

Comparison of Different Approaches in the Estimation of Streamflow Time Series (Case Study: Molasani Hydrometric Station-Karun River)

Sajjad M. Vatanchi¹, Mahmoud F. Maghrebi^{2*}

1- Ph.D. in Water Engineering and Hydraulic Structures, Civil Engineering Department, Engineering Faculty, Ferdowsi University of Mashhad.

2- Professor, Civil Engineering Department, Engineering Faculty, Ferdowsi University of Mashhad.

* maghrebi@um.ac.ir

Received: 9 July 2024

Accepted: 1 October 2024

Discussion: 22 December 2025



J. Hydraul.

Iranian Hydraulic Association

Homepage: www.jhyd.iha.ir

Abstract

Introduction: Due to limited budgets and human resources for long-term monitoring, gathering observed discharge data from rivers is a challenging issue in Iran. Novel flow estimation methods are valuable in this context. Developing accurate methods for estimating river flow is crucial due to direct discharge measurement limitations. On the other hand, indirect methods include hydrological and hydraulic models, the rating curve, and data-based models. These methods are cheaper and more accessible, but their accuracy depends on the input data quality and the model's complexity. This study evaluates and compares the performance of a multivariate power rating curve model (MPRC), classic rating curve model (CRC), the Shiono and Knight model (SKM), and adaptive neuro-fuzzy inference system (ANFIS) model for estimating streamflow time series. In addition to well-known hydraulic variables such as cross-sectional area, wetted perimeter, and free surface width, determining the mean flow velocity through isovel contours is also essential as input variables for the MPRC. A novel approach in the calibration and uncertainty analysis of the MPRC model by Markov Chain Monte Carlo (MCMC), using the ANFIS model instead of the MPRC model and comparing them with the CRC and SKM models, are the novelties of the present research.

Methodology: The MPRC model proposed by Maghrebi & Ahmadi (2017) requires not only hydraulic input variables such as cross-sectional area, wetted perimeter, and free water surface width but also the velocity parameter obtained from the isovel contours. Before model calibration using MCMC, effective parameters are identified through correlation analysis. The model is calibrated using the Markov Chain Monte Carlo (MCMC) method on a portion of the observed data from the Molasani Hydrometric Station on the Karun River. The advantage of this method is that it not only calibrates the model but also evaluates its uncertainty. In the next step, the Adaptive Neuro-Fuzzy Inference System (ANFIS) method is used with the mentioned input variables instead of using the multi-variable power model. The results of these two models are compared with the CRC and SKM models.

Results and Discussion: This study compares the accuracy of four models—MPRC, ANFIS, CRC, and SKM—in estimating streamflow. Also, the Maghrebi & Ahmadi (2017) approach, MPRC model, incorporates the following modifications:

- Feature Selection: A feature selection step is introduced before calibration and uncertainty analysis.
- Model Calibration: Station-specific data is used for calibration instead of laboratory data, enhancing the model's real-world accuracy and efficiency.
- Uncertainty Analysis: Calibration methods incorporating uncertainty analysis provide a better understanding of model limitations and more accurate flow estimates.
- Integration with Machine Learning Models: Integrating the modified model with machine learning models like ANFIS is explored. This enhances the model's potential for accurate flow estimation under diverse conditions.

Results demonstrate that the ANFIS model outperforms the other three models based on four metrics: Kling-Gupta efficiency (KGE), Scatter index (SI), Index of agreement (d), and Percent bias (PBIAS). The values of these criteria in the testing phase for ANFIS respectively are 0.988, 0.9%, 0.994, and 0.41%, which are much better than the MPRC, CRC, and SKM.

Conclusion: Overall, integrating the mentioned hydraulic variables with the ANFIS model can improve the accuracy of streamflow time series estimation. Also, this approach increased the efficiency and accuracy of the model proposed by Maghrebi & Ahmadi (2017).

Keywords: Isovel contours, Machine learning, Markov chain Monte Carlo, River discharge, Shiono and Knight model.

مقایسه رویکردهای مختلف در تخمین سری‌های زمانی جریان (مطالعه موردی: ایستگاه هیدرومتری ملاثانی-رودخانه کارون)

سجاد محمدزاده وطن‌چی^۱، محمود فغفور مغربی^{۲*}

۱- دانش‌آموخته دکتری مهندسی آب و سازه‌های هیدرولیکی، گروه عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد.

۲- استاد، گروه عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد.

* maghrebi@um.ac.ir

دریافت: ۱۴۰۳/۰۴/۱۹، پذیرش: ۱۴۰۳/۰۷/۱۰، نقد و بررسی: ۱۴۰۴/۱۰/۰۱ ☞ وب‌گاه نشریه هیدرولیک: www.jhyd.iha.ir

چکیده: با محدودیت‌های بودجه و نیروی انسانی در نظارت و جمع‌آوری داده‌های طولانی‌مدت در همه رودخانه‌های ایران، دستیابی به داده‌های دقیق و مستمر از دبی رودخانه‌ها بسیار دشوار است. به همین دلیل، بهره‌گیری از روش‌های نوین برای برآورد جریان می‌تواند گامی مؤثر در این زمینه باشد. در این مطالعه، عملکرد مدل دبی-اشل توانی چندمتغیره (MPRC)، مدل دبی-اشل کلاسیک (CRC)، مدل هیدرولیکی شیونو و نایت (SKM) و مدل یادگیری ماشین سیستم استنتاج عصبی فازی تطبیقی (ANFIS) در تخمین سری زمانی جریان بررسی و مقایسه می‌شود. در مدل توانی چندمتغیره، علاوه بر پارامترهای هیدرولیکی شناخته‌شده‌ای مانند مساحت مقطع، محیط مرطوب و عرض سطح آزاد آب، تعیین سرعت متوسط جریان از طریق منحنی‌های هم‌سرعت نیز ضروری است. برای کالیبراسیون و تحلیل عدم قطعیت این مدل، از روش زنجیره مارکوف مونت کارلو (MCMC) بر روی بخشی از داده‌های مشاهداتی ایستگاه هیدرومتری ملاثانی در رودخانه کارون استفاده شده است. در مرحله بعد، دقت مدل ANFIS در پیش‌بینی سری زمانی جریان، با در نظر گرفتن متغیرهای هیدرولیکی ورودی مذکور، مورد ارزیابی قرار گرفته و با سایر مدل‌ها مقایسه خواهد شد. رویکرد نوین در کالیبراسیون مدل توانی چندمتغیره، استفاده از مدل ANFIS به جای مدل توانی چندمتغیره و مقایسه با مدل دبی-اشل کلاسیک و SKM از نوآوری‌های پژوهش حاضر است. نتایج نشان داد که طبق چهار معیار کارایی کلینگ-گوپتا (KGE)، شاخص پراکندگی (SI)، شاخص توافق (d) و درصد انحراف ($PBIAS$)، دیگرام تیلور و نمودار جعبه‌ای، مدل ANFIS با $KGE=0.988$ ، $SI=0.9\%$ ، $d=0.994$ و $PBIAS=0.41\%$ عملکرد بهتری نسبت به سایر مدل‌های مورد مطالعه ارائه می‌دهد. به طور کلی می‌توان نتیجه گرفت که ترکیب متغیرهای هیدرولیکی ورودی مذکور با مدل ANFIS می‌تواند دقت تخمین سری زمانی جریان را بهبود بخشد.

