

## بررسی عدم قطعیت مدل‌های هوش مصنوعی در برآورد جریان رودخانه (مطالعه موردی: رودخانه کارون)

یاسر مهدی زاده زارع اناری<sup>۱</sup>، محمد نجف زاده<sup>۱</sup>، صدیقه انوری<sup>۲\*</sup>

۱- دانشکده مهندسی عمران و نقشه برداری، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران  
۲- پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران

### تاریخچه داوری:

دریافت: ۱۴۰۰/۱۲/۲۱  
بازنگری: ۱۴۰۱/۰۴/۰۶  
پذیرش: ۱۴۰۱/۰۴/۲۰  
ارائه آنلاین: ۱۴۰۱/۰۵/۱۸

### کلمات کلیدی:

پیش‌بینی جریان  
مدل‌های هوش مصنوعی  
تحلیل عدم قطعیت  
رویکرد مونت کارلو

**خلاصه:** پیش‌بینی دقیق فرآیندهای هیدرولوژیکی و احتساب عدم قطعیت‌های آن‌ها، از جمله چالش‌های اساسی در حوضه مدیریت منابع آب است. هدف مقاله حاضر، پیش‌بینی جریان ماهانه رودخانه کارون در محل ایستگاه هیدرومتری ارمند با استفاده از روش‌های هوش مصنوعی (AI) می‌باشد. به کارگیری رویکرد شبیه‌سازی مونت کارلو (MCS) جهت احتساب عدم قطعیت پیش‌بینی‌های نام برده و نیز مقایسه عملکرد آن‌ها از اهداف دیگر مقاله محسوب می‌شود. بدین منظور از مدل‌های مبتنی بر AI شامل برنامه‌نویسی بیان ژن (GEP)، اسپیلاین رگرسیون تطبیقی چند متغیره (MARS) و درخت مدل (MT) استفاده شده است. همچنین آمار ۲۸ ساله جریان رودخانه کارون (سال‌های ۱۳۶۰-۱۳۸۷) استفاده و برای تولید اعداد تصادفی، روش پارامتریک توماس-فیرینگ (TF) به کار گرفته شد. نتایج ارزیابی عملکرد مدل‌ها با شاخص‌هایی همچون ضریب همبستگی (R)، میانگین قدر مطلق خطا (MAE) و ریشه میانگین مربعات خطا (RMSE)، نشان داد که مدل MT در هر دو مرحله آموزش و آزمایش عملکرد بهتری نسبت به سایرین داشته است. شاخص‌های دقت مدل برای مرحله آموزش مدل MT برابر  $R=0/841$  و  $RMSE=36/789 \text{ m}^3/\text{s}$  بوده است در حالی که این شاخص‌ها برای مرحله آزمایش برابر با  $R=0/87$  و  $RMSE=44/253 \text{ m}^3/\text{s}$  می‌باشد. نتایج ارزیابی عدم قطعیت پیش‌بینی‌ها توسط مدل‌های GEP، MARS و MT نشان داد که مدل MT با داشتن شاخص  $R\text{-factor}=1/67$  و  $95\text{PPU}=55/5\%$  بهترین عملکرد را برای احتساب عدم قطعیت داشته است.

### ۱- مقدمه

$(ARIMA)$ ، نزدیک‌ترین همسایگی<sup>۵</sup> (K-NN) می‌باشند، قادر به شبیه‌سازی جریان رودخانه می‌باشند [۳-۱]. در مدل‌های آماری مذکور، متغیرهای وابسته به زمان باید دارای سری‌های زمانی کامل و جامعی باشند تا نتایج پیش‌بینی در سطح قابل اعتمادی باقی بماند. بر این اساس، عملکرد مدل‌های سری زمانی دارای پتانسیل پایینی برای پیش‌بینی جریان می‌باشد مخصوصاً هنگامی که اطلاعات سری زمانی جریان رودخانه ناقص باشند [۴]. با ظهور مدل‌های هوش مصنوعی داده محور، طیف گسترده‌ای از تکنیک‌های هوش مصنوعی (AI)<sup>۶</sup> برای پیش‌بینی جریان رودخانه‌ها استفاده شد. روش‌های هوش مصنوعی ظرفیت کافی برای شناسایی الگوهای پنهان در سری‌های زمانی را نشان داده‌اند و در مقایسه با روش‌های آماری قابلیت اطمینان بالایی را به اثبات رسانده‌اند [۷-۵].

رشد جمعیت و افزایش تقاضا برای آب و فرآورده‌های غذایی از یک طرف، همچنین محدودیت منابع آب شیرین قابل دسترس و توزیع ناهمگون مکانی و زمانی آن‌ها، مدیریت منابع آب را بیش از پیش ضروری ساخته است. در این راستا ارتقاء دقت پیش‌بینی‌های جریان رودخانه و احتساب عدم قطعیت‌های آن نقش کلیدی در مدیریت هر چه بهتر منابع آب ایفا می‌کند. روش‌های مدل‌سازی جریان رودخانه‌ها در حالت کلی به دو دسته مدل‌های مفهومی<sup>۱</sup> (بر مبنای روش‌های آماری) و مدل‌های داده محور<sup>۲</sup> تقسیم‌بندی می‌شوند. مدل‌های مفهومی که عموماً به صورت سری‌های زمانی شامل مدل خود همبسته<sup>۳</sup> (AR)، مدل خودهمبسته‌ی میانگین-متحرک<sup>۴</sup> (ARMA)، مدل میانگین متحرک خودهمبسته‌ی یکپارچه

- 1 Conceptual models
- 2 Data Driven Models
- 3 Auto-Regressive
- 4 Auto Regressive Moving Average

\* نویسنده عهده‌دار مکاتبات: s.anvari@kgut.ac.ir

- 5 Auto Regressive Moving Integrated Average
- 6 K-Nearest Neighborhood
- 7 Artificial intelligence



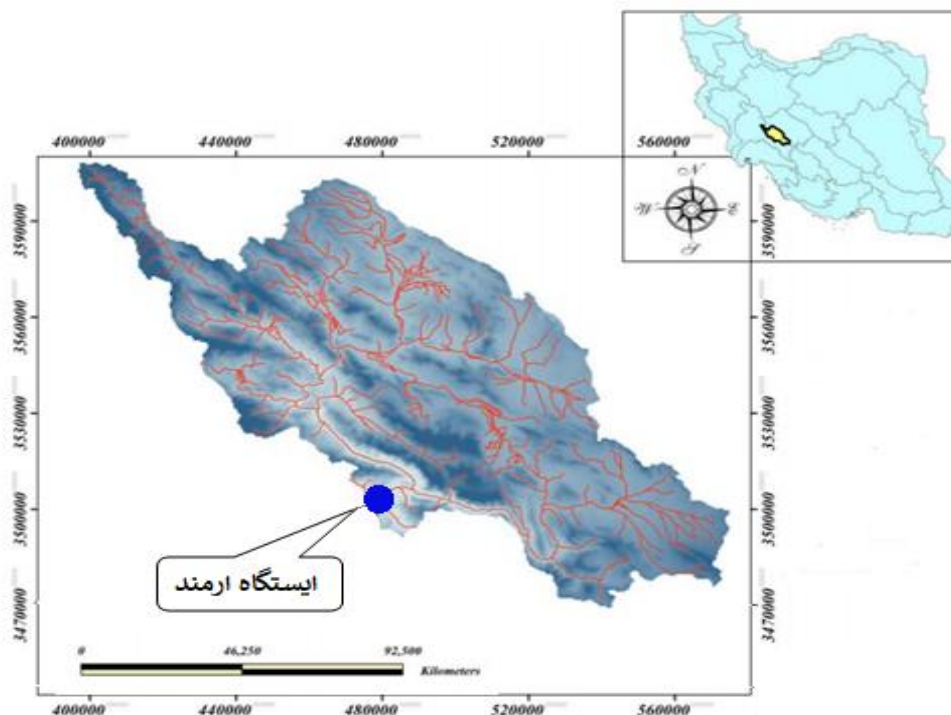
موجک برنامه‌نویسی بیان ژن (WGEP)<sup>9</sup> و موجک درخت (WM5P) استفاده کردند، نتایج نشان داد که مدل‌های هوش مصنوعی ترکیبی، عملکرد بهتری نسبت به مدل‌های مستقل دارند و برای هر دو حوضه مورد مطالعه، عملکرد مدل WM5P به خصوص برای رویدادهای شدید بهتر از WGEP است [۷]. Adnan و همکاران (۲۰۲۱) برای برآورد جریان ماهانه ایستگاه‌های Kalam و Chakdara واقع بر حوضه رودخانه Swat، از روش دسته‌بندی گروهی داده‌ها- شبکه عصبی (GMDH-NN)<sup>10</sup>، سیستم استنتاج عصبی فازی تکاملی پویا (DENFIS)<sup>11</sup> و رگرسیون اسپلاین تطبیقی چند متغیره (MARS)<sup>12</sup> استفاده گردید. نتایج نشان داد که برای دو ایستگاه نام برده به ترتیب مدل‌های DENFIS و MARS بهترین عملکردها را داشته‌اند [۱۱].

