام (۱۴۰۵). عنوان مقاله. رویکردهای نوین در مهندسی آب و محیط زیست، ۵ (۳)، ۹۳-

<https://doi.org/10.22034/nawee.2026.564165.1183> ۷۳

© نویسندگان.

ناشر: دانشگاه گنبد کاووس.



مقدمه

فرآیندهای بارش-رواناب از پیچیده‌ترین فرآیندهای هیدرولوژیکی هستند که تحت‌تأثیر پارامترهای مختلف فیزیکی و هیدرولوژیکی قرار دارند. مدل‌سازی فرآیند بارش-رواناب و پیش‌بینی دبی رودخانه یک اقدام مهم در مدیریت و مهار سیلاب، طراحی سازه‌های آبی در حوزه‌های آبخیز و مدیریت خشکسالی است (Dehghani et al, 2017). مدل‌سازی‌ها برپایه دانش تجربی و یا با توجه به داده‌های موجود انجام می‌گیرند. پایه و اساس روش‌های داده‌محور برای مدل‌سازی فرآیندهای هیدرولوژیکی، استفاده و استخراج اطلاعاتی است که درون داده‌های هیدرولوژیکی وجود دارند بدون اینکه هیچ اطلاعات دقیقی از خصوصیات و قوانین فیزیکی حاکم وجود داشته باشد. توسعه و کاربرد روش‌های داده‌محور^۱ در مدل‌سازی رواناب در چند دهه اخیر گسترش فزاینده‌ای داشته است. اگرچه مدل‌سازی با روش‌های داده‌محور ممکن است توانایی کافی برای تفسیر فرآیندهای فیزیکی درون حوضه را نداشته باشند اما بطور صحیح و دقیقی می‌توانند رواناب خروجی حوضه را تخمین بزنند (Pornemat Roudsari et al, 2015).

با گسترش روز افزون کاربردهای مبتنی بر هوش مصنوعی در دو دهه‌ی اخیر، استفاده از شبیه‌سازی‌های متکی بر شبکه‌های عصبی مصنوعی در مباحث مربوط به پیش‌بینی فراسنج‌های مختلف منابع آب مورد استفاده قرار گرفته و محققان با دقت زیادی بر این روش تأکید نموده‌اند (Ahmadian AhmadAbad & Zakeri Niri, 2022). طی چند دهه اخیر روش‌های داده‌محور و یادگیری ماشین (ML) به‌عنوان جایگزینی یا مکملی برای مباحث هیدرولوژی مطرح شده‌اند (Gauch & Lin, 2020). برای مثال Amiri et al (2025) در پژوهشی به شناسایی مناطق حساس به سیل بوسیله مدل جنگل تصادفی (RF)^۲ پرداختند. نتایج این پژوهش دقت بسیار خوب این مدل را در تولید (ROC)^۴ نشان داد. همچنین در پژوهشی دیگر، Mohammadrezapour et al, (2025) به پیش‌بینی پارامترهای مربوط به کیفیت آب با استفاده از روش سطح پاسخ (RSM)^۵، درخت تصمیم و شبکه‌های عصبی مصنوعی (ANN)^۶ پرداختند. نتایج این پژوهش نشان داد مدل درخت تصمیم بالاترین دقت را در پیش‌بینی املاح آب داشت و پس از آن مدل‌های RSM و ANN قرار گرفتند. همچنین Shakeri Yousefi et al, (2025) با استفاده از سه مدل یادگیری ماشین رگرسیون بردار پشتیبان (SVR)^۷، برنامه‌نویسی بیان ژن (GEP)^۸ و شبکه عصبی مصنوعی (ANN)، کارایی اتلاف انرژی سازه‌های گابیونی قرار گرفته در پایین‌دست سرریزها را ارزیابی کردند. در این مطالعه مدل GEP دقیق‌ترین مدل شناخته شد و پس از آن مدل ANN با اختلاف کمی در رده بعدی قرار گرفت اما مدل SVR خروجی قابل قبولی را ارائه نداد. در میان مدل‌های داده‌محور، محاسبات نرم مانند سیستم استنتاج فازی عصبی تطبیقی (ANFIS)^۹ و الگوریتم‌های تکاملی نمادین مانند GEP به‌طور گسترده در مطالعات هیدرولوژیکی به‌کار گرفته شده‌اند. ANFIS با ترکیب منطق فازی و شبکه‌های عصبی، رابطه‌های غیرخطی ورودی خروجی را به‌خوبی مدل می‌کند و در مطالعات داخلی نیز برای پیش‌بینی رواناب، رسوب و متغیرهای مرتبط نتایج قابل‌قبولی گزارش شده است (Mastouri et al, 2022). با این وجود، عملکرد ANFIS به‌شدت به ساختار اولیه، تعداد توابع عضویت و نحوه تنظیم فراپارامترها وابسته است و افزایش پیچیدگی مسأله منجر به افزایش هزینه محاسباتی و کاهش پایداری مدل می‌شود. از طرفی، مدل GEP به‌دلیل قابلیت بیان نمادین روابط و توانایی تولید فرمول‌های تحلیلی از داده‌ها در مسائل پیش‌بینی جریان، تبخیر، تعرق و بارش کاربرد یافته و در مطالعات بین‌المللی موفقیت‌هایی نشان داده است (Terzi & Özcanoglu, 2017). با این حال، ساختار تکاملی GEP معمولاً نسبت به نویز داده‌ها حساس بوده و در مسائل سری‌زمانی با وابستگی‌های بلندمدت، فاقد سازوکار صریح برای یادگیری دینامیک‌های زمانی پیچیده است.

^۱ Data-Driven

^۲ Machine Learning

^۳ Random Forest

^۴ Receiver Operating Characteristic

^۵ Response Surface Methodology

^۶ Artificial Neural Networks

^۷ Support vector regression

^۸ Gene Expression Programming

^۹ Adaptive Neuro-Fuzzy Inference System

اخیراً معماری‌های مبتنی بر ترنسفورمر^۱ که سازوکار توجه^۲ را برای یادگیری وابستگی‌های بلندبرد زمانی به کار می‌گیرند و گونه‌ای از مدل‌های (TFT)^۳ که المان‌های بازگشتی و انتخاب متغیر را نیز ترکیب می‌کند، توجه پژوهشگران هیدرولوژی را به خود جلب کرده‌اند. مطالعات محدودی در زمینه بهره‌گیری از مدل‌های ترنسفورمر در مطالعات هیدرولوژی به انجام رسیده‌اند. نتایج این مطالعات نشان داده‌اند که TFT و متدهای مبتنی بر آن در پیش‌بینی چندافقه سری‌زمانی از جمله دبی جریان و خروجی شبکه فاضلاب دقت و تفسیرپذیری مناسبی ارائه می‌دهند و می‌توانند در برخی مقایسه‌ها از (LSTM)^۴ و ترنسفورمر خالص پیشی بگیرند (Burrichter et al, 2024).

تاکنون مطالعه‌ای که به‌طور مستقیم به مقایسه مدل‌های ANFIS یا GEP با معماری‌های مبتنی بر ترنسفورمر پرداخته باشد، گزارش نشده است. در اغلب مطالعات پیشین، مدل ANFIS با مدل‌های کلاسیک‌تر یا روش‌های بهینه‌سازی ترکیب شده و مورد ارزیابی قرار گرفته است. برای مثال، (Vakili & Mousavi, 2022) از الگوریتم ژنتیک (GA)^۵ به‌عنوان یک ابزار بهینه‌سازی به منظور تنظیم پارامترها و قواعد مدل ANFIS در مدلسازی فرآیند بارش-رواناب استفاده کردند. نتایج این پژوهش نشان داد که به کارگیری GA در فرآیند بهینه‌سازی می‌تواند عملکرد پیش‌بینی ANFIS را بهبود بخشد. به گونه‌ای که دقت این مدل نسبت به حالت بدون بهینه‌سازی افزایش یافت. از طرف دیگر، مطالعات مربوط به TFT عمدتاً بر روی مقایسه با LSTM یا سایر RNN ها متمرکز بوده‌اند و همراه با مدل‌های محاسبات نرم بررسی نشده است. در همین راستا Rasia Koya & (2023) در پژوهشی به مقایسه TFT و LSTM به منظور پیش‌بینی دبی جریان پرداختند. در این پژوهش برای اولین بار از مدل‌های ترنسفورمر در مطالعات مربوط به هیدرولوژی استفاده شد. نتایج این پژوهش نشان داد که مدل TFT دقت بسیار زیاد و خطای کمی پیش‌بینی‌ها را به انجام رساند و از مدل TFT می‌توان برای مطالعات مربوط به مسائل هیدرولوژیک به خوبی بهره برد. پژوهش حاضر با هدف پرکردن خلاء مطالعاتی در زمینه مدلسازی بارش رواناب به مقایسه دو خانواده از مدل‌های نرم مانند ANFIS و GEP و مدل‌های نسل جدید ترنسفورمر TFT در یک مطالعه واحد برای حوزه آبخیز طالقان پرداخته است. این پژوهش بر این فرضیه استوار است که مدل TFT به دلیل بهره‌گیری از مکانیزم توجه، قابلیت یادگیری وابستگی‌های زمانی بلندمدت و ساختار انتخاب متغیر، قادر است با دقت بالاتر و خطای کمتر نسبت به مدل‌های GEP و ANFIS، رفتار دبی بیشینه روزانه را در افق‌های زمانی مختلف (۳، ۶، ۹ و ۱۲ ماهه) شبیه‌سازی و پیش‌بینی کند.