کلیدواژگان: منحنی‌های هم‌سرعت، یادگیری ماشین، زنجیره مارکوف مونت کارلو، دبی رودخانه، مدل شیونو و نایت.

کافی را ندارند.

برای برآورد دبی جریان در یک مقطع معین، روش‌های مختلفی وجود دارد که هر کدام برتری‌ها و کاستی‌های خاص خود را دارند. این روش‌ها به دو دسته کلی مستقیم و نامستقیم تقسیم می‌شوند. روش‌های مستقیم شامل اندازه‌گیری مستقیم دبی با استفاده از ابزارهایی مانند سرعت‌سنج‌های داپلر صوتی^۱ (ADCP) است. این روش‌ها

۱- مقدمه

اندازه‌گیری و برآورد دقیق جریان رودخانه نقش مهمی در مدیریت پایدار منابع آب، کاهش خطرهای سیلاب و ارتقای کارایی سازه‌های هیدرولیکی دارد. روش‌های سنتی برآورد جریان رودخانه، مانند اندازه‌گیری مستقیم یا استفاده از مدل‌های هیدرولوژیکی پیچیده، با وجود هزینه‌های بالا، در شرایط کمبود داده‌ها و یا شرایط هیدرولوژیکی متغیر دقت

1. Acoustic doppler current profiler

یک رابطه‌ی ریاضی ساده به صورت توانی است. برای استفاده از این منحنی، به مجموعه‌ی مناسبی از جفت اطلاعات ارتفاع آب و دبی اندازه‌گیری‌شده نیاز است. با این حال، اعمال منحنی دبی-اشل برای برآورد دوره‌های زمانی جریان رودخانه می‌تواند به دلیل اثرگذاری‌های ترکیبی منبع‌های مختلف عدم قطعیت (مانند خطاهای اندازه‌گیری و شرایط جریان غیردائمی) منجر به عدم قطعیت قابل توجهی شود (Kiang et al., 2018). به جز روش کلاسیک، روش‌های دیگری نیز برای برآورد منحنی دبی-اشل پیشنهاد شده‌اند که شامل روش جریان-مساحت (Manfreda, 2018) و روش مبتنی بر منحنی‌های هم‌سرعت (Maghrebi et al., 2016) می‌شود.

برای برآورد دبی، روشی با کمک منحنی‌های هم‌سرعت و یک نقطه‌ی اندازه‌گیری سرعت توسط (Maghrebi 2003) معرفی شد که با عنوان روش اندازه‌گیری تک‌نقطه‌ای^۴ (SPM) شناخته شده است. این روش از همانندی بین تأثیر یک سیم حامل جریان بر میدان مغناطیسی (طبق قانون بیوساوار^۵ در علم الکترومغناطیس) با تأثیر مرز آبراهه بر میدان سرعت جریان مقطع (در هیدرولیک) استفاده کرده است (Maghrebi, 2006). مدل SPM در آغاز منحنی‌های هم‌سرعت را با کمک قانون توانی یا لگاریتمی سرعت در یک آبراهه رسم می‌کند. آن‌گاه، با استفاده از این منحنی‌ها و یک نقطه‌ی اندازه‌گیری‌شده‌ی سرعت، دبی را برآورد می‌کند.

(Maghrebi & Ahmadi 2017) با استفاده از روش SPM، رابطه‌ی نوآورانه‌ای برای ایجاد منحنی دبی-اشل با بهره‌گیری از مفهوم منحنی‌های هم‌سرعت و فراسنجه‌های هیدرولیکی مرتبط، پیشنهاد کردند. این رابطه، مبتنی بر تحلیل ابعادی است و ارتباط بین دبی‌ها در دو ارتفاع مختلف را با استفاده از فراسنجه‌های هیدرولیکی مانند مساحت مقطع عرضی، محیط مرطوب، عرض سطح آزاد آب، زبری مانینگ و فراسنجه سرعت میانگین به‌دست‌آمده از منحنی‌های هم‌سرعت، برقرار می‌کند. دقیق‌ترین رابطه از طریق کمیته‌سازی اختلاف‌های بین دبی‌های برآوردی و

دقیق‌ترین برآورد دبی را ارائه می‌دهند، اما ممکن است پرهزینه و پرچالش باشند، به ویژه برای اندازه‌گیری‌های درازمدت و در رویدادهای شدید مانند سیلاب‌ها (Pham Van & Nguyen-Van, 2022). از سوی دیگر، روش‌های نامستقیم شامل استفاده از: ۱- مدل‌های هیدرولیکی، ۲- منحنی دبی-اشل و ۳- مدل‌های مبتنی بر داده‌ها هستند. این روش‌ها ارزان‌تر و آسان‌تر بوده، اما دقت آن‌ها به کیفیت داده‌های ورودی و پیچیدگی مدل بستگی دارد.

مدل‌های هیدرولیکی ابزار با قدرتی برای تحلیل و شبیه‌سازی رفتار جریان آب در رودخانه‌ها هستند. این مدل‌ها نه تنها برای محاسبه‌ی دبی در مقطع‌های مختلف بلکه برای بررسی طیف گسترده‌ای از ویژگی‌های هیدرودینامیکی مانند سرعت جریان، عمق آب، نیمرخ سطح آب و نیروهای هیدرولیکی به کار می‌روند. به طور معمول، مدل‌های هیدرولیکی به داده‌های ورودی مانند هندسه و/یا جانگاری، سطح آب، سرعت جریان و ویژگی‌های رسوب بستر رودخانه نیاز دارند. در کاربردهای عملی متداول که عمق آب از عرض رودخانه کمتر است، دبی به طور معمول با استفاده از مدل‌های میانگین عمقی^۱ شبیه‌سازی می‌شود (Pham Van et al., 2016). این نوع مدل‌ها در مقایسه با مدل‌های سه‌بعدی، زمان پردازش را به طور قابل توجهی کاهش می‌دهند و در عین حال اطلاعات دقیق‌تری از ویژگی‌های جریان نسبت به مدل‌های میانگین مقطع^۲ ارائه می‌دهند. مدل‌های میانگین عمقی مانند روش شیونو و نلیت^۳ (SKM) بر پایه‌ی حل عددی معادله‌های پیوستگی و اندازه حرکت برای جریان‌های کم‌عمق عمل می‌کنند. روش‌های چندی برای حل مدل‌های میانگین عمقی وجود دارد که از جمله‌ی آن‌ها می‌توان به روش حجم محدود، روش اجزای محدود و روش تفاضل محدود اشاره کرد.