تحقیقات نام برده و نیز سایر بررسی‌های به عمل آمده در زمینه پیش‌بینی‌های جریان رودخانه نشان می‌دهد هر چند مدل‌های AI در دهه‌های اخیر کاربردهای موفقیت آمیزی در زمینه پیش‌بینی جریان داشته است با این حال همانند سایر مدل‌های هیدرولوژیکی فیزیک پایه، دارای عدم قطعیت‌های فراوانی بوده که عمدتاً از فاکتورهای اقلیمی-هیدرولوژیکی حوضه آبریز نشأت می‌گیرند. بنابراین ملاحظه و کمی کردن عدم قطعیت‌های مرتبط با این فاکتورها برای بهبود نتایج پیش‌بینی و در نهایت مدیریت هر چه بهتر منابع آب امری ضروریست [۱۶-۱۲]. بدین منظور در تحقیق دیگر از مدل‌های رگرسیون بردار پشتیبان (SVR)<sup>۱۳</sup> و رگرسیون خطی چندگانه (MLR)<sup>۱۴</sup> برای پیش‌بینی جریان ورودی به سد بوکان استفاده گردید. همچنین از سه رویکرد جنگل تصادفی (RF)<sup>۱۵</sup>، رمزگذار خودکار عمیق (DAE)<sup>۱۶</sup> و روش آنالیز مولفه‌های اصلی (PCA) جهت پیش‌پردازش متغیرهای ورودی استفاده شد. نتایج نشان داد که مدل‌های DAE-SVR و RF-SVR در مقایسه با مدل‌های هیبریدی PCA-MLR، RF-MLR، DAE-MLR، PCA-SVR، بهبود قابل توجهی در دقت پیش‌بینی یک ماه بعد جریان داشته است. آنالیز عدم قطعیت پیش‌بینی‌های جریان در سطح اطمینان ۹۵ نیز حاکی از برتری DAE-SVR داشته است [۱۷]. در تحقیقی دیگر با ارائه ساختار بهینه مدل ANN توسط نسخه

Ghavidel و Montaseri (۲۰۱۴) عملکرد مدل‌های برنامه‌نویسی بیان ژن (GEP)<sup>1</sup> و ANFIS<sup>2</sup> را در پیش‌بینی جریان ماهانه رودخانه مورد بررسی قرار دادند. ایشان از داده‌های دبی ماهانه سال‌های ۱۳۷۰ تا ۱۳۹۰ مربوط به ایستگاه‌های صفاخانه و سنته واقع در حوضه آبریز زرینه‌رود استفاده کردند. مقادیر دبی با تأخیرهای زمانی یک تا سه ماه و همچنین شماره ماه‌ها برای تعیین اثرات تناوبی و فصلی جریان‌های ماهانه در فرآیند پیش‌بینی به مدل‌ها اضافه گردید. نتایج نشان داد که مدل GEP دارای عملکرد و دقت بهتری نسبت به ANFIS بوده است و همچنین در نظر گرفتن شماره ماه‌ها نیز دقت مدل‌سازی را افزایش می‌دهد [۸]. در تحقیقی دیگر Noori و همکاران (۲۰۱۱) با استفاده از مدل ماشین بردار پشتیبان (SVM)<sup>۳</sup> و سه روش استخراج متغیرهای ورودی شامل انتخاب پیشرو، آزمایش گاما (GT)<sup>۴</sup> و آنالیز مولفه اصلی (PCA)<sup>۵</sup> جریان رودخانه را پیش‌بینی کردند. نتایج نشان داد که سطح دقت مدل SVM با استفاده از مدل‌های پیش‌پردازش مذکور افزایش یافت [۵]. در تحقیقی دیگر Saghafian و همکاران (۲۰۱۳) با استفاده از مدل‌های شبکه عصبی مصنوعی (ANN)<sup>۶</sup>، ANFIS و K-NN جریان یک تا سه ماه بعد رودخانه کارون (ایستگاه پل شالو بالادست سد کارون ۳) را پیش‌بینی کردند. همچنین تاثیر داده‌های توزیع مکانی اقلیمی و شاخص بزرگ مقیاس SOI<sup>۷</sup> بر دقت نتایج پیش‌بینی بررسی شد. نتایج نشان داد که استفاده از داده‌های مکانی موجب به جای داده‌های ایستگاهی، دقت پیش‌بینی‌ها را افزایش داده است. شاخص SOI نیز عملکرد مدل‌های نام برده را ارتقاء داده است [۹]. در تحقیقی دیگر برای پیش‌بینی جریان ماهانه رودخانه شاور (ایران) از مدل هیبریدی الگوریتم وراثتی (GA)<sup>۸</sup> با برنامه‌نویسی بیان ژن (GEP) موسوم به GEP-GA استفاده گردید. در نهایت، عملکرد GEP-GA با مدل‌های کلاسیک برنامه‌ریزی ژنتیکی ((GEP، GP)، رگرسیون خطی چندگانه و مدل‌های رگرسیون خطی GEP مقایسه گردید. نتایج نشان داد که مدل هیبریدی پیشنهاد شده (GEP-GA) نسبت به سایر مدل‌ها عملکرد بهتری داشته است [۱۰]. Azarpira و Shahabi (۲۰۲۱) برای پیش‌بینی جریان ماهانه رودخانه‌های خشک‌رود و پل‌رود، از مدل‌های ترکیبی

9 Wavelet-Gene Expression Programming  
10 Group Method of Data Handling-Neural Networks  
11 Dynamic Evolving Neural-Fuzzy Inference System  
12 Multivariate Adaptive Regression Spline  
13 Support Vector Regression  
14 Multiple Linear Regression  
15 Random Forest  
16 Deep Auto- Encoder

1 Gene Expression Programming  
2 Adaptive Neuro-fuzzy Inference System  
3 Support Vector Machine  
4 Gamma Test  
5 Principal Component Analysis  
6 Artificial Neural Network  
7 Southern Oscillation Index  
8 Genetic Algorithm



شکل ۱. نقشه منطقه مطالعاتی در بین حوضه‌های درجه دو کشور و موقعیت ایستگاه هیدرومتری ارمند [۱۹]

Fig. 1. Map of the study area among the 2nd order sub-basins of Iran and the location of Armand hydrometric station [19]

ضمن پیش‌بینی جریان این رودخانه (در محل ایستگاه هیدرومتری ارمند)، عدم قطعیت این پیش‌بینی‌ها را با استفاده از روش مونت کارلو بررسی نماید.

## ۲- مواد و روش‌ها



### ۲-۱- منطقه مورد مطالعه

حوضه آبریز رودخانه کارون بزرگ واقع در جنوب غربی ایران، بین طول‌های  $30^{\circ} 30'$  تا  $49^{\circ} 52'$  شرقی و عرض‌های  $30^{\circ} 30'$  تا  $32^{\circ}$  شمالی ایران قرار گرفته است. این حوضه، دارای مساحت تقریبی ۶۷۲۵۷ کیلومتر مربع بوده و در برگیرنده رودخانه دائمی کارون با طول ۸۹۰ کیلومتر و میانگین آبدهی سالانه ۱۸۷۰۰ میلیون مترمکعب می‌باشد. در این تحقیق، حوضه رودخانه کارون تا محل ایستگاه هیدرومتری ارمند مورد بررسی قرار گرفته است. این ایستگاه (مطابق شکل ۱) در نزدیکی سد کارون ۴ با ارتفاع تقریبی ۱۰۸۲ متر قرار گرفته است و طول و عرض جغرافیایی آن به ترتیب برابر ۴۶-۵۰ و ۳۱-۴۰ می‌باشد. حوضه بالادست این سد دارای مساحت ۱۱۰۰۰ کیلومتر مربع بوده و میانگین آبدهی سالانه آن ۱۱۰ مترمکعب بر ثانیه است. میانگین بارندگی سالانه این حوضه تقریباً ۷۵۰ میلی‌متر، حداکثر و حداقل ارتفاع آن از سطح آب‌های آزاد به ترتیب برابر ۴۱۴۱ و ۱۰۴۴ متر می‌باشد.