روش‌شناسی پژوهش

منطقه مورد مطالعه

شکل ۱ موقعیت جغرافیایی حوزه آبخیز طالقان و پراکنش ایستگاه‌های هیدرومتری مورد استفاده در پژوهش حاضر را نمایش می‌دهد. این حوزه در دامنه‌های جنوبی رشته‌کوه البرز و در بخش شمال‌غربی استان البرز واقع شده و به‌عنوان یکی از زیرحوضه‌های مهم در رژیم هیدرولوژیکی رودخانه سفیدرود شناخته می‌شود. محدوده مورد مطالعه بین عرض‌های جغرافیایی $36^{\circ}20'48''$ تا $36^{\circ}05'23''$ شمالی و طول‌های $50^{\circ}39'35''$ تا $51^{\circ}11'07''$ شرقی قرار گرفته و مساحتی در حدود 1243 کیلومتر مربع را شامل می‌شود. توپوگرافی کاملاً کوهستانی، شیب‌های تند، تنوع کاربری اراضی و دامنه وسیع ارتفاعی این حوزه سبب شده است تا نسبت به وقوع سیلاب‌های ناگهانی، بارش‌های شدید کوتاه‌مدت و رخداد‌های هیدرولوژیکی حدی اقلیمی حساسیت بالایی داشته باشد (Ebrahimi et al, 2020). در پژوهش حاضر به منظور ارزیابی عملکرد مدل‌های نوین داده‌محور در پیش‌بینی رواناب از مدل‌های TFT، GEP و ANFIS استفاده شد. داده‌های دبی بیشینه روزانه مربوط به پنج ایستگاه هیدرومتری فعال در محدوده حوزه طالقان طی دوره ۳۰ ساله (۱۳۷۱-۱۴۰۰) جمع‌آوری و پس از انجام فرآیندهای

¹ Transformer


² Attention-Mechanism

³ Temporal Fusion Transformer

⁴ Long short-term memory

⁵ Genetic algorithm

پیش‌پردازش، معیارسازی، حذف داده‌های پرت، بررسی ایستایی و تبدیل ورودی‌ها به‌عنوان ورودی مدل‌ها مورد استفاده قرار گرفت. تمامی مراحل مدل‌سازی، آموزش، تنظیم پارامترها و ارزیابی با استفاده از محیط‌های نرم‌افزاری R انجام شد. این رویکرد امکان مقایسه دقیق عملکرد مدل‌ها در شبیه‌سازی رواناب حوضه و شناسایی مناسب‌ترین مدل برای پیش‌بینی سیل را فراهم ساخت.



شکل ۱ - منطقه و ایستگاه‌های مورد مطالعه

در پژوهش حاضر از داده‌های پنج ایستگاه هیدرومتری استفاده گردید که جدول ۱ مشخصات ایستگاه‌ها را نشان می‌دهد.

جدول ۱- مشخصات ایستگاه‌های مورد مطالعه

شماره ردیف	کد ایستگاه	نام ایستگاه	ارتفاع از سطح دریا (متر)	طول جغرافیایی (درجه دقیقه ثانیه)	عرض جغرافیایی (درجه دقیقه ثانیه)	نام رودخانه	میانگین دبی بیشینه ماهانه (مترمکعب بر ثانیه)
۱	۱۷۰۵۰	گتته ده	۲۳۵۳	۵۱-۰۳-۵۵	۳۶-۱۰-۳۱	شاهرود	۱/۸۵۸
۲	۱۷۸۷۴	دهدر	۲۲۶۸	۵۰-۱۲-۱۹	۳۶-۱۰-۴۰	دهدر	۱/۵۸۶
۳	۱۷۹۶۵	مهران جویستان	۲۰۴۹	۵۰-۵۴-۳۷	۳۶-۱۰-۵۳	شاهرود	۲/۳۲۳
۴	۱۷۹۶۶	جویستان	۱۹۷۹	۵۰-۵۴-۲۸	۳۶-۱۰-۵۴	شاهرود	۷/۶۵۵
۵	۱۷۹۳۴	علیزان جویستان	۱۹۵۳	۵۰-۵۳-۲۹	۳۶-۱۱-۱۷	شاهرود	۱/۸۸۴

مدل (TFT)

TFT یک مدل یادگیری عمیق ویژه پیش‌بینی سری‌های زمانی است. این مدل با ترکیب LSTM برای استخراج الگوهای کوتاه‌مدت و مکانیزم توجه برای یادگیری وابستگی‌های بلندمدت، قادر است رفتارهای پیچیده زمانی را با تفسیرپذیری بالا مدل‌سازی کند. TFT از چهار بخش اصلی تشکیل شده است. لایه‌های انتخاب متغیر^۱، لایه‌های LSTM رمزگذار رمزگشا، ماژول Temporal Processing و مکانیزم دروازه‌ای^۲. خروجی نهایی مدل، پیش‌بینی احتمالاتی یا نقطه‌ای برای افق‌های زمانی آینده است. لذا قادر است الگوهای کوتاه‌مدت و بلندمدت در داده‌های پیچیده زمانی را به‌طور هم‌زمان استخراج کند. به‌واسطه بهره‌گیری از مکانیزم‌های توجه چندسری و دروازه‌ای، TFT توانایی بالایی در تمرکز پویا بر بخش‌های مهم تاریخچه سری زمانی

^۱ Variable Selection Networks

^۲ Gating Mechanism

و حذف اطلاعات غیرضروری دارد. خروجی نهایی مدل به صورت پیش‌بینی نقطه‌ای یا احتمالاتی برای افق‌های آینده ارائه می‌شود و امکان تحلیل اهمیت متغیرها و نقش هر زمان را در پیش‌بینی فراهم می‌سازد.

ماژول توجه زمانی، هسته اصلی یادگیری وابستگی‌های بلندمدت در TFT است. توجه چندسری با محاسبه ماتریس شباهت میان حالت فعلی و تاریخچه گذشته، وزن تمرکز مدل را تعیین می‌کند. رابطه اصلی این بخش به صورت رابطه ۱ بیان می‌شود:

$$Attention(Q, K, V) = softmax(\frac{QK^T}{\sqrt{d_{attn}}})V \quad (1)$$

که در آن Q ماتریس Query و بیان‌گر وضعیت لحظه پیش‌بینی است، K ماتریس Key شامل اطلاعات زمانی گذشته، V ماتریس ارزش شامل نمایش محتوایی داده‌ها، d_{attn} بُعد فضای ویژگی‌هاست که برای پایداری گرادین‌ها در مخرج قرار می‌گیرد. خروجی این رابطه، ترکیبی وزن‌دار از تاریخچه است که نشان می‌دهد مدل در هر گام زمانی باید بر کدام لحظات بیشتر تمرکز کند.

در لایه‌های انتخاب متغیر برای تعیین اهمیت هر متغیر در زمان t ، ابتدا تمامی متغیرهای سری زمانی گذشته در قالب یک بردار $\bar{E}_t$ تجمیع می‌شوند. این بردار به همراه بردار زمینه‌ای استخراج‌شده از متغیرهای ایستا c_s ، وارد یک شبکه (GRN)^۱ شده و خروجی آن پس از گذر از تابع $Softmax$ ، وزن نهایی انتخاب متغیرها را تولید می‌کند که در رابطه ۲ نشان داده شده است:

$$v_{x_t} = Softmax(GRN_{v_x}(\bar{E}_t, c_s)) \quad (2)$$

که در آن $v_t^x \in \mathbb{R}^{m_x}$ وزن اهمیت هر یک از متغیر m_x ، $\bar{E}_t$ بردار ورودی متغیرهای گذشته، c_s زمینه ایستا و GRN_{v_x} شبکه غیرخطی مولد وزن‌ها هستند. این مرحله تعیین می‌کند کدام متغیرها در لحظه بیش‌ترین نقش را در پیش‌بینی دارند. رابطه دقیق بین ورودی‌ها و اهداف اغلب از قبل ناشناخته است و این امر پیش‌بینی مرتبط بودن متغیرها را دشوار می‌سازد. علاوه بر این، تعیین میزان پردازش غیرخطی مورد نیاز دشوار است و ممکن است مواردی وجود داشته باشد که مدل‌های ساده‌تر مفید باشند. با انگیزه دادن این انعطاف‌پذیری به مدل که پردازش غیرخطی را فقط در صورت نیاز اعمال کند، شبکه باقی‌مانده دروازه‌دار به عنوان یک بلوک سازنده TFT پیشنهاد می‌شود. GRN یک ورودی اصلی a و یک بردار زمینه اختیاری c را دریافت می‌کند و نتیجه ۳، ۴ و ۵ را ارائه می‌دهد:

$$GRN_{\omega}(a, c) = LayerNorm(a + GLU_{\omega}(\eta_1)) \quad (3)$$

$$\eta_1 = W_q, \omega \eta_2 + b_1, \omega \quad (4)$$

$$\eta_2 = ELU(W_2, \omega a + W_3, \omega c + b_2, \omega) \quad (5)$$

که در آن ELU تابع فعال‌سازی واحد خطی نمایی است، η_1 و η_2 لایه‌های میانی هستند، $LayerNorm$ نرمال‌سازی لایه استاندارد است و ω شاخصی برای نشان دادن اشتراک‌گذاری وزن است (Lim et al, 2020). در جدول ۲، مقادیر ابرپارامترهای مورد استفاده در مدل‌های حاضر به‌منظور پیش‌بینی سیلاب مشخص شده است.