دوره‌های زمانی دبی رودخانه در یک ایستگاه معین و در شرایط جریان مختلف را می‌توان از دوره‌های زمانی تراز سطح آب با استفاده از منحنی دبی-اشل برآورد کرد (Domeneghetti et al., 2012). منحنی دبی-اشل کلاسیک

4. Single point measurement
5. Biot-Savart law

1. Depth-averaged models
2. Section-averaged models
3. Shiono and Knight method

با سطح‌های مختلف پیچیدگی شده است. برخلاف مدل‌های سنتی که بر معادله‌های فیزیکی و رابطه‌های نظری استوار هستند، مدل‌های مبتنی بر داده قادر به مدیریت داده‌های پیچیده و غیرخطی هستند و بر استخراج مستقیم رابطه‌ها از داده‌ها تمرکز دارند. این پیشرفت‌ها و قابلیت‌ها، استفاده از مدل‌های مبتنی بر داده را در بسیاری از حوزه‌ها از جمله پیش‌بینی جریان رودخانه‌ها، پیش‌بینی آب و هوا، تشخیص بیماری‌ها، بهینه‌سازی فرآیندهای صنعتی و بسیاری دیگر افزایش داده است.

در حالی که مدل‌سازی بارش-رواناب در تحقیقات مربوط به کاربرد یادگیری ماشین در برآورد جریان رودخانه غالب است، علاقه فزاینده‌ای به برآورد مستقیم جریان رودخانه با استفاده از متغیرهای هیدرولیکی وجود دارد. این روش می‌تواند در حوضه‌های آبریز با داده‌های بارش محدود استفاده شود و کاربرد آن را افزایش دهد. از سوی دیگر، رفتار جریان رودخانه مستقیم تحت تأثیر متغیرهای هیدرولیکی مانند شیب آبراهه، زبری، سرعت و هندسه قرار می‌گیرد. این متغیرها می‌توانند در مدل‌های یادگیری ماشین گنجلنده شوند تا فرآیندهای فیزیکی حاکم بر جریان را ثبت کنند. در ادامه، به بررسی نتایج پژوهش‌های صورت گرفته در رابطه با کاربرد روش‌های یادگیری ماشین در برآورد جریان با کمک تراز سطح آب پرداخته می‌شود.

Thanh et al. (2022) شش مدل یادگیری ماشین از جمله درختواره تصمیم^۳ (DT)، رگرسیون فرآیند گاوسی^۴ (GPR)، ماشین بردار پشتیبان کمترین مربعات^۵ (LSSVM)، اسپلاین رگرسیون تطبیقی چند متغیره^۶ (MARS)، جنگل تصادفی^۷ (RF) و مدل‌های SVR را برای بازسازی دبی میانگین روزانه گمشده با استفاده از داده‌های چندین ایستگاه مقایسه کردند. عملکرد هر مدل یادگیری ماشین با منحنی دبی-اشل کلاسیک^۸ (CRC) مقایسه شد. یافته‌های به دست آمده نشان داد که مدل‌های یادگیری ماشین از منحنی دبی-اشل کلاسیک عملکرد بهتری دارند. He et al. (2023) از یادگیری ماشین برای برآورد دبی در

تحلیلی یا مشاهده شده معرفی می‌شود. برای راستی‌آزمایی، نتایج روش پیشنهادی با داده‌های مشاهده شده دبی-اشل از چهار رودخانه مقایسه شد و نتایج نشان‌دهنده دقت بالای این روش بود.

لازم به یادآوری است، دقت و قابلیت اطمینان منحنی دبی-اشل نقش مهمی در مدیریت مؤثر منابع آب، پیش‌بینی سیلاب و طراحی هیدرولیکی ایفا می‌کند. عدم قطعیت در منحنی دبی-اشل به دلیل دانش ناکافی و تغییرپذیری آن ایجاد می‌شود. این عدم قطعیت می‌تواند ناشی از خطاهای اندازه‌گیری در داده‌های تراز و دبی، محدودیت در داده‌های مشاهده شده، تغییرپذیری‌های بستر رودخانه در طول زمان و دخالت‌های انسانی مانند لایروبی، احداث سد یا توسعه‌ی شهری باشد.

روش‌های مختلفی برای برآورد و در نظر گرفتن عدم قطعیت‌ها در منحنی‌های دبی-اشل وجود دارد و انتخاب روش تا حد زیادی به نیازها و ویژگی‌های خاص محل مطالعه بستگی دارد (Kiang et al., 2018). روش زنجیره مارکوف مونت کارلو^۱ (MCMC) یکی از روش‌های استنتاج بی‌زین^۲ است که برای واسنجی و تحلیل عدم قطعیت مدل‌ها به کار می‌رود. این روش هنگامی که با مدل‌های پیچیده سر و کار داریم یا هنگامی که تابع احتمال به سختی به صورت تحلیلی قابل محاسبه است، بسیار سودمند است (Marjoram et al., 2003). MCMC با تولید نمونه‌هایی از توزیع پسین، امکان کاوش در فضای فراسنجه‌های با ابعاد بالا را فراهم می‌کند و عدم قطعیت را به طور کمی بیان می‌کند (Vlachou et al., 2023). در زمینه‌ی شبیه‌سازی هیدرولوژیکی، MCMC می‌تواند برای ارزیابی عدم قطعیت فراسنجه‌ها در مدل‌ها استفاده شود (Shi et al., 2023).