باینری بهبود یافته الگوریتم‌ساز جستجوی گرانشی (IBGSA)، عدم قطعیت‌های متغیرهای دما و دبی را در پیش‌بینی جریان رودخانه کارون (محل ایستگاه پل شالو) را بررسی و باندهای عدم قطعیت پیش‌بینی یک ماه بعد جریان محاسبه گردید [۱۸].

مدل GEP در واقع نسل سوم از الگوریتم وراثتی (GA) است. از این رو الگوریتم GEP با غلبه بر محدودیت نقش دوگانه کروموزوم‌ها در الگوریتم‌های پیش از خود (GP, GA)، امکان عملگرهای متعدد وراثتی را با ضمانت سلامت همیشگی کروموزوم‌های فرزند فراهم می‌سازد و با سرعتی بیش از GP به دلیل تنوع ساختاری بالاتر از GA فضای پاسخ‌های ممکن را به صورت کامل‌تری جستجو می‌کند. مدل MT نیز نسبت به مدل درخت تصمیم از مباحث جامع‌تر و عمومی‌تر استفاده می‌کند و امکان ساخت درخت تصمیم را از هر مدل انتخابی فراهم می‌کند. با توجه به برتری عملکرد مدل‌های هوش مصنوعی MARS، GEP و MT در قیاس با سایر مدل‌های AI، تاکنون تحقیقی توسط این مدل‌ها جهت پیش‌بینی جریان رودخانه کارون انجام نشده است. لذا هدف اصلی تحقیق حاضر آن است تا

1 Improved Binary Version of Gravitational Search Algorithm



شکل ۲-الف. نمودار تغییرات جریان روزانه ایستگاه ارمند، (ب) نمودار جعبه‌ای تغییرات ماهانه دبی ایستگاه ارمند

Fig. 2-(a). Variations of daily streamflow at Armand hydrometric station, (b). Box polot of monthly discharge of Armand station

و پیچیده بین آن‌ها را مدل کند [۲۰ و ۲۱]. معادله کلی MARS بدین صورت است:

$$y' = a_0 + \sum_{m=1}^M a_m BF_m(X) \quad (1)$$

که در آن  $a_0$  جمله ثابت،  $y'$  برآوردی از متغیر وابسته و به صورت تابعی از متغیرهای مستقل  $X$ ، ضریب مربوط به تابع پایه  $m$  ام،  $M$  تعداد گره‌ها یا توابع پایه غیر ثابت می‌باشند و  $BF_m(X)$  تابع پایه  $m$  ام که از رابطه زیر محاسبه می‌شود:

$$BF_m(X) = \prod_{i=1}^{K_m} \left[ S_{i,m} \left( X_{v(i,m)} - t_{i,m} \right) \right]_+^q \quad (2)$$

که در آن  $S_{i,m}$  برابر با  $\pm 1$ ،  $K_m$  درجه تعامل بین متغیرها در تابع پایه  $m$  ام،  $X_{v(i,m)}$  متغیر مستقل  $v$  ام، محل گره هر یک از متغیرهای مستقل موجود در تابع پایه  $m$  ام، اندیس  $+$  یعنی انتخاب بخش مثبت و  $q$  درجه تابع پایه است.

قابل ذکر است که داده‌های مورد استفاده در این تحقیق، سری زمانی ۲۸ ساله جریان روزانه ایستگاه هیدرومتری ارمند برای سال‌های ۱۳۶۰ تا ۱۳۸۷ می‌باشد که سری زمانی روزانه آن‌ها و نیز نمودار جعبه‌ای تغییرات ماهانه دبی در شکل ۲ ترسیم شده است.

مطابق شکل بالا، بیشترین مقدار جریان رودخانه مربوط به ماه‌های اردیبهشت (۴۷۸/۸۶)، اسفند (۴۰۳/۳۹) و فروردین (۳۵۶ مترمکعب بر ثانیه) می‌باشد که دلیل آن بارندگی‌های ماه‌های قبل و همچنین رواناب‌های ناشی از ذوب برف می‌باشد. از طرفی کمترین میزان دبی متعلق به شهریور (۲۱/۲۱)، مهر (۲۱/۳۳) و مرداد (۲۳/۰۵) است. همچنین ۷۰ درصد داده‌ها (سال‌های ۱۳۶۰ تا ۱۳۷۹) برای آموزش و مابقی یعنی آمار سال‌های ۱۳۸۰ تا ۱۳۸۷ برای آزمایش مدل‌های MARS، GEP و MT استفاده شده است.

## ۲-۲- مدل‌های هوش مصنوعی جهت پیش‌بینی جریان

### -مدل گرسون اسپلین تطبیقی چند متغیره (MARS)

مدل MARS اولین بار توسط فریدمن در سال ۱۹۹۱ معرفی شد. این مدل هیچگونه نیازی به پیش فرض در مورد نوع رابطه متغیرهای مستقل و وابسته ندارد؛ از همین رو نسبت به بسیاری از روش‌های دیگر از قابلیت بالایی در تعیین رابطه بین متغیرها برخوردار است و می‌تواند روابط غیرخطی

میانی<sup>۴</sup> و گره انتهایی<sup>۵</sup> تشکیل شده که گره‌های ابتدایی و میانی دربرگیرنده توابع تعیین شده و همچنین گره انتهایی شامل متغیرهای مستقل می‌باشند. عملگرهایی همچون جهش<sup>۶</sup> و تلاقی<sup>۷</sup> در GEP کاربرد دارند. عملگر دیگر ترانهش<sup>۸</sup> است که طی آن پدیده‌های مختلف با مجموعه‌ای از توابع، مدل می‌شوند. طی فرآیند GEP، اگر نتایج قابل قبول از یک راه حل پیدا شود و یا نسل‌ها به تعداد مشخصی برسند، تکامل متوقف و جواب بهینه پیدا می‌شود در غیر این صورت، بهترین راه حل مربوط به نسل پیش رو ذخیره شده که این به معنای نخبه‌گزینی است [۲۳ و ۲۲]. گام‌های به کارگیری این مدل در تحقیق حاضر به شرح جدول ۱ می‌باشد.

### – الگوریتم درخت مدل (MT)

MT نخستین بار توسط Quinlan (۱۹۹۲) معرفی و متعاقباً بهبود و توسعه آن توسط Wang و Witten (۱۹۹۶) صورت گرفت [۲۵] و [۲۴]. این مدل با الهام از طبیعت درختان از ساختار ریشه، شاخه و برگ تشکیل شده که هر یک متناسب با طراحی مدل، وظایفی را به عهده دارند. MT همانند یک درخت رگرسیونی دودویی می‌باشد که در واپسین گره‌های (برگ‌ها) خود توابع رگرسیونی خطی داشته و قادر است صفات عددی پیوسته تولید کند [۲۶]. در این تحقیق از مدل M5 که یکی از زیرمجموعه‌های مدل‌های درختی (MT) است استفاده گردیده است. در فرآیند تولید MT از معیار انشعاب<sup>۹</sup> برای تولید یک تصمیم درختی استفاده می‌گردد. این معیار برای مدل درختی M5 بر مبنای رفتار انحراف استاندارد مقادیر کلاسی است که به عنوان کمیتی از خطا به گره می‌رسد و کاهش قابل انتظار در این خطا را به عنوان پاسخ آزمایش هر صفت در آن گره مشخص محاسبه می‌کند. معادله کاهش انحراف معیار (SDR)<sup>۱۰</sup> به صورت زیر است [۲۵]. به طور خلاصه، مراحل اصلی توسعه درخت M5 عبارت است از: (۱) ساخت درخت (۲) هرس درخت و (۳) نرم کردن درخت.

$$SDR = sd(T) - \sum_i \frac{|T_i|}{|T|} \times sd(T_i) \quad (6)$$

- 4 Argument
- 5 Terminal
- 6 Mutation
- 7 Crossover
- 8 Transposition
- 9 Branch Criterion
- 10 Standard Deviation Reduction

$$\left[ S_{i,m} (X_{v(i,m)} - t_{i,m}) \right]_+^q = \text{Max} \left( 0, \left[ S_{i,m} (X_{v(i,m)} - t_{i,m}) \right]^q \right) \quad (3)$$