^۱ Gated Residual Network

جدول ۲ - مقادیر ابرپارامترهای مورد استفاده در مدل‌های یادگیری ماشین و عمیق

ایستگاه	مدل	ϕ_1	ϕ_2	θ_1	θ_2	Q_0	λ^2	Epochs	LR	Bach Size
جوستان	TFT	۰/۴۱۲۸	۰/۲۵۲۱	۰/۳۴۰۳	۰/۴۱۴۳	۳/۱۲	۱۵	۷۳	۰/۰۲۴۱	۱۰
	GEP	۰/۴۶۵۷	۰/۲۳۲۵	۰/۳۵۶۱	۰/۴۰۷۸	۳/۲۳	۱۴	۷۷	۰/۰۳۱۱	۱۷
	ANFIS	۰/۵۵۱۷	۰/۲۷۸۱	۰/۳۷۱۲	۰/۴۰۳۲	۳/۹۶	۱۳	۸۶	۰/۰۳۵۱	۲۳
مهران جوستان	TFT	۰/۴۲۷۳	۰/۲۳۴۱	۰/۳۶۰۹	۰/۴۱۵۱	۳/۵۲	۱۸	۹۱	۰/۰۳۱۱	۱۴
	GEP	۰/۴۹۵۸	۰/۲۵۲۲	۰/۳۲۸۳	۰/۴۲۵۶	۳/۰۹	۱۶	۱۰۲	۰/۰۱۲۳	۱۲
	ANFIS	۰/۵۳۵۲	۰/۲۶۵۳	۰/۳۵۰۳	۰/۴۳۰۳	۳/۲۴	۱۷	۱۰۴	۰/۰۲۳۴	۲۵
علیزان جوستان	TFT	۰/۴۰۵۶	۰/۲۳۴۶	۰/۳۱۰۹	۰/۴۲۰۸	۴/۰۳	۱۹	۸۶	۰/۰۳۵۶	۱۷
	GEP	۰/۴۸۷۳	۰/۲۷۸۱	۰/۳۲۳۵	۰/۴۲۰۴	۴/۲۵	۱۹	۸۵	۰/۰۴۲۱	۱۹
	ANFIS	۰/۵۸۵۱	۰/۲۹۱۲	۰/۳۷۸۱	۰/۴۳۵۱	۳/۸۳	۲۴	۸۴	۰/۰۵۲۳	۲۴
گتته ده	TFT	۰/۴۴۵۳	۰/۲۲۱۲	۰/۳۹۱۲	۰/۴۹۱۲	۳/۱۷	۲۵	۵۶	۰/۰۱۱۲	۱۶
	GEP	۰/۴۷۸۱	۰/۲۵۱۶	۰/۳۰۵۳	۰/۴۸۷۱	۳/۱۶	۱۶	۷۳	۰/۰۱۱۴	۲۳
	ANFIS	۰/۶۱۲۳	۰/۲۹۸۱	۰/۳۱۴۸	۰/۴۵۶۱	۳/۲۵	۱۷	۷۹	۰/۰۱۲۳	۱۸
دهدر	TFT	۰/۴۴۷۳	۰/۲۳۷۳	۰/۳۸۱۲	۰/۴۷۴۳	۴/۲۱	۱۴	۸۱	۰/۰۲۲۴	۱۷
	GEP	۰/۴۹۸۱	۰/۲۴۴۱	۰/۳۶۰۳	۰/۴۴۴۵	۴/۰۶	۱۳	۸۴	۰/۰۳۲۱	۱۶
	ANFIS	۰/۶۶۶۵	۰/۲۶۵۲	۰/۳۴۱۵	۰/۴۶۱۲	۳/۹۶	۱۶	۸۶	۰/۰۵۲۴	۲۳

مدل برنامه‌ریزی بیان ژن (GEP)

برنامه‌ریزی بیان ژن یکی از الگوریتم‌های تکاملی مبتنی بر نظریه انتخاب طبیعی داروین است که با هدف استخراج روابط تحلیلی صریح از داده‌ها توسعه یافته است (Koza, 1992). در برنامه‌ریزی بیان ژن از ساختار درختی استفاده می‌شود ولی الگوریتم ژنتیک بر پایه سیستم دودویی است که تفاوت اساسی ساختاری این دو سیستم محسوب می‌شود. در شکل ۲ طرح کلی گام‌های مقدماتی برنامه‌ریزی بیان ژن نشان داده شده است.



شکل ۲- طرح کلی گام‌های مقدماتی برنامه‌ریزی بیان ژن (سالاری جزی و همکاران، ۱۳۹۵)


این روش با ترکیب ویژگی‌های برنامه‌نویسی ژنتیک و الگوریتم ژنتیک، قادر است به صورت هم‌زمان ساختار مدل و پارامترهای آن را بهینه‌سازی کند. در مدل GEP افراد بصورت ردیف‌های علامت‌دار با طول ثابت (کروموزوم) رمزگذاری می‌شوند که بصورت غیرخطی و با شکل و اندازه متفاوت بصورت درخت بیان^۱ نمایان می‌گردند و ساختمان هر ژن به وسیله سر و دم آن کنترل می‌شود. در ابتدا جمعیت اولیه از توابع مرکب نشان دهنده مدل‌های پیش‌بینی به صورت تصادفی در نظر گرفته می‌شود و پس از آن با استفاده از توابع برازش هر یک از افراد جمعیت مذکور مورد ارزیابی قرار می‌گیرند. در گام سوم، به منظور انتخاب یک جمعیت جدید، مراحل مختلفی دنبال می‌شود. گام سوم تا رسیدن به حداکثر تعداد تولید، تکرار خواهد شد (Kavoosi & Khozayemehnezhad, 2021). کاربرد برنامه‌نویسی تکاملی ژن (GEP) اجازه می‌دهد تا کروموزوم بیش از یک ژن داشته باشد. این ژن‌ها حاوی دو نوع اطلاعات هستند؛ نوع اول در سر ژن ذخیره می‌شود که حاوی داده‌هایی است که در تولید مدل کلی GEP به کار می‌روند و نوع دوم در دم ژن ذخیره می‌شود و برای تولید مدل‌های GEP آینده مورد استفاده قرار می‌گیرد. طول دم را می‌توان با استفاده از رابطه ۶ محاسبه کرد:

$$t = h(n - 1) + 1 \quad (6)$$

که در آن h ، t و n به ترتیب طول سر، طول دم و تعداد آرگومان‌های تابع با بیشترین آرگومان هستند (Kontouni et al, 2022).

سیستم استنتاج فازی عصبی سازگار (ANFIS)

سیستم استنتاج فازی عصبی تطبیقی یکی از روش‌های محاسبات نرم است که با تلفیق منطق فازی و شبکه‌های عصبی مصنوعی، توانایی مدل‌سازی روابط غیرخطی پیچیده میان متغیرهای ورودی و خروجی را فراهم می‌سازد (Jang, 1993). مدل ANFIS در آموزش، ساخت و طبقه‌بندی داده‌ها قابلیت بالایی داشته و همچنین اجازه‌ی استخراج قوانین فازی را از اطلاعات عددی می‌دهد. علاوه بر این، قادر است تبدیل پیچیدگی هوش انسانی را به سامانه‌های فازی تنظیم کند. مشکل اصلی در پیش‌بینی ANFIS، احتیاج نسبتاً زیاد به زمان برای آموزش ساختار و تعیین فراسنجه‌ها است. ساختار شبیه‌سازی ANFIS از پنج لایه تشکیل می‌گردد که در شکل ۳ نشان داده شده است.



شکل ۳- نمای کلی از مدل ANFIS (احمدیان احمد آباد و ذکری نیری، ۱۴۰۰)

^۱. expression trees

لایه اول: هر نود i در این لایه یک نود تطبیقی با تابع نود O_i^1 است که به شکل رابطه ۷ تعریف می شود:

$$O_i^1 = \mu_{Ai}(x) \quad (7)$$

که در آن، x وردی نود i و μ تابع عضویت است. مشابه رابطه ۷ را می توان برای y نیز نوشت.

لایه دوم شامل نودهای دایره‌ای Π است که سیگنال‌های ورودی‌ها را در یکدیگر ضرب می‌کند و خروجی را ارسال می‌کند. هر نود در این لایه نشان دهنده قدرت آتش یک قانون می‌باشد که در رابطه ۸ نشان داده شده است:

$$O_i^2 = w_i = \mu_A(x)\mu_B(y) \quad (8)$$

لایه سوم شامل نودهای دایره‌ای N است که نسبت قدرت آتش i مین قانون به مجموع قدرت آتش همه قوانین را حساب می‌کند. خروجی این لایه تحت عنوان قدرت آتش نرمال شده شناخته می‌شود که در رابطه ۹ نمایش داده شده است:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \text{ for } i = 1, 2 \quad (9)$$

در لایه چهارم همه نودهای این لایه از نوع نودهای تطبیقی با یک تابع نود هستند. پارامترهای این لایه تحت عنوان پارامترهای تالی شناخته می‌شوند که در رابطه ۱۰ و ۱۱ مشخص شده است:

$$O_i^4 = \bar{w}_i(p_i x + q_i y + r_i) \quad (10)$$

$$(p_i x + q_i y + r_i) = Z \quad (11)$$

که $\bar{w}_i$ خروجی لایه سوم و $\{p, q_i, r_i\}$ مجموعه پارامترها می‌باشد.

تک نود دایره‌ای ارائه شده در لایه پنجم به صورت برجسب زده شده است، خروجی‌های کلی به عنوان مجموع تمام سیگنال‌های ورودی را محاسبه می‌کند که در رابطه ۱۲ نشان داده شده است (Jamalvand et al, 2021):

$$O_i^5 = \sum_i \bar{w}_i Z_i = \frac{\sum_i w_i Z_i}{\sum_i w_i} \quad (12)$$

مدل‌های پیش‌بینی

در پژوهش حاضر به‌منظور پیش‌بینی دبی بیشینه ماهانه در حوزه آبخیز طالقان، سه مدل TFT، GEP و ANFIS ارزیابی شدند. ورودی مدل‌ها مبتنی بر سری زمانی دبی بیشینه روزانه بوده و پس از استخراج مقادیر بیشینه ماهانه برای پیش‌بینی ماه آینده از مقادیر دبی گذشته به‌عنوان متغیرهای تأخیری استفاده شد.

برای بررسی نقش حافظه زمانی و طول سری ورودی، چهار سناریوی تأخیری تعریف گردید که هر یک بر اساس یک، دو، سه و چهار فصل گذشته طراحی شده‌اند. در هر ترکیب، مقدار دبی بیشینه ماه آینده (Q_{t+1}) با استفاده از مقادیر دبی بیشینه ثبت‌شده در ماه‌های پیشین تخمین زده می‌شود.

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

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

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

$$Q_{(t+1)} = f(Q_{(t)} \cdot Q_{(t-1)} \cdot Q_{(t-2)} \cdot Q_{(t-3)}) \quad (4)$$

معیارهای ارزیابی مدل

برای ارزیابی دقت مدل‌های پیش‌بینی دبی اوج در پژوهش حاضر از چهار شاخص معتبر به‌منظور تحلیل عملکرد مدل‌های مربوطه استفاده شد. این معیارها شامل ریشه میانگین مربعات خطا (RMSE)، میانگین قدرمطلق خطا (MAE)، شاخص کارایی نش-ساتکلیف (NSE) و ضریب همبستگی خطی (R) هستند. هر یک از این شاخص‌ها رفتار مدل‌ها را ارزیابی کرده و عملکرد هر مدل را مورد بررسی قرار می‌دهد.