در دهه‌های گذشته، شاهد افزایش چشمگیری در قدرت پردازشی و پیشرفت‌های قابل توجه در روش‌های یادگیری ماشین و شبکه‌های عصبی عمیق بوده‌ایم. این پیشرفت‌ها منجر به ظهور طیف گسترده‌ای از مدل‌های مبتنی بر داده

5. Least squares support vector machine
6. Multivariate adaptive regression spline
7. Random forest
8. Classic rating curve

1. Markov chain Monte Carlo
2. Bayesian
3. Decision tree
4. Gaussian process regression

۲- مواد و روش‌ها

این بخش به بررسی مدل پیشنهادی Maghrebi & Ahmadi (2017) می‌پردازد که یک مدل توانی چندمتغیره (MPRC) است. با توجه به استفاده از روش MCMC برای واسنجی و تحلیل عدم قطعیت مدل MPRC، شرح کاملی از این روش ارائه خواهد شد. پس از آن، مدل یادگیری ماشین ANFIS معرفی و در نهایت، مدل دبی-اشل کلاسیک (CRC) و مدل هیدرولیکی SKM جهت مقایسه با دیگر مدل‌ها بررسی می‌شود. در ادامه، به معرفی رودخانه مورد مطالعه، چگونگی آماده‌سازی داده‌ها و معیارهای ارزیابی مدل نیز پرداخته می‌شود.

۲-۱- منحنی دبی-اشل با استفاده از منحنی‌های

هم‌سرعت

برای استخراج رابطه‌ی دبی-اشل، در آغاز باید فراسنجه‌های هیدرولیکی مؤثر بر دبی شناسایی شوند. متغیرهای مؤثر در تعیین مقدار دبی عبارت‌اند از: مساحت مقطع جریان، محیط مرطوب، عرض سطح آزاد آب و سرعت میانگین جریان. بنابراین، می‌توان رابطه‌ی بین دبی و متغیرهای هیدرولیکی را به‌صورت رابطه‌ی (۱) نمایش داد (Maghrebi & Ahmadi, 2017):

$$Q = f(A, P, T, U) \quad (1)$$

که در آن، Q دبی رودخانه، A مساحت مقطع جریان، P محیط مرطوب، T عرض سطح آزاد آب و U سرعت میانگین جریان به‌دست آمده از خطوط هم‌سرعت جریان است. (Maghrebi, 2006)

با توجه به اینکه هدف تحقیق یافتن رابطه‌ای کلی بین دبی در دو تراز مختلف است، بیان این رابطه به صورت نسبی، روشی مناسب‌تر خواهد بود. در این نسبت، باید متغیرهای کلیدی از فراسنجه‌های ثابت در همه ترازها جداسازی شوند تا امکان حذف آن‌ها از فرآیند محاسبه فراهم شود. این رابطه توانی چندمتغیره (MPRC) برای دو تراز مختلف به‌صورت نسبی در رابطه‌ی (۲) بیان شده است (Vatanchi

ایستگاه هیدرولوژیکی سد هویتانگاو چین استفاده کردند. آنان از روش RF برای این منظور استفاده کرده و نتایج نشان دادند که این روش برای برآورد دقیق دبی از منحنی دبی-اشل کلاسیک عملکرد بهتری دارد. (Pham Van & Nguyen-Van (2022) به مقایسه‌ی سه مدل مختلف شامل منحنی دبی-اشل کلاسیک، مدل هیدرولیکی توزیع جانبی یک‌بعدی و مدل یادگیری عمیق واحد بازگشتی دروازه‌دار^۱ (GRU) پرداختند که می‌تواند برای ارزیابی دبی آب از دوره‌های زمانی تراز سطح آب یک مقطع رودخانه برای مدت زمان درازی به‌کار رود. در نهایت، نتایج نشان داد که در بین سه مدل بررسی شده، مدل GRU بهترین عملکرد را دارد.

در این پژوهش، در آغاز عملکرد مدل دبی-اشل پیشنهادی (Maghrebi & Ahmadi (2017) یعنی مدل توانی چندمتغیره^۲ (MPRC)، در برآورد دوره زمانی جریان رودخانه بررسی می‌شود. در این مدل از متغیرهای هیدرولیکی جریان (مانند: محیط مرطوب و سطح مقطع) و فراسنجه سرعت به‌دست آمده از منحنی‌های هم‌سرعت استفاده شده است. به منظور واسنجی و ارزیابی عدم‌قطعیت آن از روش MCMC استفاده می‌شود. اطلاعات مشاهده‌شده ایستگاه آب‌سنجی ملاثانی واقع در رودخانه کارون برای واسنجی مدل به‌کار گرفته می‌شود. در گام دوم، به جای استفاده از مدل توانی چندمتغیره، از مدل یادگیری ماشین با قدرت ANFIS استفاده می‌شود و عملکرد آن در برآورد دوره زمانی جریان نیز بررسی می‌شود. ANFIS می‌تواند با استفاده از مجموعه داده‌های به‌نسبت کوچک، مدل‌های دقیقی را تولید کند. در نهایت، نتایج مدل توانی چندمتغیره و مدل ANFIS با منحنی دبی-اشل کلاسیک^۳ (CRC) و مدل هیدرولیکی شیونو و نایت (SKM) مقایسه می‌شوند. در این پژوهش، رویکردی نوین برای واسنجی و تحلیل عدم قطعیت مدل MPRC ارائه شده است. همچنین، با جایگزین شدن این مدل با ANFIS و مقایسه نتایج با مدل‌های CRC و SKM، بهترین مدل برای برآورد دوره زمانی جریان بررسی می‌شود.

3. Classic rating curve

1. Gated Recurrent Unit
2. Multivariable power rating curve

(& Maghrebi, 2024):

$$\frac{Q_e}{Q_r} = \left(\frac{A_e}{A_r}\right)^{a_1} \left(\frac{P_e}{P_r}\right)^{a_2} \left(\frac{T_e}{T_r}\right)^{a_3} \left(\frac{U_e}{U_r}\right)^{a_4} \quad (2)$$

که در آن، زیرنویس e نشان دهنده‌ی تراز است که دبی در آن برآورد می‌شود و زیرنویس r نیز به تراز مرجع یا به عبارتی میزان فراسنجه‌های مشخص شده در تراز است که دبی در آن اندازه‌گیری شده است، اشاره دارد.

پیش از واسنجی مدل، شناسایی فراسنجه‌های مؤثر ضروری است. برای این منظور، می‌توان از روش‌های مختلف انتخاب ویژگی مانند تحلیل همبستگی استفاده کرد. پس از شناسایی فراسنجه‌ها، نوبت به واسنجی کردن مدل می‌رسد. رویکرد واسنجی در این مدل پیشنهادی، از الگوی روش‌های یادگیری ماشینی تقلید می‌کند. در این روش، شماری از داده‌های یک ایستگاه مشاهده‌ای به عنوان داده‌های آموزشی و باقی‌مانده‌ی داده‌ها برای ارزیابی مدل استفاده می‌شوند. به این ترتیب، مدل برای هر ایستگاه به صورت محلی واسنجی می‌شود. برای واسنجی مدل، می‌توان از روش MCMC استفاده کرد. نکته‌ی دیگری که باید در نظر گرفته شود، مدل حاکم بر متغیرهای هیدرولیکی و دبی است. افزون بر مدل MPRC (معادله ۲)، می‌توان از رویکردهای یادگیری ماشینی مانند ANFIS نیز برای مدل‌سازی این رابطه با همان متغیرهای هیدرولیکی بهره جست.