اعتبارسنجی متقابل تعمیم‌یافته (GCV)<sup>۱</sup> که برای ممانعت از افزونگی در MARS استفاده می‌شود به شکل زیر است:

$$GSV(M) = \frac{1}{N} \sum_{i=1}^N [y_i - \hat{f}(X_i)]^2 \left/ \left[ 1 - \left( \frac{C(M)}{N} \right) \right]^2 \right. \quad (4)$$

که  $N$  تعداد داده‌ها،  $M$  تعداد توابع پایه غیرثابت،  $y_i$  مقدار واقعی متغیر وابسته،  $C(M)$  معیار هزینه مدل و تعداد مؤثر درجه آزادی و  $\hat{f}(X_i)$  مقدار برآورده شده متغیر وابسته می‌باشد. در مرحله حرکت رو به عقب بعد از حذف تابع پایه، GCV محاسبه شده و بقیه توابع که با حذف آن‌ها مقدار GCV کاهش می‌یابد از مدل خارج شده و کنار گذاشته می‌شوند تا در نهایت مدلی با GCV بهینه مطابق رابطه زیر به دست آید:

$$C(M) = \text{trace} \left( B (B^T B)^{-1} B^T \right) + 1 + d.m \quad (5)$$

که  $B$  یک ماتریس  $M \times N$  حاوی مقدار توابع تابع به ازای داده‌های ورودی و  $d$  هزینه در ازای هر تابع پایه است که عموماً عددی ما بین ۲ و ۴ انتخاب می‌شود؛ و هر چه پارامتر  $d$  بزرگتر انتخاب شود تعداد گره‌ها کاهش می‌یابد و مدل نهایی هموارتر خواهد بود. از همین رو آن را به عنوان پارامتر هموارسازی هم در نظر می‌گیرند.

### – مدل برنامه‌نویسی بیان ژن (GEP)

این مدل که در ابتدا توسط Ferreira در سال ۱۹۹۹ ارائه شد نوعی الگوریتم تکاملی برگرفته از سیستم وراثتی موجودات زنده می‌باشد [۲۲]. اولین مرحله در مدل‌سازی GEP تولید جمعیت اولیه (کروموزوم) به کمک فرآیندهای تصادفی و یا اطلاعات مسأله می‌باشد. کروموزوم‌های اولیه توسط یک تابع برازش<sup>۲</sup> ارزیابی و میزان مناسب بودن راه حل تعیین می‌گردد. هر کروموزوم (درخت) از زیر درخت‌هایی به نام ژن ساخته شده‌اند. هر ژن از سه بخش گره ابتدایی<sup>۳</sup> (ریشه)، گره

- 1 Generalized Cross Validation
- 2 Fitness Function
- 3 Root Node

جدول ۱. گام‌های طی شده در مدل GEP در تحقیق حاضر

Table 1. Development phases of GEP model in this study

تعیین تابع برازش مناسب	تابع جذر میانگین مربعات خطا (RMSE) به عنوان تابع برازش در این تحقیق، انتخاب گردید. در مطالعه حاضر، مجموعه ترمینال‌ها، مقادیر دبی رودخانه با تأخیرهای زمانی می‌باشند. بدین منظور از چهار عملگر اصلی و نیز توابع زیر استفاده گردیده است.
تعیین مجموعه متغیرهای ورودی و مجموعه توابع	$\{ \exp(x), \ln(x), 1/x, x^2, \sqrt[3]{x}, \min(x, y), \text{avg}(x, y), \text{Arc tan}(x), \tanh(x), 1-x \}$
تعیین ساختار و معماری کروموزوم‌ها	تعداد داده‌های آموزش ۲۳۵، آزمایش ۱۰۱، تعداد کروموزوم‌ها ۳۰، طول هر رأس <sup>۱</sup> برابر ۷، تعداد ژن‌ها ۳، نرخ جهش ۰/۰۰۱۳۸، نرخ انتقال ژن ۰/۰۰۲۷۷، نرخ باز ترکیبی ژن ۰/۰۰۲۷۷، نرخ باز ترکیبی تک نقطه‌ای و دو نقطه‌ای هم ۰/۰۰۲۷۷ انتخاب شدند.
تعیین تابع پیوند و عملگرهای ژنتیک و نرخ هر یک از آن‌ها.	در اینجا عمل جمع برای ایجاد پیوند بین زیر شاخه‌ها مورد استفاده قرار گرفت.

تولید اعداد تصادفی و تحلیل عدم قطعیت

در این تحقیق، برای ملاحظه عدم قطعیت مقادیر جریان رودخانه و تأثیر آن بر پیش‌بینی‌های یک ماه بعد جریان، از روش MCS استفاده شده است. مفهوم اساسی MCS بر اساس نمونه‌برداری‌های تصادفی مکرر یا اعداد مصنوعی تولید شده از یک متغیر غیرقطعی<sup>۳</sup> می‌باشد. این اعداد تصادفی از توزیع آماری داده‌ها واقعی تقلید می‌کنند که توسط کارشناسان و برخی از تجربیات شناسایی شده‌اند [۲۸ و ۱۸]. برای تولید داده‌های مصنوعی در تحقیق حاضر از روش پارامتریک توماس - فیرینگ (TF)<sup>۴</sup> استفاده شده است. در این روش فرض بر آنست که مقادیر دبی ماهانه جریان فقط به دو پارامتر انحراف معیار و میانگین مقادیر همان ایستگاه وابسته بوده است بدین صورت که هر داده دبی ماهانه به دبی ماه قبل خود وابسته است و معادله حاکم بر این مدل به صورت زیر می‌باشد [۲۹].

$$Q_{i+1} = \bar{Q}_{j+1} + b_j (Q_i - \bar{Q}_j) + e_i + S_{j+1} \sqrt{1 - r_j^2} \quad (7)$$

$$Q_2 = \mu_{Feb} + b_{\frac{Feb}{Jan}} (Q_1 - \mu_{Feb}) + t_n \sigma_{Feb} \sqrt{1 - \rho_{\frac{Feb}{Jan}}^2} \quad (8)$$

در معادله بالا  $T$  نمونه‌های رسیده به گره و  $T_i$  نمونه‌هایی است که  $i$  امین برآمد تست پتانسیلی را دارا بوده و  $sd$  انحراف معیار می‌باشد. دقت درخت برای داده‌های آموزش به طور یکنواخت با رشد درخت افزایش می‌یابد. با این وجود، این افزایش دقت اندازه‌گیری شده بر روی داده‌های آزمایش مستقل، ابتدا افزایش یافته و سپس کاهش می‌یابد که برای حل این مشکل از فرآیندی به نام هرس استفاده می‌شود. آخرین مرحله، استفاده از یک فرآیند نرم کردن<sup>۱</sup> برای جبران ناپیوستگی‌های شدید است که به طور اجتناب‌ناپذیری بین مدل‌های خطی مجاور در برگ‌های درخت هرس شده، به ویژه برخی از مدل‌های ایجاد شده با تعداد داده‌های آموزشی کم رخ می‌دهد [۲۶].

شبیه‌سازی مونت کارلو (MCS)<sup>۲</sup>

اساس کار این روش بر اساس تولید اعداد تصادفی است. بدین صورت که هر متغیر با استفاده از اعداد تصادفی تولید گردیده و تابع توزیع احتمالاتی مربوط به آن محاسبه می‌شود. سپس متناظر با آن‌ها خروجی هر مدل محاسبه و این عمل بارها تکرار می‌گردد. در ادامه با استفاده از داده‌های خروجی تولید شده به تجزیه و تحلیل نحوه تغییرات نتایج مدل یاد شده پرداخته می‌شود و میزان عدم قطعیت پارامتر خروجی نیز از طریق محاسبه شاخص‌های آماری و یا تعیین تابع توزیع آن بیان می‌گردد [۲۷].