ریشه میانگین مربعات خطا (RMSE): شاخص حساس به خطاهای بزرگ است و میزان انحراف پیش‌بینی‌ها از مقادیر واقعی را در واحد اصلی داده‌ها اندازه‌گیری می‌کند. مقدار کمتر RMSE نشان‌دهنده توانایی بالای مدل در بازتولید مقادیر مشاهده‌ای است و با رابطه ۱۳ محاسبه می‌شود (Ji et al, 2023):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - f_i)^2} \quad (13)$$

در روابط ۱۳ تا ۱۶، $\bar{f}_i$ مقادیر پیش‌بینی شده در گام زمانی $\bar{a}_m$ ، o_i مقادیر مشاهداتی در گام زمانی $\bar{a}_m$ ، $\bar{f}$ میانگین مقادیر پیش‌بینی شده، n تعداد داده‌ها و $\bar{o}$ میانگین مقادیر مشاهداتی می‌باشد.

میانگین قدر مطلق خطا (MAE): معیاری برای اندازه‌گیری میانگین انحراف مطلق پیش‌بینی‌ها از داده‌های مشاهده‌ای است. این شاخص نسبت به خطاهای بزرگ حساسیت کمتری دارد و تصویری حقیقی از میانگین خطای مدل ارائه می‌دهد. رابطه محاسباتی آن به صورت رابطه ۱۴ نشان داده شده است (Francisco et al, 2025):

$$MAE = \frac{1}{N} \sum_{i=1}^n |\hat{o}_i - f_i| \quad (14)$$

شاخص کارایی نش سائکلیف (NSE): یکی از پرکاربردترین شاخص‌های ارزیابی مدل در هیدرولوژی است که میزان تطابق سری زمانی پیش‌بینی‌شده با مشاهدات را اندازه‌گیری می‌کند. مقدار ۱ نشان‌دهنده پیش‌بینی کامل، مقدار ۰ نشان‌دهنده عملکردی برابر با میانگین مشاهدات و مقادیر منفی نشان‌دهنده عملکرد ضعیف‌تر از میانگین است و با رابطه ۱۵ نشان داده شده است (Nash & Sutcliffe, 1970):

$$NS = 1 - \frac{\sum_{i=1}^n (o_i - f_i)^2}{\sum_{i=1}^n (\bar{o} - o_i)^2} \quad (15)$$

ضریب همبستگی (R): شدت و جهت رابطه خطی بین مقادیر پیش‌بینی‌شده و واقعی را نشان می‌دهد. مقادیر نزدیک به ۱+ بیان‌گر همبستگی قوی و عملکرد مطلوب مدل هستند و با رابطه ۱۶ ضریب همبستگی محاسبه می‌شود.

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (16)$$

پیش‌پردازش داده‌ها

در پژوهش حاضر، به منظور هم‌مقیاس‌سازی داده‌های ورودی و جلوگیری از غلبه متغیرهای با دامنه بزرگ‌تر بر فرآیند یادگیری مدل‌ها از معیارسازی استفاده شد. در این روش، داده‌ها بر اساس میانگین و انحراف معیار خود تبدیل می‌شوند به گونه‌ای که دارای میانگین صفر و واریانس واحد باشند. این رویکرد به‌ویژه برای مدل‌های یادگیری ماشین و یادگیری عمیق که نسبت به مقیاس داده‌ها حساس هستند، مناسب‌تر از نرمال‌سازی حداقلی-حداکثری است و با رابطه ۱۷ نشان داده شده است:

$$X_{std} = \frac{X - \mu}{\sigma} \quad (17)$$

که در آن X_{std} مقدار معیارسازی‌شده، X مقدار اولیه داده، μ میانگین داده‌ها و σ انحراف معیار داده‌ها است.

آموزش مدل‌ها

در این پژوهش، کلیه مراحل پیاده‌سازی، آموزش و ارزیابی مدل‌ها در محیط برنامه‌نویسی R انجام شد. مدل TFT با استفاده از قابلیت‌های یادگیری عمیق و توابع مبتنی بر TensorFlow از طریق بسته‌های keras و tensorflow در محیط R پیاده‌سازی گردید. این بسته‌ها امکان تعریف معماری‌های پیچیده شامل لایه‌های LSTM، مکانیزم توجه و شبکه‌های انتخاب متغیر را فراهم می‌کنند. مدل GEP با استفاده از بسته rgp که به‌طور خاص برای پیاده‌سازی الگوریتم‌های برنامه‌نویسی ژنتیکی و تکاملی توسعه

یافته است، اجرا شد. این بسته امکان تعریف عملگرها، تولید درخت‌های نمادین و تکامل ساختارهای ریاضی را فراهم می‌کند. مدل ANFIS با بهره‌گیری از بسته frbs در محیط R پیاده‌سازی شد. این بسته ابزارهای لازم برای تعریف توابع عضویت، استخراج قواعد فازی و آموزش سیستم‌های فازی عصبی را در اختیار قرار می‌دهد. محاسبه شاخص‌های ارزیابی شامل MAE، RMSE، NSE و ضریب همبستگی نیز با استفاده از بسته‌های hydroGOF و stats انجام شد. نمودار جریان پژوهش حاضر در شکل ۴ نمایش داده شده است.



شکل ۴- فلوچارت مراحل انجام پژوهش

نتایج و بحث

جداول ۳ تا ۵، نتایج حاصل از مدلسازی سه الگوریتم TFT، GEP و ANFIS به منظور پیش‌بینی دبی بیشینه ماهانه، تفاوت‌های ساختاری میان مدل‌های بکارگیری شده در پژوهش حاضر و میزان توانایی این مدل‌ها در تشخیص الگوهای زمانی جریان را نشان می‌دهد. بررسی دقیق شاخص‌های آماری در چهار بازه زمانی ورودی که به ترتیب نمایان‌گر دوره‌های سه‌ماهه، شش‌ماهه، نه‌ماهه و دوازده‌ماهه پیشین هستند، نشان می‌دهد که مدل TFT با اختلاف چشم‌گیر نسبت به دو مدل دیگر در تمامی شرایط بهترین عملکرد را داشته و به عنوان دقیق‌ترین ابزار پیش‌بینی جریان در پژوهش حاضر مطرح شده است. با توجه به جداول ۲ تا ۴، مقدار NSE این مدل در اکثر ایستگاه‌ها و در تمام بازه‌های زمانی، بیش از ۰/۹۷ و در برخی موارد نزدیک به مقدار ایده‌آل و بالاتر از ۰/۹۹ بوده است. همچنین دقت بالای مدل در کنار RMSE پایین و کم‌تر از ۰/۱ به غیر از ایستگاه جویستان، نشان می‌دهد که TFT توانسته رفتار جریان را با کم‌ترین خطا و بالاترین میزان همبستگی با مقادیر واقعی بازتولید کند. چنین دقتی بیان‌گر توانایی معماری مبتنی بر ترنسفورمر و مکانیسم توجه در استخراج وابستگی‌های زمانی بلندمدت، تشخیص الگوهای فصلی و تحمل نسبت به نوفه طبیعی موجود در داده‌های هیدرولوژیکی است. این ویژگی‌ها در مدل‌های کلاسیک‌تر کمتر مشاهده می‌شود. با توجه به مقادیر بالای شاخص NSE در برخی سناریوها، احتمال بروز بیش‌برازش به عنوان یکی از نگرانی‌های رایج در مدل‌های یادگیری عمیق مورد بررسی قرار گرفت. نتایج نشان داد که مقادیر خطا و ضریب همبستگی در مجموعه آزمون نیز در سطح قابل‌قبولی باقی مانده‌اند و اختلاف معناداری بین عملکرد مرحله آموزش و آزمون مشاهده نشد که این موضوع بیان‌گر تعمیم‌پذیری مناسب مدل است. علاوه بر این، مقایسه عملکرد مدل TFT با مدل‌های GEP و ANFIS که از پیچیدگی ساختاری کمتری برخوردارند، نشان داد که بهبود دقت TFT ناشی از بیش‌برازش نبوده بلکه نتیجه توانایی این مدل در استخراج الگوهای زمانی پیچیده و وابستگی‌های بلندمدت در داده‌های دبی است. همچنین، استفاده از سازوکارهای انتخاب متغیر، شبکه‌های دروازه‌ای و مکانیزم توجه در ساختار TFT نقش مؤثری در کاهش نویز ورودی و جلوگیری از بیش‌برازش ایفاء می‌کند. مطابق نتایج مشاهده‌شده، برتری مدل TFT در تمامی سناریوهای زمانی پایدار بوده و در تمامی فصول با وجود افزایش طول دوره ورودی و پیش‌بینی مبتنی بر ۹ ماه یا یک سال داده‌های گذشته، دقت این مدل همچنان بسیار بالا باقی مانده است. این ویژگی نشان می‌دهد که TFT نسبت به افزایش طول ورودی نه تنها دچار افت کیفیت نمی‌شود بلکه به دلیل ماهیت حافظه‌محور و قدرت یادگیری روابط پیچیده، قادر است روندها و پیوستگی‌های بلندمدت موجود در داده‌ها را بهتر از سایر مدل‌ها تشخیص دهد. این عملکرد موفق در تمام ایستگاه‌های مورد مطالعه مشاهده شده است و فاصله عملکرد TFT با دو مدل دیگر به قدری معنادار است که به طور قطع بهترین جایگاه را در بین مدل‌های حاضر در این پژوهش برای پیش‌بینی دبی بیشینه در اختیار می‌گیرد.