۲-۲- تحلیل عدم قطعیت با روش MCMC

در آمار کلاسیک، فراسنجه‌های توزیع آماری مانند میانگین و واریانس به عنوان میزان‌های ثلثت و ناشناخته در نظر گرفته می‌شوند. این فراسنجه‌ها با استفاده از آمار نمونه^۱ برآورد می‌شوند. روش‌های رایج برای برآورد این فراسنجه‌ها شامل برآورد بیشینه احتمال^۲ و روش گشتاور^۳ است. پس از برآورد فراسنجه‌ها و در نظر گرفتن عدم قطعیت‌های مرتبط، می‌توان فاصله‌های اطمینان را محاسبه کرد. در مقابل، رویکرد بیزین با فراسنجه‌ها به عنوان متغیرهای تصادفی با توزیع‌های احتمالی رفتار می‌کند. این رویکرد،

توزیع پیشین^۴ را که معرف دانش پیشین ما در مورد فراسنجه‌ها است، در نظر می‌گیرد و پس از آن با استفاده از داده‌های مشاهده‌شده، توزیع پسین^۵ را که معرف توزیع به‌روز شده‌ی فراسنجه‌ها است، به دست می‌آورد. توزیع پسین، عدم قطعیت موجود در برآورد فراسنجه‌ها را به طور کامل در بر می‌گیرد.

محاسبه‌ی توزیع پسین در نظریه بیزین، به دلیل پیچیدگی‌های ریاضی و محاسبه‌ای، چالش برانگیز است. روش زنجیره‌ی مارکوف مونت کارلو (MCMC) با تولید نمونه‌های متعدد از توزیع پسین، ماهیت دقیق آن را آشکار می‌کند (Van de Schoot et al., 2021). این روش بر دو مفهوم کلیدی بنا شده است: زنجیره‌ی مارکوف برای نمونه‌گیری از توزیع هدف و شبیه‌سازی مونت کارلو برای محاسبه‌ی آماره‌های توزیع پسین بر مبنای فراسنجه‌های نمونه‌گیری شده. به طور خلاصه، MCMC با پیمایش یک مسیر زنجیره‌وار در فضای فراسنجه، به تدریج به سمت توزیع پسین همگرا می‌شود. در هر گام از زنجیره، یک فراسنجه جدید بر مبنای فراسنجه کنونی و یک توزیع پیشنهادی^۶ تولید می‌شود. این فرآیند تکرار می‌شود تا زنجیره به تعادل برسد و نمونه‌های تولیدشده، بازتابی از توزیع پسین باشند. در میان الگوریتم‌های پرشمار MCMC برای نمونه‌گیری از توزیع‌های احتمالی پیچیده، الگوریتم متروپلیس-هیستینگز^۷ به عنوان یکی از پرکاربردترین الگوریتم‌ها شناخته می‌شود (Wang et al., 2017). این الگوریتم برای برآورد توزیع هدف $\pi(\theta|D)$ به یک توزیع پیشنهادی کمکی $q(\theta^*|\theta^{(t+1)})$ نیاز دارد. مرحله‌های الگوریتم متروپلیس-هیستینگز به طور خلاصه به شرح زیر است:

- (۱) در آغاز، یک فراسنجه اولیه $\theta^{(t-1)}$ انتخاب می‌شود.
- (۲) در گام t، یک مقدار جدید θ^* از توزیع پیشنهادی $q(\theta^*|\theta^{(t-1)})$ نمونه‌گیری می‌شود.
- (۳) نسبت پذیرش α با استفاده از معادله‌ی (۳) محاسبه می‌شود:

1. Sample statistics
2. Maximum likelihood estimation
3. Method of moments
4. Prior distribution

5. Posterior distribution
6. Proposal distribution
7. Metropolis-Hastings

MCMC موضوعی مورد بحث است. برخی پژوهش‌ها مانند Gelman et al. (1997) مقدار ۰/۴۵ را برای تک فراسنجه و ۰/۲۳ را برای چند فراسنجه پیشنهاد می‌کنند، در حالی که برخی دیگر مانند Rosenthal (2014) محدوده‌ی ۰/۲ تا ۰/۵ را قابل قبول می‌دانند.

مرحله‌های گام‌به‌گام استفاده از روش MCMC در واسنجی و تحلیل عدم قطعیت مدل پیشنهادی عبارت‌اند از:

(۱) مدل دبی-اشل پیشنهادی، معادله‌ی (۲)، در نظر گرفته می‌شود.

(۲) مجموعه‌ای از فراسنجه‌ها که توسط بردار θ در مدل پیشنهادی تعریف شده‌اند، تعیین می‌شوند.

(۳) مقدارهای اولیه θ به طور تصادفی از توزیع گاوسی $(\mu, C) \sim N$ تعیین می‌شوند. در این پژوهش، مقدار میانگین (μ) برای همه‌ی فراسنجه‌ها برابر با ۱ در نظر گرفته شده و ماتریس کوواریانس (C) نیز از طریق آزمون و خطا تعیین می‌شود.

(۴) هر جست‌وجوی تصادفی فضای فراسنجه را کاوش خواهد کرد. در این فرآیند، هر جست‌وجو یک گام به سمت مجموعه‌ای جدید از مقادیرها برای بردار فراسنجه (θ) برمی‌دارد و مدلی با این مقادیرها ایجاد می‌کند.

(۵) نتایج مدل با داده‌های مشاهده شده از طریق χ^2 (معادله‌ی ۴) مقایسه می‌شود:

$$\chi^2 = \sum_i \frac{(Q_{o,i} - Q_{e,i})^2}{2\sigma_i^2} \quad (4)$$

که در آن، Q_e دبی برآوردشده، Q_o دبی مشاهده‌ای و σ^2 واریانس خطای داده‌ها را نشان می‌دهد. برای برآورد σ^2 می‌توان از عدم قطعیت تجربی یا برآوردهای آماری مانند بیشینه احتمال و کمترین مربعات بهره برد.