3 Uncertain variable  
4 Thomas - Fiering

1 Smoothing  
2 Monte-Carlo simulation

که در رابطه فوق  $X_U$  برابر ۹۷/۵ درصد حد بالای پیش‌بینی،  $X_L$  برابر ۲/۵ درصد حد پایین پیش‌بینی و  $k$  تعداد نقاط داده‌های مشاهده شده می‌باشد.

$$95PPU = \frac{1}{K} \text{count} (Q | X_L \leq Q \leq X_U) \times 100 \quad (۱۳)$$

منظور از معیار 95PPU این است که چند درصد داده‌های تاریخی در بازه‌ای بین ۲/۵ درصد که همان حد پایین پیش‌بینی‌ها و ۹۷/۵ درصد که حد بالای پیش‌بینی‌هاست قرار دارند. به طور کلی باند 95PPU حد فاصل صفر تا ۱۰ درصد و R-factor نیز مابین صفر تا بی نهایت تغییر می‌کند؛ بدین ترتیب که مقادیر بیشتر معیار 95PPU به همراه مقادیر کمتر پارامتر R-factor نشان از عدم قطعیت کمتر مدل و عملکرد مناسب آن دارد.

### شاخص‌های ارزیابی عملکرد مدل‌های پیش‌بینی: در راستای

ارزیابی و دقت مدل‌های پیش‌بینی، از معیارهایی همچون ریشه میانگین مربعات خطا (RMSE)<sup>۲</sup>، ضریب همبستگی (R) و میانگین خطای مطلق (MAE)<sup>۳</sup> استفاده گردید.

### ۳- نتایج و بحث

#### ۳-۱- نتایج پیش‌بینی‌های یک ماه بعد جریان رودخانه کارون

همانطور که قبلاً اشاره شد آمار دبی مربوط به سال‌های ۱۳۶۰ تا ۱۳۸۷ (مجموعاً ۲۸ سال) متعلق به ایستگاه آب‌سنجی ارمند، در این تحقیق استفاده شده است. متغیرهای ورودی شامل مقادیر جریان رودخانه برای یک تا سه ماه قبل ( $Q(t-1)$ ,  $Q(t-2)$ ,  $Q(t-3)$ ) می‌باشند. همچنین ۷۰ درصد داده‌ها شامل سال‌های ۱۳۶۰ تا ۱۳۷۹ برای آموزش و ۳۰ درصد مابقی یعنی سال‌های ۱۳۸۰ تا ۱۳۸۷ جهت آزمایش مدل‌های GEP, MARS و MT به کار گرفته شد. در ادامه نتایج مدل‌های هوشمند نام برده در مراحل آموزش و آزمایش در شکل‌های ۴ تا ۶ ارائه شده است. مطابق این اشکال سه شاخص گرافیکی خط ۴۵ درجه (خط  $y=x$ ) و نیز خطوط مثبت و منفی ۳۰٪ برای نمایش کیفی میزان دقت مدل‌های نام برده در هر دو مرحله آموزش و آزمایش مشخص شده است. شایان ذکر است که هدف از ترسیم

$$Q_{13} = \mu_{Jan} + b_{\frac{Jan}{Dec}} (Q_{12} - \mu_{Jan}) + t_n \sigma_{Jan} \sqrt{\left(1 - \rho_{\frac{Jan}{Dec}}^2\right)} \quad (۹)$$

$$b_j = r_j \left[ \frac{S_{j+1}}{S_j} \right] \rightarrow b_{\frac{Feb}{Jan}} = \rho_{\frac{Feb}{Jan}} \left( \frac{\sigma_{Feb}}{\sigma_{Jan}} \right) \quad (۱۰)$$

که در آن  $Q_i$  و  $Q_{i+1}$  جریان‌های ماهانه تولید شده در دوره  $i$  و  $i+1$ ،  $Q_j$  و  $Q_{j+1}$  متوسط جریان ماهانه در ماه‌های  $j$  و  $j+1$ ، ضریب همبستگی حداقل مربعات برای محاسبه جریان ماه  $j+1$  از جریان در ماه  $j$  (رابطه ۱۰) به دست می‌آید،  $r_j$ : ضریب همبستگی بین جریان‌های ماه‌های  $j$  و  $j+1$ ،  $S_j$  و  $S_{j+1}$ : انحراف معیار برای ماه‌های  $j$  و  $j+1$ ،  $e_i$  متغیر تصادفی از توزیع نرمال استاندارد با میانگین صفر و انحراف معیار یک می‌باشد. همچنین  $t_n$  متغیر تصادفی نرمال با میانگین صفر و واریانس یک،  $\sigma$  انحراف استاندارد دبی برای ماه مورد نظر و  $\rho$  ضریب همبستگی بین ماه‌های مجاور می‌باشند.

### شاخص‌های کمی کردن عدم قطعیت

به منظور ارزیابی عدم قطعیت مدل‌های GEP, MARS و MT، در تحقیق حاضر از آماره ۹۵ درصد عدم قطعیت پیش‌بینی (95PPU)<sup>۱</sup> محاسبه گردید. در همین راستا لازم است ۹۷/۵ درصد حد بالای پیش‌بینی‌ها و ۲/۵ درصد حد پایین آن حاصل از توزیع نرمال یک صد مرتبه اجرای مدل‌ها با الگوهای متفاوتی از داده‌های واسنجی محاسبه گردد. معیار R-factor که بیانگر عرض میانگین باند اطمینان می‌باشد از طریق رابطه زیر محاسبه می‌شود [۳۰]:

$$R - factor = \frac{\bar{d}_X}{\sigma_X} \quad (۱۱)$$

در رابطه فوق،  $\sigma_X$  انحراف معیار متغیر اندازه‌گیری شده  $X$  و  $\bar{d}_X$  میانگین فاصله کران بالا و پایین است که از رابطه زیر به دست می‌آید:

$$\bar{d}_X = \frac{1}{k} \sum_{i=1}^k (X_U - X_L) \quad (۱۲)$$


2 Root Mean Square Error

3 Mean Absolute Error

1 95 Percent Prediction Uncertainty

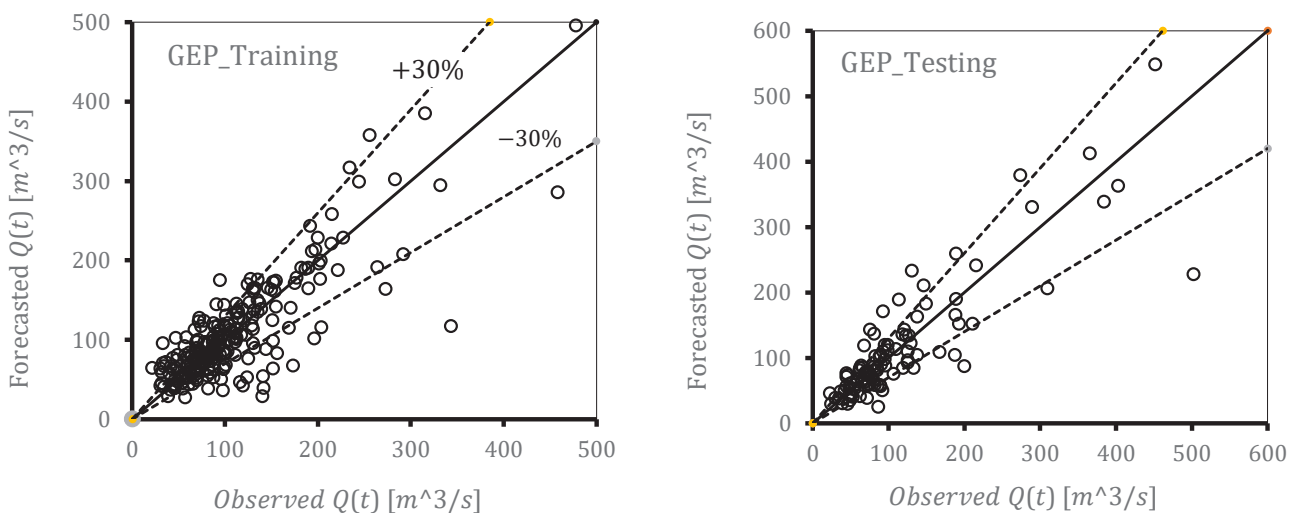
دو مرحله آموزش و آزمایش می‌باشند. در بعضی نقاط مشاهده‌ای حاصل از هر سه مدل هوش مصنوعی در مرحله آموزش برای جریان مشاهده‌ای برابر با  $342/6 \text{ m}^3/\text{s}$  مقادیر محاسباتی بسیار کمتری را نتیجه دادند. همچنین شکل‌های ۳ تا ۵ بیانگر عملکرد ضعیف مدل‌های هوش مصنوعی برای دبی برابر با  $501/94 \text{ m}^3/\text{s}$  در مرحله آزمایش می‌باشند.