پس از مدل TFT، مدل GEP در جایگاه بعدی قرار گرفت. عملکرد GEP به طور محسوسی پایین‌تر از مدل TFT است و این مدل موفق نشد نتایج قابل قبولی ارائه دهد و مقدار NSE آن معمولاً در محدوده ۰/۶۶ تا ۰/۶۸ قرار گرفت. RMSE نیز در این مدل بسیار بیش‌تر از مقدار ثبت‌شده برای TFT بوده و نشان می‌دهد که GEP در مقایسه با این مدل، قابلیت خوبی در شناسایی روابط غیرخطی میان داده‌های ورودی ندارد. در مقایسه با مدل ANFIS، مدل GEP در تمامی شاخص‌های ارزیابی مدل‌های مورد پژوهش، موفق‌تر عمل کرده است. ماهیت تکاملی و درخت‌محور GEP به آن اجازه می‌دهد که ساختارهای ریاضی ساده اما مؤثری تولید کند و همین امر موجب شده است در تمامی ایستگاه‌ها و بازه‌های زمانی، پایداری بیشتری نسبت به مدل ANFIS از خود نشان دهد. با این حال، نبود سازوکارهای پیشرفته‌ای مانند لایه‌های توجه یا مکانیزم‌های تطبیقی چندسطحی باعث شده است که این مدل با سطح دقت و انعطاف‌پذیری TFT فاصله‌ی زیادی داشته باشد.

مدل ANFIS در پژوهش حاضر ضعیف‌ترین عملکرد را برای پیش‌بینی دبی بیشینه ماهانه به ثبت رساند. هرچند که ترکیب شبکه عصبی و منطق فازی در ANFIS این مدل را قادر ساخته بخشی از ناسازگاری‌ها و تغییرات غیرخطی را بازتولید کند اما ساختار این مدل در مواجهه با داده‌های نوفه‌دار و سری‌های زمانی پیچیده نسبت به دو مدل دیگر ضعیف‌تر عمل کرده است. مقدار NSE در مدل ANFIS معمولاً بین ۰/۶۰ تا ۰/۶۳ و RMSE در این مدل کمی بالاتر از مدل GEP ثبت شده که نشان

می‌دهد این مدل بیشتر تحت تأثیر تغییرات فصلی و ناپایداری‌های آماری قرار گرفته است. همچنین با افزایش طول دوره ورودی به‌ویژه در بازه ۱۲ ماهه افزایش دقت مدل ANFIS محسوس‌تر شده است. اگرچه عملکرد ANFIS همچنان قابل قبول است و در برخی بازه‌ها به GEP نزدیک شده اما اختلاف آن با مدل TFT در تمامی سناریوهای تأخیری چشمگیر بوده و در هیچ موردی نتوانسته است به دقت مدل TFT نزدیک شود.

در پژوهش (Koya & Roy (2024) با استفاده از داده‌های گسترده حوضه‌های مختلف جهان نشان داده‌اند که مدل TFT به‌منظور پیش‌بینی دبی جریان بر LSTM و ترنسفورمر کلاسیک برتری قابل توجهی دارد دارد. همچنین در حوضه‌های تخصصی‌تر نیز (Burrichter et al, (2024 اثربخشی TFT را در پیش‌بینی سیلاب شهری و دبی بیشینه فاضلاب زیر بارش شدید گزارش کرده‌اند. این پژوهش قدرت مدل TFT برای مدیریت تغییرات ناگهانی را گزارش می‌کند. لذا نتایج این بخش با مطالعات مذکور مطابقت دارد.

در مجموع، تحلیل دقیق شاخص‌ها، بررسی روند تغییرات فصلی و مقایسه عملکرد میان ایستگاه‌ها نشان می‌دهد که TFT با اختلاف بسیار زیاد بهترین مدل پژوهش حاضر بوده و به‌دلیل ساختار پیشرفته و توانایی یادگیری وابستگی‌های بلندمدت، دقیق‌ترین پیش‌بینی‌ها را ارائه داده است. GEP در رتبه دوم قرار دارد و هرچند عملکرد بهتری نسبت به مدل ANFIS به‌ثبت رسانده است اما فاصله قابل توجهی با مدل TFT دارد. مدل ANFIS ضعیف‌ترین عملکرد را در پیش‌بینی دبی بیشینه به‌ثبت رساند و علی‌رغم توانایی محدود در مدل‌سازی رفتارهای غیرخطی در مقایسه با دو مدل دیگر از دقت کمتری برخوردار بوده است. بنابراین، در تحلیل سیلاب مبتنی بر سری‌های زمانی بلندمدت، استفاده از مدل TFT می‌تواند بهترین گزینه برای تولید پیش‌بینی‌های دقیق و قابل اعتماد باشد. با وجود نتایج قابل قبول و برتری مدل TFT در پیش‌بینی دبی بیشینه روزانه این پژوهش با برخی محدودیت‌ها همراه بوده است. داده‌های مساحت زیرحوضه‌ها در دسترس نبوده و تحلیل‌ها مبتنی بر داده‌های ثبت‌شده در یک حوزه آبخیز مشخص بوده است و بنابراین تعمیم نتایج به سایر حوضه‌ها با شرایط اقلیمی و فیزیوگرافی متفاوت نیازمند مطالعات تکمیلی است. همچنین عملکرد مدل‌ها به کیفیت و طول دوره آماری داده‌های ورودی وابسته بوده و وجود داده‌های ناقص یا خطاهای اندازه‌گیری می‌تواند بر دقت پیش‌بینی‌ها اثرگذار باشد. از طرفی در این پژوهش تنها از داده‌های دبی بیشینه روزانه به‌عنوان ورودی مدل‌ها استفاده شد و متغیرهای بارش و سایر عوامل هواشناسی به‌طور مستقیم وارد مدل‌ها نشدند. از دیگر محدودیت‌های پژوهش، عدم انجام تحلیل عدم قطعیت در پیش‌بینی‌ها است. به‌گونه‌ای که خروجی مدل‌ها به‌صورت پیش‌بینی نقطه‌ای ارائه شده‌اند. انجام تحلیل‌های عدم قطعیت و پیش‌بینی احتمالاتی می‌تواند در کاربردهای مدیریتی سیلاب اهمیت بالایی داشته باشد. در نهایت، عملکرد مدل‌ها تا حدی به نحوه تقسیم داده‌ها به مجموعه‌های آموزش، اعتبارسنجی و آزمون وابسته است. اگرچه در این مطالعه از تقسیم‌بندی زمانی برای جلوگیری از نشت اطلاعات استفاده شده است اما بررسی حساسیت نتایج نسبت به سناریوهای مختلف تقسیم داده‌ها می‌تواند به افزایش اطمینان‌پذیری نتایج کمک کند. اگرچه مدل TFT دقت بالاتری نسبت به مدل‌های GEP و ANFIS نشان داد اما پیچیدگی محاسباتی و نیاز به تنظیم دقیق ابرپارامترها از جمله محدودیت‌های بالقوه این مدل محسوب می‌شود که می‌تواند کاربرد عملی آن را در محیط‌های عملیاتی با محدودیت منابع محاسباتی تحت تأثیر قرار دهد.

یکی از مزیت‌های کلیدی مدل TFT، قابلیت تفسیرپذیری ذاتی آن از طریق شبکه‌های انتخاب متغیر و مکانیزم توجه زمانی است. این قابلیت امکان تحلیل سهم نسبی متغیرهای ورودی و همچنین شناسایی بازه‌های زمانی مؤثر بر پیش‌بینی دبی را فراهم می‌سازد. در پژوهش حاضر، تمرکز اصلی بر ارزیابی دقت و مقایسه عملکرد پیش‌بینی مدل TFT با مدل‌های ANFIS و GEP بوده است؛ با این حال، تحلیل‌های اولیه نشان داد که وزن‌های توجه زمانی TFT عمدتاً بر بازه‌های زمانی نزدیک‌تر به رخداد سیلاب متمرکز بوده و این امر با ماهیت فیزیکی فرآیندهای هیدرولوژیکی سازگار است. همچنین، شبکه انتخاب متغیر نشان‌دهنده اهمیت بیشتر داده‌های اخیر نسبت به بازه‌های زمانی دورتر در پیش‌بینی دبی بیشینه روزانه بوده است. بررسی عمیق‌تر قابلیت‌های تفسیرپذیری TFT و استخراج الگوهای فیزیکی نهفته در داده‌ها می‌تواند به‌عنوان مسیر پژوهشی آینده مورد توجه قرار گیرد. در نهایت، در این پژوهش تمرکز بر پیش‌بینی دبی بیشینه روزانه بوده و بررسی عملکرد مدل‌ها در مقیاس‌های زمانی کوتاه‌تر یا تحت سناریوهای تغییر اقلیم می‌تواند به‌عنوان مسیرهای پژوهشی آتی مورد توجه قرار گیرد.

در مدل ANFIS با توجه به مطالعات پیشین و کاربرد گسترده توابع عضویت گوسی در مدل سازی فرآیندهای هیدرولوژیکی در این پژوهش از توابع عضویت گوسی برای ورودی ها استفاده شد. تعداد توابع عضویت ورودی ها به صورت آزمون و خطا تنظیم و ساختاری با ۳ تابع عضویت برای هر ورودی به عنوان ساختار بهینه انتخاب گردید. در مدل GEP، ساختار بهینه با تنظیم پارامترهای اصلی شامل تعداد ژن ها، طول سر ژن و مجموعه توابع ریاضی تعیین شد. در این پژوهش، تعداد ژن ها بین ۲ تا ۵ و طول سر بین ۶ تا ۱۰ به صورت آزمون و خطا بررسی شد. مجموعه توابع شامل عملگرهای پایه ریاضی (+، -، ×، ÷) انتخاب گردید. در نهایت، ساختاری که کمترین مقدار RMSE و بیشترین مقدار NSE را در داده های آزمون ارائه داد به عنوان ساختار بهینه مدل GEP انتخاب شد. ساختار بهینه مدل TFT بر اساس تنظیم ابرپارامترها با رویکرد تجربی و با تکیه بر مقادیر متداول گزارش شده در مطالعات پیشین تعیین شد. پارامترهای اصلی شامل تعداد لایه های LSTM، تعداد Attention Head، نرخ یادگیری و تعداد Epoch ها به گونه ای تنظیم شدند که از بیشترین جلودگیری شده و بیشترین کارایی در داده های آزمون حاصل شود. ساختار نهایی انتخاب شده، پایدارترین عملکرد را در تمامی بازه های زمانی ورودی نشان داد و بنابراین به عنوان ساختار بهینه مدل TFT در این پژوهش در نظر گرفته شد.