(۶) ساخت تابع درست‌نمایی: در این راستا، از توزیع نرمال (گاوسی) با میانگین صفر و واریانس ثابت به عنوان مدل آماری رایج برای ساخت تابع درست‌نمایی استفاده می‌شود که در معادله‌ی (۵) بیان شده است:

$$\pi(D|\theta) = \exp[-\chi^2] \quad (5)$$

(۷) الگوریتم MCMC مدل‌های جدید را با مدل کنونی

$$\alpha = \min \left\{ 1, \frac{\pi(\theta^*|D) q(\theta^{t-1}|\theta^*)}{\pi(\theta^{t-1}|D) q(\theta^*|\theta^{t-1})} \right\} \quad (3)$$

که در این رابطه، $\pi(\cdot)$ تابع توزیع هدف، D مجموعه داده‌های ورودی-خروجی، θ فراسنجه‌های مدل و $q(\cdot)$ توزیع پیشنهادی است.

(۴) یک عدد تصادفی u از توزیع یکنواخت $u \sim U[0,1]$ ایجاد می‌شود.

(۵) اگر $u < \alpha$ ، آنگاه $\theta^{(t)} = \theta^*$ در غیر این صورت $\theta^{(t)} = \theta^{(t-1)}$ و $t = t+1$.

(۶) مرحله‌های ۲ تا ۵ تکرار می‌شوند تا هنگامی که زنجیره به تعادل برسد و نمونه‌های تولید شده نماینده‌ی مناسبی از توزیع هدف باشند.

انتخاب هوشمندانه‌ی تابع پیشنهادی، کلید افزایش سرعت همگرایی، بهبود کاوش در فضای جست‌جو و در نهایت، ارتقای عملکرد کلی الگوریتم است. تابع پیشنهادی، که با $(\theta^{(t+1)} | \theta^*)$ نشان داده می‌شود، نقش بنیادی در

هدایت الگوریتم در فضای جست‌جو ایفا می‌کند. اگرچه از دید نظری، این تابع را می‌توان به دلخواه انتخاب کرد، اما انتخاب دقیق آن تأثیر قابل توجهی بر کارایی محاسبه‌ای الگوریتم دارد. در میان توابع پیشنهادی مختلف، توزیع نرمال به دلیل سادگی و کارایی بالا، به‌طور گسترده‌ای استفاده می‌شود (Reis & Stedinger, 2005). کارایی یک

عامل مهم است که هنگام استفاده از الگوریتم‌های متروپلیس-هیستینگ باید در نظر گرفته شود. نسبت پذیرش^۱، که سرعت همگرایی الگوریتم و کارایی آن در کاوش فضای جست‌جو را نشان می‌دهد، از جمله معیارهای مهم سنجش کارایی این الگوریتم‌ها است. میزان پذیرش پایین در الگوریتم‌های MCMC می‌تواند منجر به تولید اعداد تصادفی نادرست و ناکافی بودن کاوش فضای جست‌جو شود. انتخاب توزیع پیشنهادی مناسب، استفاده از روش‌های تطبیقی و افزایش شمار گام‌های زنجیره MCMC می‌تواند به بهبود عملکرد این الگوریتم‌ها و دستیابی به نتایج دقیق‌تر کمک کند. از سوی دیگر، نسبت پذیرش مطلوب برای برآورد فراسنجه در الگوریتم‌های

۲-۳- سامانه استنتاج عصبی فازی تطبیقی (ANFIS)

سامانه استنتاج عصبی فازی تطبیقی^۱ (ANFIS) روشی ترکیبی از شبکه‌های عصبی و منطق فازی است. این ادغام به کسب مزایای هر دو در یک چارچوب واحد منجر می‌شود. به همین دلیل، ANFIS به عنوان یک ابزار با قدرت برای برآورد میزان‌ها عمل می‌کند و با مجموعه‌ای از قوانین اگر-آنگاه فازی کار می‌کند که می‌توانند رابطه‌های پیچیده بین ورودی‌ها و خروجی‌ها را مدل‌سازی کنند. فراسنجه‌های ANFIS با استفاده از ترکیبی از الگوریتم‌های یادگیری تنظیم می‌شوند: پس‌انتشار برای فراسنجه‌های مرتبط با تابع‌های عضویت^۲ ورودی و حداقل مربعات برای فراسنجه‌های مرتبط با تابع‌های عضویت خروجی. این فرآیند به کاهش خطا در آموزش و بهبود فرآیند یادگیری کمک می‌کند.

الگوریتم خوشه‌بندی فازی^۳ اطلاعات لازم برای ساخت سامانه استنتاج فازی، از جمله قانون‌های ابتدایی و ساختار فازی را فراهم می‌کند (Cobaner, 2011). با استفاده از این روش خوشه‌بندی، ممکن است سامانه‌های استنتاج فازی مدل‌های پیچیده‌ای را برای ارتباط بین ورودی‌ها و فضای خروجی ارائه دهند.

برای استفاده‌ی مؤثر از داده‌های ورودی در ANFIS، ویژگی‌های آن داده‌ها باید از طریق قوانین خاص استخراج شوند. این قوانین بر مبنای مقدمات (بخش اگر) و نتایج (بخش آنگاه) تعریف می‌شوند. در مدل سوگنو^۴، قوانین به صورت توابع خطی از ورودی‌ها هستند، دو ورودی (x و y) و یک خروجی (f) در معادله‌های (۶) و (۷) ارائه شده است (Yaseen et al., 2017):

$$\text{Rule 1: If } x \text{ is } P_1 \text{ and } y \text{ is } Q_1; \text{ then } f_1 = p_1x + q_1y + r_1 \quad (6)$$

$$\text{Rule 2: If } x \text{ is } P_2 \text{ and } y \text{ is } Q_2; \text{ then } f_2 = p_2x + q_2y + r_2 \quad (7)$$

که در آن‌ها P_i و Q_i تابع‌های عضویت ورودی‌های x و y هستند. f_i نماینده‌ی میانگین وزنی خروجی‌های از یک قانون خاص است، در حالی که p_i ، q_i و r_i فراسنجه‌های تابع

و داده‌ها مقایسه می‌کند. اگر مدل جدید کارایی بهتری در تطبیق با داده‌ها داشته باشد، جستجو به طور تصادفی به سمت آن مدل جدید هدایت می‌شود. در غیر این صورت، جستجو مسیر جدیدی را امتحان می‌کند یا در جای خود باقی می‌ماند. نسبت پذیرش از گیر افتادن جستجوهای تصادفی در مدل‌هایی با احتمال بالا که به حتم بهترین مدل‌ها نیستند، جلوگیری می‌کند.

۸) جستجوهای تصادفی به طور پیوسته در فضای فراسنجه مدل انجام می‌شوند تا به ناحیه‌های با بالاترین احتمال در بین مدل‌ها برسند. پس از پایان این فرآیند، توزیع پسین فراسنجه‌ها به دست می‌آید. میانگین این توزیع پسین به عنوان برآورد بهینه‌ی فراسنجه‌های مدل در نظر گرفته می‌شود. همچنین، می‌توان از توزیع پسین برای محاسبه‌ی فاصله اطمینان ۹۵ درصدی فراسنجه‌ها استفاده کرد.