خطوط  $\pm 30\%$  درصد، تعیین یک بازه، جهت قرارگیری نقاط خطا می‌باشد، بدین ترتیب نقاطی که در بالا و پایین خط نیمساز (۴۵ درجه) قرار دارند نمایانگر مقدار خطای موجود بین داده‌های تاریخی و پیش‌بینی شده توسط مدل می‌باشد. شکل‌های ۳ تا ۵ نشان می‌دهند که بیشتر نقاط محاسباتی دبی ماهانه در بازه قابل قبول  $\pm 30\%$  درصد متمرکز شده‌اند و این مطلب بیانگر عملکرد مطلوب مدل‌های هوش مصنوعی MARS، GEP و MT در هر



شکل ۳. نمودار پراکندگی بین داده‌های مشاهده‌ای و پیش‌بینی شده در مراحل آموزش و آزمایش مدل MARS

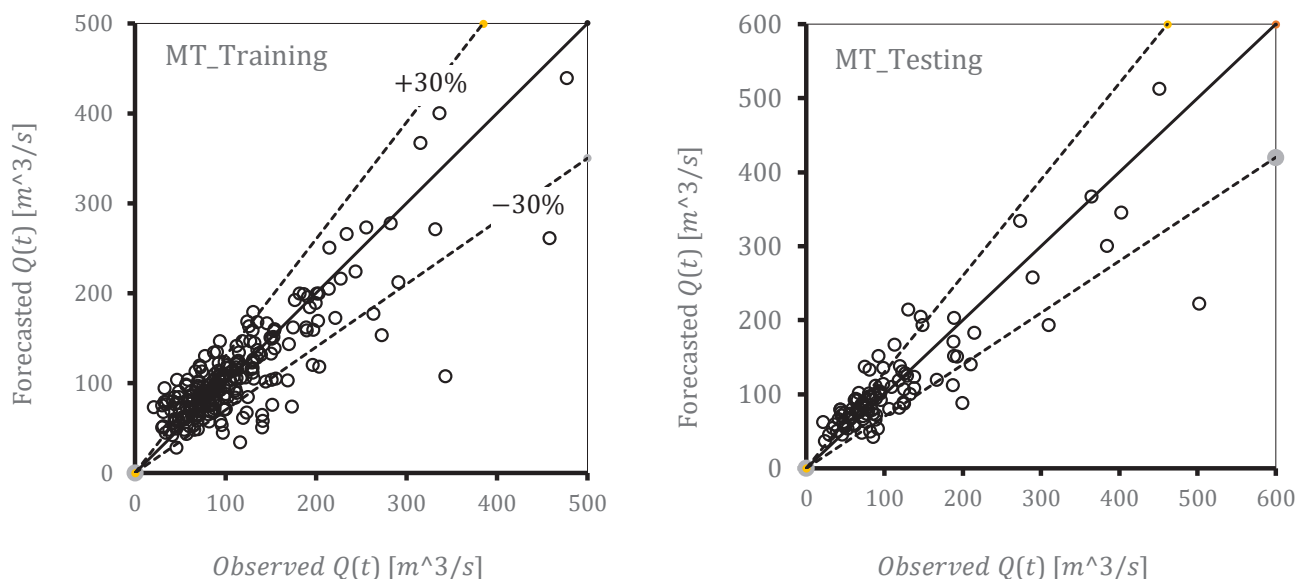
Fig. 3. Scatter plot between observed and forecasted Karun streamflow in the training and testing phases of MARS model



شکل ۴. نمودار پراکندگی بین داده‌های مشاهده‌ای و پیش‌بینی شده در مراحل آموزش و آزمایش مدل GEP

4. Scatter plot between observed and forecasted Karun streamflow in the training and testing phases of GEP model





شکل ۵. نمودار پراکندگی بین داده‌های مشاهداتی و پیش‌بینی شده در مراحل آموزش و آزمایش مدل MT

Fig.5. Scatter plot between observed and forecasted Karun streamflow in the training and testing phases of MT model

جدول ۲. نتایج عملکرد مدل‌های GEP، MARS و MT در مراحل آموزش و آزمایش


Table 2. Results of MARS, GEP and MT models performances in the training and testing stages

مرحله آزمایش			مرحله آموزش			مدل‌ها
MAE (m <sup>3</sup> /s)	RMSE (m <sup>3</sup> /s)	R	MAE (m <sup>3</sup> /s)	RMSE (m <sup>3</sup> /s)	R	
۳۰/۹۹۸	۴۷/۴۹۳	۰/۸۴۸	۲۴/۲۵۹	۳۶/۷۶۵	۰/۸۴۱	<b>MARS</b>
۲۸/۹۴۰	۴۶/۲۴۳	۰/۸۶۵	۲۵/۱۳۲	۳۸/۵۵۶	۰/۸۳۹	<b>GEP</b>
۲۸/۴۲۴	۴۴/۲۵۳	۰/۸۷۰	۲۴/۳۸۱	۳۶/۷۸۹	۰/۸۴۱	<b>MT</b>


همچنین در جدول ۲ عملکرد مدل‌های MARS، GEP و MT با استفاده از شاخص‌های RMSE، ضریب همبستگی و MAE کمی و با هم مقایسه شده‌اند.

با توجه به جدول فوق و نیز شکل‌های ۳ تا ۵، می‌توان نتیجه گرفت که مدل MT در هر دو مرحله آموزش و آزمایش عملکرد بهتری نسبت به سایرین داشته است. نتایج جدول ۲ نشان می‌دهد که مدل‌های هوش مصنوعی MT (R = ۰/۸۴۱ و RMSE = ۳۶/۷۸۹ m<sup>3</sup>/s) و MARS (R = ۰/۸۳۹ و RMSE = ۳۸/۵۵۶ m<sup>3</sup>/s) نسبتاً یکسانی هستند. این در حالی است که مدل GEP از نظر سطح دقت در تخمین جریان رودخانه کارون در مرحله بعدی قرار دارد. همچنین مقادیر MAE در مرحله آموزش بیانگر این واقعیت می‌باشد. در مرحله آزمایش،

خطوط  $\pm 30\%$  درصد، تعیین یک بازه، جهت قرارگیری نقاط خطا می‌باشد، بدین ترتیب نقاطی که در بالا و پایین خط نیمساز (۴۵ درجه) قرار دارند نمایانگر مقدار خطای موجود بین داده‌های تاریخی و پیش‌بینی شده توسط مدل می‌باشد. شکل‌های ۳ تا ۵ نشان می‌دهند که بیشتر نقاط محاسباتی دبی ماهانه در بازه قابل قبول  $\pm 30\%$  درصد متمرکز شده‌اند و این مطلب بیانگر عملکرد مطلوب مدل‌های هوش مصنوعی MARS، GEP و MT در هر دو مرحله آموزش و آزمایش می‌باشند. در بعضی نقاط مشاهده‌ای حاصل از هر سه مدل هوش مصنوعی در مرحله آموزش برای جریان مشاهده‌ای برابر با  $342/6 \text{ m}^3/\text{s}$  مقادیر محاسباتی بسیار کمتری را نتیجه دادند. همچنین شکل‌های ۳ تا ۵ بیانگر عملکرد ضعیف مدل‌های هوش مصنوعی برای دبی برابر با  $501/94 \text{ m}^3/\text{s}$  در مرحله آزمایش می‌باشند.



(ب) آذر (December)



(الف) فروردین (April)

شکل ۶. برازش توزیع نرمال به مقادیر ماهانه دبی ایستگاه ارمند

Fig. 6. Normal distribution function fitted to the monthly streamflow of Armand station

مصنوعی و مدل‌های کلاسیک ریاضی می‌توان نتیجه گرفت که علیرغم سادگی مدل‌های کلاسیک ریاضی به لحاظ ساختار فرمولی، در مقایسه با مدل‌های هوش مصنوعی مورد استفاده در تحقیق حاضر (GEP, MT, MARS) از دقت بسیار پایینی برخوردار هستند.