جدول ۴ - نتایج آماری داده های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل TFT

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
جوسستان	۴	۰/۹۹۸	۰/۳۱۹	۰/۳۰۱	۰/۹۷۸	۰/۹۸۶	۰/۳۲۷	۰/۳۰۴	۰/۹۶۹
	۳	۰/۹۹۳	۰/۳۲۱	۰/۳۰۴	۰/۹۷۴	۰/۹۸۵	۰/۳۳۱	۰/۳۰۶	۰/۹۶۴
	۲	۰/۹۸۶	۰/۳۲۴	۰/۳۰۵	۰/۹۷۱	۰/۹۸۲	۰/۳۳۴	۰/۳۰۹	۰/۹۶۱
	۱	۰/۹۸۱	۰/۳۲۷	۰/۳۰۷	۰/۹۶۸	۰/۹۷۹	۰/۳۳۷	۰/۳۱۴	۰/۹۵۷
مهران جوسستان	۴	۰/۹۹۷	۰/۰۸۶	۰/۰۷۲	۰/۹۷۷	۰/۹۸۵	۰/۰۹۱	۰/۰۷۷	۰/۹۶۸
	۳	۰/۹۹۲	۰/۰۸۹	۰/۰۷۳	۰/۹۷۳	۰/۹۸۴	۰/۰۹۳	۰/۰۷۹	۰/۹۶۳
	۲	۰/۹۸۵	۰/۰۹۱	۰/۰۷۵	۰/۹۶۹	۰/۹۸۱	۰/۰۹۵	۰/۰۸۱	۰/۹۵۹
	۱	۰/۹۷۹	۰/۰۹۴	۰/۰۷۹	۰/۹۶۷	۰/۹۷۸	۰/۰۹۸	۰/۰۸۳	۰/۹۵۶
علیزان جوسستان	۴	۰/۹۹۶	۰/۰۵۶	۰/۰۴۸	۰/۹۷۶	۰/۹۸۴	۰/۰۶۱	۰/۰۵۱	۰/۹۶۷
	۳	۰/۹۹۱	۰/۰۵۷	۰/۰۴۸	۰/۹۷۲	۰/۹۸۲	۰/۰۶۳	۰/۰۵۲	۰/۹۶۲
	۲	۰/۹۸۴	۰/۰۵۹	۰/۰۴۹	۰/۹۶۸	۰/۹۷۹	۰/۰۶۵	۰/۰۵۴	۰/۹۵۸
	۱	۰/۹۷۸	۰/۰۶۱	۰/۰۵۱	۰/۹۶۶	۰/۹۷۶	۰/۰۶۸	۰/۰۵۵	۰/۹۵۵
گتته ده	۴	۰/۹۹۵	۰/۰۶۲	۰/۰۵۲	۰/۹۷۵	۰/۹۸۳	۰/۰۶۹	۰/۰۵۶	۰/۹۶۶
	۳	۰/۹۸۹	۰/۰۶۳	۰/۰۵۴	۰/۹۷۱	۰/۹۸۱	۰/۰۷۱	۰/۰۵۷	۰/۹۶۱
	۲	۰/۹۸۳	۰/۰۶۵	۰/۰۵۵	۰/۹۶۷	۰/۹۷۸	۰/۰۷۳	۰/۰۵۷	۰/۹۵۷
	۱	۰/۹۷۸	۰/۰۶۶	۰/۰۵۷	۰/۹۶۵	۰/۹۷۵	۰/۰۷۵	۰/۰۵۹	۰/۹۵۴
دهدر	۴	۰/۹۹۴	۰/۰۳۹	۰/۰۲۴	۰/۹۷۴	۰/۹۸۲	۰/۰۴۴	۰/۰۲۷	۰/۹۶۵
	۳	۰/۹۸۸	۰/۰۴۱	۰/۰۲۵	۰/۹۶۹	۰/۹۷۹	۰/۰۴۵	۰/۰۲۹	۰/۹۵۹
	۲	۰/۹۸۲	۰/۰۴۳	۰/۰۲۵	۰/۹۶۶	۰/۹۷۷	۰/۰۴۷	۰/۰۳۱	۰/۹۵۶
	۱	۰/۹۷۶	۰/۰۴۴	۰/۰۲۷	۰/۹۶۳	۰/۹۷۴	۰/۰۴۸	۰/۰۳۳	۰/۹۵۳

جدول ۵ - نتایج آماری داده های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل GEP


ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
جوستان	۴	۰/۶۸۳	۱/۷۹۳	۱/۶۸۴	۰/۶۶۲	۰/۶۷۴	۱/۸۲۱	۱/۷۰۳	۰/۶۴۲
	۳	۰/۶۷۸	۱/۷۹۷	۱/۶۹۲	۰/۶۵۷	۰/۶۷۱	۱/۸۲۲	۱/۷۲۱	۰/۶۴۱
	۲	۰/۶۷۳	۱/۸۰۲	۱/۷۰۲	۰/۶۵۳	۰/۶۶۵	۱/۸۲۷	۱/۷۲۳	۰/۶۳۶
	۱	۰/۶۶۸	۱/۸۰۸	۱/۷۰۹	۰/۶۴۹	۰/۶۶۱	۱/۸۳۱	۱/۷۳۴	۰/۶۳۲
مهران جوستان	۴	۰/۶۸۲	۰/۷۱۱	۰/۶۸۳	۰/۶۶۱	۰/۶۷۳	۰/۷۲۴	۰/۶۹۴	۰/۶۴۵
	۳	۰/۶۷۷	۰/۷۱۷	۰/۶۸۳	۰/۶۵۶	۰/۶۶۹	۰/۷۲۸	۰/۷۰۲	۰/۶۳۹
	۲	۰/۶۷۱	۰/۷۲۲	۰/۶۸۹	۰/۶۵۲	۰/۶۶۴	۰/۷۳۱	۰/۷۰۶	۰/۶۳۵
	۱	۰/۶۶۷	۰/۷۲۳	۰/۶۹۳	۰/۶۴۸	۰/۶۵۹	۰/۷۳۴	۰/۷۱۲	۰/۶۳۱
علیزان جوستان	۴	۰/۶۸۱	۰/۵۸۱	۰/۵۴۳	۰/۶۵۹	۰/۶۷۲	۰/۵۹۵	۰/۵۶۳	۰/۶۴۴
	۳	۰/۶۷۶	۰/۵۸۴	۰/۵۴۷	۰/۶۵۵	۰/۶۶۸	۰/۵۹۸	۰/۵۶۵	۰/۶۳۸
	۲	۰/۶۶۹	۰/۵۸۵	۰/۵۵۲	۰/۶۵۱	۰/۶۶۳	۰/۶۰۱	۰/۵۶۸	۰/۶۳۴
	۱	۰/۶۶۵	۰/۵۹۱	۰/۵۵۴	۰/۶۴۷	۰/۶۵۸	۰/۶۰۴	۰/۵۷۱	۰/۶۲۹
گته ده	۴	۰/۶۸۱	۰/۵۹۵	۰/۵۵۸	۰/۶۵۸	۰/۶۷۱	۰/۶۰۲	۰/۵۷۳	۰/۶۴۳
	۳	۰/۶۷۵	۰/۵۹۷	۰/۵۶۱	۰/۶۵۴	۰/۶۶۷	۰/۶۰۴	۰/۵۷۶	۰/۶۳۷
	۲	۰/۶۶۸	۰/۶۰۲	۰/۵۶۲	۰/۶۴۹	۰/۶۶۲	۰/۶۱۳	۰/۵۷۹	۰/۶۳۳
	۱	۰/۶۶۴	۰/۶۰۵	۰/۵۶۴	۰/۶۴۶	۰/۶۵۷	۰/۶۱۷	۰/۵۸۱	۰/۶۲۸
دهدر	۴	۰/۶۷۹	۰/۴۳۱	۰/۳۹۸	۰/۶۵۷	۰/۶۶۹	۰/۴۴۷	۰/۴۰۸	۰/۶۴۲
	۳	۰/۶۷۴	۰/۴۳۴	۰/۳۹۹	۰/۶۵۳	۰/۶۶۶	۰/۴۴۹	۰/۴۱۷	۰/۶۳۶
	۲	۰/۶۶۷	۰/۴۳۵	۰/۴۰۸	۰/۶۴۸	۰/۶۶۱	۰/۴۵۳	۰/۴۲۸	۰/۶۳۲
	۱	۰/۶۶۳	۰/۴۴۲	۰/۴۱۲	۰/۶۴۵	۰/۶۵۶	۰/۴۵۷	۰/۴۳۱	۰/۶۲۶

جدول ۴ - نتایج آماری داده های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل ANFIS