روندنامی فرآیند واسنجی و تحلیل عدم قطعیت مدل MPRC توسط الگوریتم متروپلیس-هیستینگز در شکل ۱ ارائه شده است.

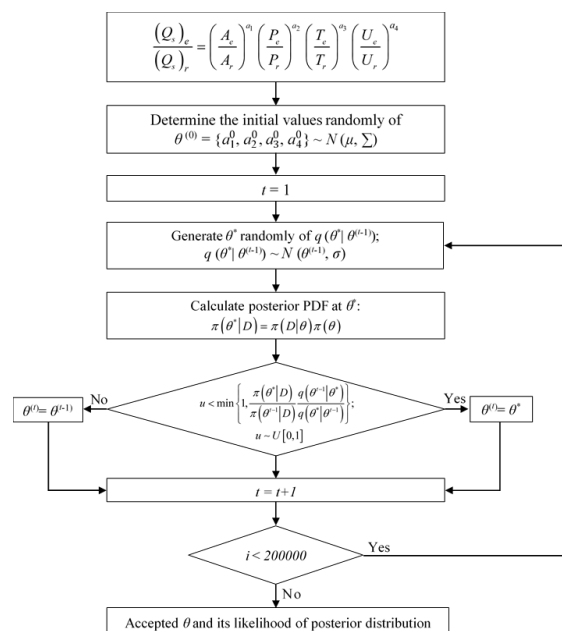


Fig. 1 Flowchart of Metropolis-Hastings algorithm for the parameter estimation using the MCMC approach
 شکل ۱ روندنامی الگوریتم متروپلیس-هیستینگز برای برآورد فراسنجه‌های مدل پیشنهادی با استفاده از روش MCMC

3. Fuzzy C-means (FCM) clustering
 4. Sugeno

1. Adaptive neuro-fuzzy inference system
 2. Membership functions

لایه‌ی پیش‌نرمال‌سازی می‌شوند (معادله‌ی ۱۰). هر گره وزن یک قاعده را بر مجموع همه وزن‌های قواعد تقسیم می‌کند تا مقدار نرمال‌شده برای هر قاعده به دست آید:

$$\bar{w}_i = \frac{w_i}{(w_1 + w_2)} \quad (i = 1, 2) \quad (10)$$

که در آن، \bar{w}_i درجه‌ی عضویت نرمال‌شده‌ی قانون i است. لایه‌ی ۴ (ضرب نرمال‌سازی شده): این لایه خروجی‌های نرمال‌سازی شده از لایه‌ی پیش را با یک تابع متناظر با هر قانون ضرب می‌کند (معادله‌ی ۱۱):

$$\bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (11)$$

این تابع ممکن است خطی یا غیرخطی باشد و برای هر قاعده متفاوت است.

لایه‌ی ۵ (تجمیع): در این لایه، خروجی‌های هر گره از لایه‌ی پیش تجمیع می‌شوند تا خروجی نهایی سامانه به دست آید (معادله‌ی ۱۲) که نتیجه‌ی ترکیب همه قواعد فازی بر مبنای ورودی‌های داده شده است:

$$\sum \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (12)$$

این مرحله‌ها به ANFIS اجازه می‌دهد تا الگوهای پیچیده و غیرخطی را یاد بگیرد و توانایی پیش‌بینی و تحلیل داده‌ها را در شرایط مختلف بهبود بخشد. شایان یادآوری است که در این پژوهش از نرم افزار متلب برای پیاده‌سازی ANFIS استفاده شده است. ساختار نهایی مدل در جدول ۱ ارائه شده است.

جدول ۱ ابرفراسنجه‌های تنظیم‌شده برای ANFIS

Table 1 Tuned hyperparameters for ANFIS	
Tuned hyperparameters	
number of clusters=	100
Epoch =	500
Learning rate =	0.01

۲-۴- منحنی دبی-اشل کلاسیک (CRC)

ایجاد یک رابطه‌ی دبی-اشل به منظور تبدیل داده‌های پیوسته‌ی تراز آب به دوره‌های زمانی جریان، روشی ساده برای نظارت بر جریان‌ها در ایستگاه‌های اندازه‌گیری است. این تابع، که اغلب به عنوان منحنی سنجه‌ی رودخانه به

خروجی را تعیین می‌کنند. شکل ۲ ساختار مدل ANFIS را به صورتی که دارای دو ورودی و یک خروجی است، نمایش می‌دهد.




Fig. 2 ANFIS model architecture (Yaseen et al., 2017)

شکل ۲ معماری مدل (Yaseen et al., 2017) ANFIS

وظیفه هر لایه در ANFIS به شرح زیر است (Vatanchi et al., 2023):

لایه‌ی ۱ (فازی‌سازی): در این لایه، هر گره متناسب با توابع عضویت فازی است که ورودی‌ها را به درجه‌های عضویت فازی تبدیل می‌کند. هر گره ورودی‌های عددی را می‌گیرد و خروجی‌هایی را تولید می‌کند که نشان‌دهنده‌ی درجه‌ی تعلق هر ورودی به یک مجموعه‌ی فازی خاص است. تابع‌های عضویت مختلفی، از جمله سیگموئید، مثلثی، گاوسی و دوزنقه‌ای، در مدل‌های ANFIS به کار می‌رود. برای مثال، تابع‌های عضویت گاوسی تعمیم‌یافته به صورت معادله‌ی (۸) تعریف می‌شوند:

$$\mu_{Ni} = \frac{1}{1 + [(x - c_i)/a_i]^{2b_i}} \quad (8)$$

که در آن، $\{a_i, b_i, c_i\}$ مجموعه‌ی فراسنجه‌های تابع هستند.

لایه‌ی ۲ (اعمال قواعد): در این لایه، خروجی‌های لایه پیش ضرب می‌شوند (معادله‌ی ۹) تا قدرت یا وزن هر قانون فازی محاسبه شود:

$$w_i = \mu_{Ai}(x) \mu_{Bi}(y) \quad (i = 1, 2) \quad (9)$$

که در آن، μ_{Ai} درجه عضویت x در مجموعه A_i و μ_{Bi} درجه عضویت y در مجموعه B_i است. هر گره در این لایه نشان‌دهنده‌ی یک قاعده‌ی فازی است و خروجی آن وزن نسبی آن قاعده (که از ضرب درجه‌های عضویت به دست می‌آید) می‌باشد.