### ۳-۲- تولید اعداد تصادفی و تحلیل عدم قطعیت

همانطور که قبلاً ذکر شد اساس کار روش MCS تولید اعداد تصادفی از متغیرهای احتمالاتی مساله می‌باشد. برای تولید داده‌های تصادفی دبی به روش پارامتریک TF، ابتدا نرمال بودن (شکل ۶) مورد بررسی قرار گرفت. مطابق این شکل داده‌های دبی ماه فروردین از توزیع نرمال تبعیت می‌کند، این در حالیست که دبی در برخی ماه‌ها (همانند ماه آذر)، دارای توزیع نرمال نبوده است.

در ادامه داده‌هایی که از توزیع نرمال تبعیت نمی‌کنند با استفاده از تبدیل مناسب به داده‌های متناظری که دارای توزیع نرمال هستند، انتقال داده شده و از آن‌ها برای تولید داده‌های مصنوعی استفاده نمود [۳۱]. بدین منظور از تبدیل Box-Cox که یکی از قوی‌ترین تبدیلات موجود می‌باشد استفاده گردید [۳۲]. بعد از تبدیل داده‌ها، با استفاده از روش پارامتریک TF اقدام به تولید داده مصنوعی با تکرار ۱۰۰ مرتبه برای داده‌های پایه گردید. برای صحت‌سنجی داده‌های تولید شده، پارامترهای آماری (میانگین، انحراف


جدول ۲ نشان داد که مدل هوش مصنوعی MT با داشتن R برابر با ۰/۸۷ و RMSE برابر با  $44/253 \text{ m}^3/\text{s}$  در مقایسه با مدل‌های هوش مصنوعی GEP ( $R=0/865$ ) و  $RMSE=46/243 \text{ m}^3/\text{s}$  و MARS ( $R=0/848$ ) و  $RMSE=47/493 \text{ m}^3/\text{s}$  دارای دقت بالاتری می‌باشد.

در ادامه به منظور بررسی عملکرد مدل‌های هوش مصنوعی تحقیق نسبت به با مدل‌های سری زمانی کلاسیک ARMA نتایج مدل‌های نام برده با هم مقایسه شدند. نتایج نشان داد که ضریب همبستگی حاصل از مدل ARMA برابر با ۰/۸۴۷ حاصل گردید که در مقایسه با سایر مدل‌های هوش مصنوعی عملکرد ضعیف‌تری دارد. در تحقیق Zamani و همکاران (۲۰۱۵) از دو مدل BL و ARMA جهت شبیه‌سازی الگوی دبی رودخانه کارون در ایستگاه آرمند استفاده نمود و نتیجه گرفتند که مدل‌های هوش مصنوعی در مقایسه با مدل‌های کلاسیک سری زمانی از دقت بالایی برخوردار می‌باشند [۱۹]. همچنین با استفاده از نرم‌افزار SPSS عملکرد مدل کلاسیک ARIMA (دارای دو تاخیر زمانی) با ضریب همبستگی برابر با ۰/۷۴،  $RMSE$  برابر با  $55/05 \text{ m}^3/\text{s}$  و  $MAE$  برابر با  $31/043 \text{ m}^3/\text{s}$  نشان می‌دهد که سطح عملکرد پایین‌تری در مقایسه با سایر مدل‌های هوش مصنوعی دارد. همچنین مدل کلاسیک ARMA دارای عملکرد ضعیفی ( $R=0.66$ ,  $RMSE=61.110 \text{ m}^3/\text{s}$ , and  $MAE=40.164$ ) در برآورد دبی ماهانه می‌باشد. با مقایسه عملکرد مدل‌های هوش



شکل ۷. مقایسه داده‌های مشاهداتی با حدود بالا و پایین پیش‌بینی‌ها در مدل MARS (باند ۹۵٪ اطمینان)

**Fig. 7. The upper and lower uncertainty bands of forecasted streamflow by MARS model in comparison with observational data (95% confidence level)**



شکل ۸. مقایسه داده‌های مشاهداتی با حدود بالا و پایین پیش‌بینی‌ها در مدل MT (باند ۹۵٪ اطمینان)

**Fig. 8. The upper and lower uncertainty bands of forecasted streamflow by MT model in comparison with observational data (95% confidence level)**

ادامه نمودارهای مربوط به عدم قطعیت مدل‌ها، که در برگزیده مقایسه داده‌های مشاهداتی با حدود بالا (۹۷/۵٪) و پایین (۲/۵٪) و همچنین با سطح اطمینان ۹۵٪ می‌باشد ترسیم گردید. بدین منظور نتایج مدل‌های MARS و MT به عنوان نمونه ارائه شده است.

معیار و چولگی) این داده‌ها با پارامترهای سری‌های ماهانه داده‌های تاریخی مقایسه شد که تقریباً انطباق خوبی در همه ماه‌ها مشاهده گردید. در نهایت با استفاده از روش TF صد دوره ۲۸ ساله داده‌های دبی تولید شد. سپس با استفاده از داده‌های تولید شده، پیش‌بینی‌های یک ماه بعد جریان با مدل‌های MARS، GEP و MT انجام و نتایج آن‌ها با هم مقایسه گردید. در

جدول ۳. مقایسه نتایج عدم قطعیت مدل‌های هوش مصنوعی در پیش‌بینی جریان رودخانه کارون

Table 3. Comparison of uncertainty results for AI models for forecasting Karun river flow.

95PPU	R-factor	مدل‌های هوش مصنوعی
٪۶۱	۱/۹۲	MARS
٪۵۹/۵	۱/۶۷	MT
٪۶۴	۲/۰۲۵	GEP

میانگین قدر مطلق خطا (MAE) به منظور ارزیابی و دقت مدل‌ها به کار گرفته شدند. از تحقیق حاضر، نتایج زیر قابل استخراج می‌باشد:

- مقادیر شاخص‌های R، RMSE و MAE برای پیش‌بینی‌های یک ماه بعد جریان نشان دادند که مدل MT در هر دو مرحله آموزش و آزمایش عملکرد بهتری نسبت به سایر مدل‌های هوش مصنوعی MARS و GEP و مدل کلاسیک ریاضی ARMA داشته است.

- برای ملاحظه عدم قطعیت مدل‌های MARS، GEP و MT در پیش‌بینی‌های یک ماه بعد جریان رودخانه کارون، شاخص‌های R-factor و باند 95PPU به کار گرفته شد. نتایج نشان داد که شاخص R-factor که همان عرض باند اطمینان است در مدل MT برابر با ۱/۶۷ به دست آمد که این مقدار در مقایسه با MARS و GEP عدد کمتری می‌باشد. معیار 95PPU که اختلاف حد بالا و پایین پیش‌بینی‌هاست برای مدل‌های MARS، GEP و MT به ترتیب برابر ۶۱، ۵۹/۵ و ۶۴ درصد بوده است. با احتساب هر دو شاخص، می‌توان گفت مدل MT عملکرد نسبی بهتری در قیاس با سایر مدل‌ها داشته است.

#### منابع

- [1] R.J. Abrahart, L. See, Neural network vs. ARMA modelling: constructing benchmark case studies of river flow prediction. In GeoComputation'98. Proceedings of the Third International Conference on GeoComputation, University of Bristol, United Kingdom (1998) 17-19.
- [2] H. K. Cigizoglu, Estimation, forecasting and extrapolation of river flows by artificial neural networks. Hydrological Sciences Journal, 48(3) (2003) 349-361.

نتایج عدم قطعیت مدل‌های MARS، GEP و MT برای پیش‌بینی یک ماه بعد جریان رودخانه کارون مطابق جدول ۳ محاسبه و کمی شده‌اند. مقادیر کوچکتر R-factor که بیانگر پهنای باند عدم قطعیت است بیانگر عملکرد خوب مدل می‌باشد. از این منظر مدل MT دارای کوچک‌ترین مقدار R-factor در قیاس با سایر مدل‌ها بوده است. از طرفی، مقادیر 95PPU که نشان دهنده درصد داده‌های قطعی (مشاهداتی تاریخی) در باند تخمین عدم قطعیت ۹۵ درصد قرار می‌گیرند، برای مدل‌های نام برده بین ۵۹/۵ تا ۶۴ درصد می‌باشد. در نهایت برای قضاوت در مورد عملکرد بهترین مدل در شرایط عدم قطعیت بایستی هر دو شاخص کمینه R-factor و بیشینه 95PPU همزمان مد نظر قرار گیرند که با توجه به موارد نام برده می‌توان گفت که عملکرد مدل MT در شرایط عدم قطعیت نسبت به سایر مدل‌ها بهتر بوده است.