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
جوسدان	۴	۰/۶۲۹	۱/۸۵۶	۱/۸۰۲	۰/۵۹۱	۰/۶۱۳	۱/۸۷۴	۱/۸۱۳	۰/۵۷۸
	۳	۰/۶۲۴	۱/۸۵۹	۱/۸۰۷	۰/۵۸۷	۰/۶۰۹	۱/۸۷۸	۱/۸۲۲	۰/۵۷۴
	۲	۰/۶۱۹	۱/۸۶۴	۱/۸۱۳	۰/۵۸۳	۰/۶۰۳	۱/۸۷۹	۱/۸۳۲	۰/۵۶۹
	۱	۰/۶۱۳	۱/۸۶۸	۱/۸۱۷	۰/۵۷۹	۰/۵۹۸	۱/۸۸۳	۱/۸۳۸	۰/۵۶۱
مهران جوسدان	۴	۰/۶۲۸	۰/۷۸۳	۰/۶۹۹	۰/۵۸۹	۰/۶۱۲	۰/۸۰۲	۰/۷۳۲	۰/۵۷۷
	۳	۰/۶۲۳	۰/۷۹۱	۰/۶۹۹	۰/۵۸۶	۰/۶۰۸	۰/۸۰۹	۰/۷۳۵	۰/۵۷۳
	۲	۰/۶۱۸	۰/۷۹۴	۰/۷۰۴	۰/۵۸۲	۰/۶۰۲	۰/۸۱۲	۰/۷۳۹	۰/۵۶۸
	۱	۰/۶۱۲	۰/۷۹۸	۰/۷۰۸	۰/۵۷۷	۰/۵۹۷	۰/۸۱۴	۰/۷۴۴	۰/۵۵۹
علیزان جوسدان	۴	۰/۶۲۷	۰/۶۵۶	۰/۵۹۳	۰/۵۸۸	۰/۶۱۱	۰/۶۸۳	۰/۵۹۴	۰/۵۷۶
	۳	۰/۶۲۲	۰/۶۵۹	۰/۵۹۵	۰/۵۸۵	۰/۶۰۷	۰/۶۸۴	۰/۵۹۹	۰/۵۷۲
	۲	۰/۶۱۷	۰/۶۶۲	۰/۵۹۹	۰/۵۸۱	۰/۶۰۱	۰/۶۹۳	۰/۶۰۴	۰/۵۶۶
	۱	۰/۶۱۱	۰/۶۶۴	۰/۶۰۱	۰/۵۷۶	۰/۵۹۶	۰/۶۹۹	۰/۶۱۳	۰/۵۵۸
گتده	۴	۰/۶۲۵	۰/۶۶۸	۰/۶۰۴	۰/۵۸۷	۰/۶۰۹	۰/۷۰۲	۰/۶۱۷	۰/۵۷۵
	۳	۰/۶۲۱	۰/۶۷۱	۰/۶۱۳	۰/۵۸۴	۰/۶۰۶	۰/۷۰۵	۰/۶۱۹	۰/۵۷۱
	۲	۰/۶۱۶	۰/۶۷۴	۰/۶۱۷	۰/۵۸۱	۰/۶۰۱	۰/۷۰۸	۰/۶۲۴	۰/۵۶۵
	۱	۰/۶۱۱	۰/۶۸۳	۰/۶۲۱	۰/۵۷۳	۰/۵۹۸	۰/۷۱۲	۰/۶۳۱	۰/۵۵۷
دهدر	۴	۰/۶۲۴	۰/۴۵۶	۰/۴۱۳	۰/۵۸۶	۰/۶۰۸	۰/۴۷۱	۰/۴۲۸	۰/۵۷۴
	۳	۰/۶۱۹	۰/۴۶۱	۰/۴۲۴	۰/۵۸۳	۰/۶۰۵	۰/۴۷۴	۰/۴۳۱	۰/۵۶۹
	۲	۰/۶۱۵	۰/۴۶۳	۰/۴۳۱	۰/۵۷۹	۰/۵۹۹	۰/۴۸۱	۰/۴۴۳	۰/۵۶۴
	۱	۰/۶۰۹	۰/۴۷۱	۰/۴۳۸	۰/۵۷۲	۰/۵۹۷	۰/۴۸۵	۰/۴۵۲	۰/۵۵۶

با توجه به شکل ۵ و بررسی نمودار خط همبستگی میان مقادیر پیش‌بینی‌شده و مشاهده‌ای در سه مدل TFT، GEP و ANFIS نشان می‌دهد که رفتار مدل‌های مورد بررسی از نظر میزان نزدیکی نقاط به خط نیمساز تفاوت زیادی دارد. در مدل TFT، الگوی پراکندگی داده‌ها کاملاً منظم و منسجم بوده و تقریباً تمامی نقاط در مجاورت مستقیم خط همبستگی کامل قرار گرفته‌اند. این رفتار نشان‌دهنده توانایی بالای مدل در بازسازی دقیق مقادیر واقعی و انطباق مناسب میان روند و دامنه تغییرات جریان است. شیب خط رگرسیون و تقاطع آن با محورهای مختصات در این مدل تقریباً با خط نیمساز منطبق است و مقدار همبستگی بسیار بالا نشان می‌دهد که مدل TFT به‌صورت پایدار در برآورد برهم‌کنش‌های زمانی و ساختار غیرخطی داده‌های هیدرولوژیکی موفق عمل کرده است. قرارگیری متراکم نقاط در محدوده نزدیک به خط نیمساز به معنای خطای بسیار پایین و عدم وجود ناهماهنگی قابل‌توجه در خروجی‌ها است. این ویژگی در مدل‌های کلاسیک به‌ندرت مشاهده می‌شود و مهم‌ترین تفاوت مدل‌های ترنسفورمر و کلاسیک به‌شمار می‌آید. در همین راستا، (Burrichter et al, 2024) نشان دادند که مدل TFT در پیش‌بینی سری‌های زمانی هیدرولوژیکی، به‌ویژه در مقیاس‌های زمانی بلندتر، هم‌راستایی بسیار بالاتری با داده‌های مشاهده‌ای نسبت به مدل‌های کلاسیک از خود نشان می‌دهد. در مدل GEP میزان پراکندگی نقطه‌ها نسبت به مدل TFT بیشتر است و نقاط در محدوده‌ای گسترده‌تر پیرامون خط همبستگی قرار گرفته‌اند. مقدار همبستگی این مدل که معمولاً بین ۰/۶۴ تا ۰/۶۶

ثبت شده، نشان‌دهنده قدرت متوسط مدل در بازتولید روندهای واقعی است. هر چند GEP تا حدی توانسته الگوی کلی تغییرات را دنبال کند اما فاصله قابل توجه نقاط از خط نیمساز، بیانگر وجود خطاهای پراکنده و همچنین ناتوانی مدل در شناسایی بخش‌هایی از رفتارهای ناگهانی و نوسانی جریان است. ناتوانی مدل GEP در شناسایی الگوی تغییرات و وجود خطاهای پراکنده طبیعی است زیرا ساختار مبتنی بر تکامل ژنتیکی و تولید روابط تحلیلی ساده، توانایی محدودی در استخراج وابستگی‌های پیچیده زمانی دارد و نسبت به مدل‌های مبتنی بر سازوکار توجه، قدرت کمتری در هم‌راستا کردن پیش‌بینی با مقدار واقعی را داراست. نتایج بدست آمده با یافته‌های Terzi & Özcanoglu, (2017) و Kontouni et al, (2022) هم‌خوانی دارد. به گونه‌ای که این مطالعات نیز گزارش کرده‌اند مدل‌های مبتنی بر GEP، علی‌رغم توانایی تولید روابط تحلیلی قابل تفسیر، در استخراج وابستگی‌های پیچیده زمانی و دینامیک‌های غیرخطی شدید با محدودیت مواجه‌اند. در مدل ANFIS نیز پراکندگی بیشتری نسبت به GEP مشاهده می‌شود و نقاط فاصله قابل توجهی از خط همبستگی کامل دارند. مقدار همبستگی این مدل نیز عمدتاً در محدوده ۰/۵۷ تا ۰/۵۹ قرار دارد که نشان‌دهنده ضعف مدل در بازسازی دقیق رفتار جریان در دامنه‌های تغییرات است. الگوی مشاهده‌شده در نمودار همبستگی مدل ANFIS نشان می‌دهد که این مدل گرایش بیشتری به ایجاد خطاهای سیستماتیک دارد. این امر در بازه‌هایی که داده‌ها نوسانات شدید یا رفتار غیرفصلی از خود نشان داده‌اند، بیش‌تر دیده می‌شود. ساختار فازی عصبی مدل ANFIS در مواجهه با داده‌های پیچیده و دارای سیگنال بالا معمولاً دچار کاهش دقت می‌شود و پراکندگی گسترده‌تر نقاط پیرامون خط نیمساز نشان‌دهنده این محدودیت است. این موضوع با نتایج مطالعات پیشین نیز هم‌راستا است؛ به طوری که Vakili & Mousavi, (2022) و Mastouri et al, (2021) گزارش کرده‌اند عملکرد ANFIS در مواجهه با داده‌های پیچیده و دارای سیگنال بالا به شدت وابسته به ساختار فازی و نحوه تنظیم توابع عضویت بوده و در بسیاری از موارد منجر به کاهش دقت و افزایش پراکندگی پیش‌بینی‌ها می‌شود.