#### ۴- خلاصه و نتیجه‌گیری

تحقیق حاضر تلاشی برای پیش‌بینی یک ماه بعد جریان رودخانه کارون (در محل ایستگاه هیدرومتری ارمند) توسط مدل‌های هوش مصنوعی MARS، GEP و MT می‌باشد. همچنین احتساب عدم قطعیت مقادیر جریان رودخانه توسط روش شبیه‌سازی مونت کارلو (MCS) و تاثیر آن بر باندهای عدم قطعیت پیش‌بینی‌های جریان توسط مدل‌های نام برده از دیگر اهداف تحقیق حاضر بوده است. بدین منظور آمار ۲۸ ساله جریان رودخانه کارون (سال‌های ۱۳۸۷-۱۳۶۰) استفاده و برای تولید اعداد تصادفی، روش پارامتریک توماس-فیرینگ (TF)<sup>۱</sup> به کار گرفته شد. شاخص‌های آماری همچون ضریب همبستگی (R)، جذر میانگین مربعات خطا (RMSE) و

1 Thomas-Fiering

- 2853-2871.
- [12] A. Bensoussan, N. Farhi, Uncertainties and risks in water resources management. The economics of sustainable development, (Chapter: Uncertainties and risks in water resources management), Publisher: Econom (2010) 163-79.
- [13] M. Dehghani, B. Saghafian, F. Nasiri Saleh, A. Farokhnia, R. Noori, Uncertainty analysis of streamflow drought forecast using artificial neural networks and Monte-Carlo simulation, *International Journal of Climatology*, 34(4), (2014) 1169-80.
- [14] S. Anvari, J. Mousavi, S. Morid, A Multilevel Uncertainty-Based Approach for Optimal Irrigation Scheduling. *Advances in Hydroinformatic*. (2018) 359-372.
- [15] S. Anvari, J.H. Kim, M. Moghaddasi, The role of meteorological and hydrological uncertainties in the performance of optimal water allocation approaches, *Irrigation and Drainage*, 68(2) (2019) 342-53.
- [16] M. Moghaddasi, S. Anvari, N. Akhondi, A trade-off analysis of adaptive and non-adaptive future optimized rule curves based on simulation algorithm and hedging rules. *Theoretical and Applied Climatology*, 148(1) (2022) 65-78.
- [17] M. Abbasi, A. Farokhnia, M. Bahreinimotlagh, R. Roozbahani, A Hybrid of Random Forest and Deep Auto-Encoder with Support Vector Re-gression Methods for Accuracy improvement and uncertainty reduction of long-term streamflow prediction. *Journal of Hydrology*, 597 (2021) 125717.
- [18] S. Anvari, E. Rashedi, S. Lotfi, A Coupled Metaheuristic Algorithm and Artificial Intelligence for Long-Lead Stream Flow Forecasting. *International Journal of Optimization in Civil Engineering*, 12(1) (2022) 91-104.
- [19] R. Zamani, F. Ahmadi, F., Radmanesh Comparison of the Gene Expression Programming, Nonlinear Time Series and Artificial Neural Network in Estimating the River Daily Flow (Case Study: The Karun River), *Journal of Water and Soil*; 28 (6) (2015) 1172-1182 (In Persian).
- [20] Friedman, J.H. (1991). *Multivariate Adaptive*
- [3] C.L. Wu, K.W. Chau, C.Fan, Prediction of rainfall time series using modular artificial neural networks coupled with data-preprocessing techniques. *Journal of Hydrology*, 389(1-2) (2010) 146-167.
- [4] W. Huang, B. Xu, A. Chan-Hilton, Forecasting flows in Apalachicola River using neural networks. *Hydrological processes*, 18(13) (2004) 2545-2564.
- [5] R. Noori, A.R. Karbassi, A. Moghaddamnia, D. Han, M.H. Zokaei-Ashtiani, A.Farokhnia, M. Ghafari Gousheh, Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction. *Journal of Hydrology*. 401(3-4) (2011) 177-189.
- [6] Z.M. Yaseen, A. El-Shafie, O. Jaafar, H.A. Afan, K.N. Sayl, Artificial intelligence based models for stream-flow forecasting: 2000–2015. *Journal of Hydrology*, 530 (2015) 829-844.
- [7] F. Azarpira, S. SHahabi, Evaluating the capability of hybrid data-driven approaches to forecast monthly streamflow using hydrometric and meteorological variables. *Journal of Hydroinformatics*. 23(6) (2021) 1165-1181. <https://doi.org/10.2166/hydro.2021.105>
- [8] M. Montaseri, S. Zamanzad Ghavidel, Streamflow Forecasting using soft computing techniques. *Water and soil Journal*. 28(2) (2014) 394-405. (In Persian)
- [9] B. Saghafian, S. Anvari, S. Morid, Effect of Southern Oscillation Index and spatially distributed climate data on improving the accuracy of Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System and K-Nearest Neighbour streamflow forecasting models. *Expert System*. 30(4) (2013). 367-380.
- [10] A. Danandeh Mehr, An improved gene expression programming model for streamflow forecasting in intermittent streams. *Journal of Hydrology*. 563 (2018) 669-678.
- [11] R.M. Adnan, Z .Liang, K.S. Parmar, K. Soni, O. Kisi, Modeling monthly streamflow in mountainous basin by MARS, GMDH-NN and DENFIS using hydro climatic data. *Neural Computing and Applications*. 33(7) (2021).

- [26] Yi, H. S., Lee, B., Park, S., Kwak, K. C., & An, K. G. (2019). Prediction of short-term algal bloom using the M5P model-tree and extreme learning machine. *Environmental Engineering Research*, 24(3), 404-411.
- [27] Eckhardt K., Breuer L., Frede H.G. (2003). Parameter uncertainty and the significance of simulated land use change effects, *Journal of Hydrology*, 273: 164 -176.
- [28] Talebizadeh M, Morid S, Ayyoubzadeh SA, Ghasemzadeh M. Uncertainty analysis in sediment load modeling using ANN and SWAT model, *Water Resour Manag* 2010; 24(9): 1747-61.
- [29] Thomas, H.A & Fiering, M.B. (1962). Mathematical synthesis of streamflow sequence for the analysis of river basins simulations. In: Maass, A. et al. (Eds.), *Design of Water Resources Systems*. Harvard University.
- [30] Khoi, D. N., Thom, V. T., Quang, C. N. X., & Phi, H. L. (2017). Parameter uncertainty analysis for simulating streamflow in the upper Dong Nai river basin. *La Houille Blanche*, (1), 14-23.
- [31] Maheepala, S., & Perera, B. J. C. (1996). Monthly hydrologic data generation by disaggregation. *Journal of hydrology*, 178(1-4), 277-291.
- [32] McMahon TA, Adeloye A.J. (2005) *Water resources yield*. Water Resources Publications, Littleton.
- Regression Splines. *The Annals of Statistics*. 19: 1-67.
- [21] West, A.M., Evangelista, P.H., Jarnevich, C.S & Schulte, D. (2018). A tale of two wildfires: testing detection and prediction of invasive species distributions using models fit with topographic and spectral indices. *Landscape Ecology*. 33: 969-984.
- [22] Ferreira, C. (2001). Gene Expression Programming: a new adaptive algorithm for Solving Problems. *Complex Systems* 13(2): 87-129.
- [23] Mollahasani, A., Alavi, A.H & Gandomi, A.H. (2011). Empirical modeling of plate load test moduli of soil via gene expression programming. *Computers and Geotechnics*. 38(2): 281-286.
- [24] Quinlan, J.R. (1992). *Learning with continuous classes*. 5th Australian joint conference on artificial intelligence. Vol 92.
- [25] Wang, Y. and Witten, I. H. (1996). Induction of model trees for predicting continuous classes.
- [26] Mirhashemi, S.H., Panahi, M. and Zareei L (2020). Evaluation of M5P Algorithm for Estimation of Potential Evapotranspiration, Minimum and Maximum Temperature (Case study: Sari Weather Station). *Journal of Meteorology and Atmospheric Sciences* 2(4): 287-295 (In Persian).

چگونه به این مقاله ارجاع دهیم

M. Abbasi, M. Tabesh, H. Safarpour, S. A. R. Shahangian, *Environmental Impacts Assessment of Water Demand Management Policies on Urban Water Systems Using Life Cycle Approach*, *Amirkabir J. Civil Eng.*, 54(11) (2023) 4383-4396.

DOI: 10.22060/ceej.2022.21208.7653