شکل ۵- نمودار مقایسه همبستگی مدل‌ها

نتیجه گیری

پژوهش حاضر نشان داد که بهره‌گیری از مدل‌های نوین داده‌محور به‌ویژه معماری‌های مبتنی بر ترنسفورمر، گامی مهم در ارتقاء دقت پیش‌بینی‌های هیدرولوژیکی و مدیریت جریان‌های اوج در حوضه‌های کوهستانی می‌باشد. مقایسه سه مدل TFT، ANFIS و GEP در پیش‌بینی دبی بیشینه ماهانه حوزه آبخیز طالقان نشان داد که تفاوت میان نسل جدید مدل‌های یادگیری عمیق و مدل‌های محاسبات نرم به مراتب چشم‌گیرتر از آن است که در مطالعات پیشین مطرح شده است. مدل TFT با بهره‌گیری از سازوکار توجه، ساختار رمزگذار رمزگشا و شبکه‌های انتخاب متغیر، وابستگی‌های بلندمدت و الگوهای ناپایدار جریان را با دقتی بسیار بالا بازسازی کرده و در تمامی ایستگاه‌ها و دوره‌های زمانی ورودی، بهترین عملکرد را ارائه داد. نوآوری پژوهش حاضر ماهیتی کاربردی و مقایسه‌ای دارد و هدف آن توسعه یک مدل جدید یا اصلاح ساختار معماری‌های موجود نبوده است. ارزش افزوده اصلی این مطالعه در ارائه یک مقایسه منسجم میان مدل‌های نسل جدید مبتنی بر ترنسفورمر و مدل‌های متداول داده‌محور در پیش‌بینی دبی بیشینه روزانه نهفته است. نتایج این مقایسه نشان می‌دهد که انتخاب نوع مدل، به‌ویژه در سری‌های زمانی بلندمدت و داده‌های نوفه‌دار، تأثیر تعیین‌کننده‌ای بر دقت پیش‌بینی دارد و استفاده از معماری‌های مبتنی بر توجه می‌تواند به‌طور معناداری کیفیت شبیه‌سازی سیلاب را بهبود بخشد. ثبت مقادیر NSE بالاتر از ۰/۹۷ و RMSE کمتر از ۰/۱ در اکثر موقعیت‌ها نشان‌دهنده توانایی این مدل در بازنمایی پیچیدگی‌های هیدرولوژیکی و کاهش خطاهای سیستماتیک است؛ موضوعی که در مدل‌های کلاسیک‌تر کمتر مشاهده می‌شود. در مقایسه با مدل TFT، مدل GEP اگرچه در جایگاه دوم قرار گرفت و نسبت به مدل ANFIS پایداری بیشتری نشان داد اما فاصله معناداری با مدل ترنسفورمر داشت. ساختار تکاملی مدل GEP امکان تولید روابط تحلیلی ساده و کاربردی را فراهم کرد و در برخی دوره‌های بلندمدت عملکرد نسبتاً مناسبی ارائه داد اما عدم برخورداری از ابزارهای یادگیری عمیق و فقدان سازوکارهای توجه سبب شد که مدل، موفق به شناسایی رفتارهای پیچیده، ناگهانی و وابستگی‌های زمانی دوربرد نشود. مدل ANFIS نیز با وجود توانایی محدود در مدل‌سازی روابط غیرخطی در میان سه مدل ضعیف‌ترین عملکرد را ثبت کرد و بیش از سایر مدل‌ها تحت تأثیر نویز، ناپایداری‌های فصلی و نوسان‌های آماری قرار گرفت. از آنجا که تحلیل شاخص‌ها، نمودارهای پراکنش و الگوهای فصلی در تمامی ایستگاه‌ها نشان داد که عملکرد مدل TFT در افزایش دقت، کاهش خطا و بازتولید ساختار زمانی جریان، برتری چشمگیری دارد، می‌توان نتیجه گرفت که استفاده از مدل‌های مبتنی بر ترنسفورمر در هیدرولوژی یکی از امیدوارکننده‌ترین مسیرهای توسعه آینده است. قدرت مدل TFT در یادگیری هم‌زمان الگوهای کوتاه‌مدت و بلندمدت و تفسیرپذیری بالای خروجی‌ها، مدل را به گزینه‌ای مناسب به‌منظور پیش‌بینی سیلاب، تحلیل خشکسالی و برنامه‌ریزی منابع آب تبدیل می‌کند. با توجه به دقت بالای مدل TFT در پیش‌بینی دبی بیشینه روزانه، نتایج این پژوهش نشان می‌دهد که این مدل می‌تواند در کاربردهای عملی مختلف مدیریت سیلاب مورد استفاده قرار گیرد. از جمله مهم‌ترین این کاربردها می‌توان به سیستم‌های هشدار زود هنگام سیل اشاره کرد که در آن پیش‌بینی دقیق دبی‌های اوج نقش کلیدی در کاهش خسارات جانی و مالی دارد. علاوه بر این، خروجی‌های مدل TFT می‌تواند به‌عنوان ورودی قابل‌اعتماد در طراحی و ارزیابی سازه‌های کنترلی سیلاب نظیر سدها، بندهای انحرافی و سازه‌های حفاظتی رودخانه‌ای مورد استفاده قرار گیرند. در حوضه مدیریت و بهره‌برداری مخازن نیز، پیش‌بینی دقیق جریان‌های اوج امکان اتخاذ تصمیمات بهینه در خصوص رهاسازی آب و کنترل تراز مخزن را فراهم می‌سازد. در نهایت، به‌دلیل پایداری عملکرد مدل TFT در افق‌های زمانی مختلف، این مدل می‌تواند به‌عنوان ابزاری کارآمد در برنامه‌ریزی بلندمدت منابع آب و مدیریت ریسک سیلاب در حوضه‌های کوهستانی مورد توجه قرار گیرد. نتایج پژوهش حاضر روشن ساخت که برای تحلیل‌های مبتنی بر سری‌های زمانی بلندمدت و تغییرپذیری‌های پیچیده هیدرولوژیکی، مدل‌های نسل جدید مانند TFT قادر به ایجاد تحول قابل توجهی در کیفیت پیش‌بینی هستند. بنابراین، پیشنهاد می‌شود پژوهش‌های آینده به توسعه مدل‌های ترکیبی، استفاده از داده‌های چندحسی مانند بارش راداری یا داده‌های سنجش از دور و بررسی عملکرد مدل TFT در پیش‌بینی رخداد‌های حدی اقلیمی مانند سیلاب‌های ناگهانی بپردازند. تلفیق مدل‌های ترنسفورمر با روش‌های کلاسیک‌تر نیز می‌تواند به بهبود تفسیرپذیری و افزایش پایداری مدل‌ها در شرایط کم‌داده کمک کند.

منابع

- Ahmadian AhmadAbad,G., Zakeri Niri,M., 2021. Simulation and comparison of runoff estimation by neural network methods, regression and fuzzy inference(A case study:Dez catchment). *Nivar*, 45(114-115), 92-105(in persian). doi: 10.30467/nivar.2022.290750.1196.
- Burrichter, B., Koltermann da Silva, J., Niemann, A., Quirmbach, M., 2024. A Temporal Fusion Transformer Model to Forecast Overflow from Sewer Manholes during Pluvial Flash Flood Events. *Hydrology*, 11(3), 41. <https://doi.org/10.3390/hydrology11030041>
- Dehghani, N., Vafakhah, M., Bahremand, A., 2016. Rainfall-Runoff Modeling using Artificial Neural Network and Neuro-Fuzzy Inference System in Kasilian Watershed. *J Watershed Manage Res.* 7(13), 137-128(in persian).
- Ebrahimi, A., Roozbahani, A., Bani habib, M.A., 2018. Groundwater Level Prediction Using Dynamic Bayesian Networks Based on Sensitivity Analysis (Case Study: Birjand Plain). *Iranian Water*, 12(2), 91-100. (In Persian)
- Francisco, R., Matos, L.P., Marinho, R., Lopes, N., Portela, M.M., Barros, P., 2025. Application of Temporal Fusion Transformers to Run-Of-The-River Hydropower Scheduling. *Hydrology*, 12(81). <https://doi.org/10.3390/hydrology12040081>
- Gauch, M., Lin, J., 2020. A Data Scientist's Guide to Streamflow Prediction. [arXiv:2006.12975v1](https://arxiv.org/abs/2006.12975)
- Jang, J. S. R., 1993. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665–685.
- Ji, W., Cao, Z., Li, X., 2023. Multi-Task Learning and Temporal-Fusion-Transformer-Based Forecasting of Building Power Consumption. *Electronics*, 12, 4656. <https://doi.org/10.3390/electronics12224656>
- Kavoosi,M., khozehmehnezhad,H., 2021. Review and compare performance of 4 modeling methods LS-SVM, NN, GEP and ANFIS-PSO in Simulation of Rainfall - Runoff (Study Area: Halil River - Jiroft Dam). *Irrigation and Water Engineering*, 11(3), 96-110. doi: 10.22125/iwe.2021.128115
- Kontoni, D.-P. N., Onyelowe, K. C., Ebid, A. M., Jahangir, H., Rezazadeh Eidgahee, D., Soleymani, A., Ikpa, C., 2022. Gene Expression Programming (GEP) Modelling of Sustainable Building Materials including Mineral Admixtures for Novel Solutions. *Mining*, 2(4), 629-653. <https://doi.org/10.3390/mining2040034>
- Lim, B., OArik, S., Loeff, N., Pfister, T., 2020. Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting. [arXiv:1912.09363v3](https://arxiv.org/abs/1912.09363)
- Mastouri, R., Najarchi, M., Torabi, S.A., 2022. Application of group experimental mode decomposition algorithm to improve the accuracy of daily river flow prediction using artificial intelligence methods, *Iranian Water Research Journal*, 16(45), 1-14(in persian). magiran.com/p2469788
- Nash, J.E., Sutcliffe, J.V., 1970. River flow forecasting through conceptual models part I: A discussion of principles. *Journal of Hydrology*, 10(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Pornemat Roudsari, A., Ghaderi, K., Karimi Ghohari, SH., 2015. Rainfall Runoff Modeling using Group Method of Data Handling (GMDH) and Artificial Neural Network (ANN) IN In Polrood Basin. *J Watershed Manage Res.* 5(10), 68-84(in persian).
- Rasiaya Koya, S., Roy, T., 2023. Temporal Fusion Transformers for Streamflow Prediction: Value of Combining Attention with Recurrence. <https://doi.org/10.48550/arXiv.2305.12335>
- R.Koza, J., 1992. Genetic Programming as a Means for Programming Computers by Natural Selection. ISBN: 9780262527910
- Salari Jozi, M., Ghorbani, KH., Sohrabian, E., Abdolhoseini, M., 2017. Daily River Flow Forecasting Using Data-Driven Models. *Iranian Journal of Irrigation and Drainage*, 4(10), 479-488(in persian).
- Terzi, Ö., Özcanoglu, O., 2017. STREAMFLOW ESTIMATION OF GÖKSU RIVER WITH GENE EXPRESSION PROGRAMMING. *Journal of Engineering Sciences and Design*, 5(3), 483-488. <https://doi.org/10.21923/jesd.330479>
- Vakili, SH., Mousavi, M., 2022. Rainfall–runoff modeling using adaptive neuro-fuzzy inference system (ANFIS) and genetic algorithm (GA). *Watter Supply*, 20(10), 7460-7475. DOI:[10.2166/ws.2022.318](https://doi.org/10.2166/ws.2022.318)
- Jamalvand, A., Yaghoubi, B., Izadbakh, M.A., Shabanlou, S., 2021. Optimization of ANFIS Network to Simulate Long Term Rainfall in Babolsar City. *Iranian Journal of Soil and Water research*, 52(8), 2111-2123(in persian). DOI:[10.22059/ijswr.2021.323558.668970](https://doi.org/10.22059/ijswr.2021.323558.668970)