لایه‌ی ۳ (نرمال‌سازی): در این لایه، وزن‌های حاصل از

شیب بستر است.

نرم افزار سامانه برآورد انتقال^۲ (CES) برای حل عددی رابطه‌ی (۱۴) توسعه پیدا کرده است. این نرم افزار می‌تواند افزون بر برآورد منحنی دبی-اشل، اثرگذاری‌های آب برگشتی و عدم قطعیت منحنی دبی-اشل را نیز بررسی کند.

۲-۶- رودخانه مورد مطالعه

رودخانه‌ی کارون از مهم‌ترین رودخانه‌های ایران است که طی مسیر طولانی خود به آبادانی بسیاری از شهرها و روستاها کمک کرده است. ایستگاه آب‌سنجی ملاثانی، که در حدود ۶۵ کیلومتری شمال اهواز قرار دارد، از جمله ایستگاه‌های مهم این رودخانه است. شکل ۳ نمایی از رودخانه در محدوده‌ی ایستگاه ملاثانی، به همراه مقطع عرضی و تصویری از خود ایستگاه نشان می‌دهد. شیب طولی رودخانه در این نقطه نزدیک به ۰/۰۰۰۱ و ضریب زبری آن ۰/۰۲۵ برآورد شده است (Zahiri et al., 2009). اطلاعات مشاهده‌ای دبی در شکل ۴ نمایش داده شده است، که در آن ۶۰ درصد از داده‌ها برای آموزش و ۴۰ درصد برای آزمایش مدل استفاده می‌شوند. اندازه‌گیری دبی و تراز از تاریخ ۱۴۰۰/۷/۱ تا ۱۴۰۲/۷/۱، به صورت دو بار در روز انجام شده است. لازم به یادآوری است، نبود داده‌های کافی در دوره‌های خشکسالی و ترسالی، از جمله چالش‌های رایج در بررسی و ارزیابی‌های هیدرولوژی است. این محدودیت می‌تواند بر دقت مدل‌سازی‌ها و پیش‌بینی‌ها تاثیر بگذارد. میزان فراسنجه‌های آماری داده‌های دبی و تراز در ایستگاه ملاثانی در جدول ۲ ارائه شده است.

۲-۷- آماده‌سازی داده‌ها

آماده‌سازی داده‌ها، فرآیندی ضروری است که داده‌های خام را به اطلاعات قابل استفاده برای مدل‌سازی تبدیل می‌کند. پس از گردآوری داده‌ها، کاستی‌ها، خطاها و ناسازگاری‌های موجود شناسایی و اصلاح می‌شوند تا از صحت و اعتبار اطلاعات برای تحلیل و گزارش‌دهی اطمینان حاصل شود.

کار می‌رود، یک تابع توانی منحصر به فرد است. با این حال، لازم است توجه داشت که این روش تنها در شرایط جریان دائمی کاربرد دارد. در مورد جریان‌های غیردائمی که در طبیعت رایج هستند، این رویکرد ممکن است ناکافی باشد و منبع قابل توجهی از خطاها را به همراه داشته باشد (Dottori et al., 2009). این روش (معادله‌ی (۱۳)) توسط Dymond & Christian (1982)، Herschy (2009) و Pappenberger et al. (2006) استفاده شده است:

$$Q_s = a_1(H - a_2)^{a_3} \quad (13)$$

که در آن، Q_s دبی برآوردشده در شرایط جریان دائمی است و a_1 ، a_2 و a_3 فراسنجه‌های واسنجی هستند که به‌طور معمول با روش کمترین مربعات^۱ تعیین می‌شوند (Petersen-Øverleir, 2004).

۲-۵- مدل هیدرولیکی شیونو و نایت (SKM)

در سال‌های اخیر، با استفاده از معادله‌های دیفرانسیلی حاکم بر جریان و حل آن‌ها در مقطع‌های مختلف هندسی با شرایط مرزی پیچیده در فضاهای دو یا سه‌بعدی، برآورد دبی با کمک مدل‌های هیدرولیکی امکان پذیر شده است. از جمله این روش‌ها، روش شیونو و نایت (SKM) است. در این روش، معادله‌ی لنزازه حرکت متوسط عمقی جریان برای جریان آشفته یکنواخت و دائمی حل می‌شود. در یک آبراهه باز منشوری، معادله‌ی لنزازه حرکت در یک جریان یکنواخت دائمی را می‌توان با معادله‌ی پیوستگی ترکیب کرد تا رابطه‌ی (۱۴) به‌دست آید (Abril & Knight, 2004):

$$\rho \left[\frac{\partial UV}{\partial y} + \frac{\partial UW}{\partial z} \right] = \rho g S_0 + \frac{\partial}{\partial y} (-\rho \overline{uv}) + \frac{\partial}{\partial z} (\rho \overline{uw}) \quad (14)$$

که در آن (U, V, W) مولفه‌های سرعت میانگین به ترتیب در جهت‌های x (جهت جریان)، y (جانبی) و z (عمود بستر) هستند. (u, v, w) نوسان‌های آشفته‌ی سرعت نسبت به میانگین هستند، ρ چگالی آب، g شتاب گرانشی و S_0

هستند و می‌توانند بر دقت تحلیل‌ها و تفسیر داده‌ها تأثیر منفی گذارند. در این پژوهش، از برآورد چگالی هسته‌ای^۱ (KDE) برای یافتن داده‌های پرت استفاده شده است (Latecki et al., 2007). با این محدودیت که هیچ داده‌ای اوج حذف نشود. KDE، که یک روش یادگیری بدون نظارت و نافراسنجه‌ای است، برای برآورد تابع چگالی احتمال (PDF) داده‌ها به کار رفته است. این روش با استفاده از تابع کرنل، توزیع احتمالی داده‌ها را بررسی می‌کند و داده‌هایی که در ناحیه‌های با چگالی پایین قرار دارند را به عنوان نقطه‌های پرت شناسایی می‌کند.

این فرآیند شامل شناسایی داده‌های پرت، حذف مقادیرهای گم‌شده و استانداردسازی داده‌هاست. همچنین، به دلیل وجود شمار زیادی ویژگی در برخی مجموعه‌های داده‌ها، فرآیند انتخاب ویژگی به کار گرفته می‌شود تا تنها ویژگی‌های مرتبط و کلیدی برای مدل نگه داشته و بقیه حذف شوند.

در بررسی اطلاعات مربوط به جریان رودخانه، یافتن نقطه‌های پرت برای تضمین صحت داده‌ها دارای اهمیت بالایی است. نقطه‌های پرت به داده‌هایی اطلاق می‌شود که به‌طور چشمگیر از الگوی کلی یا روند مورد انتظار منحرف

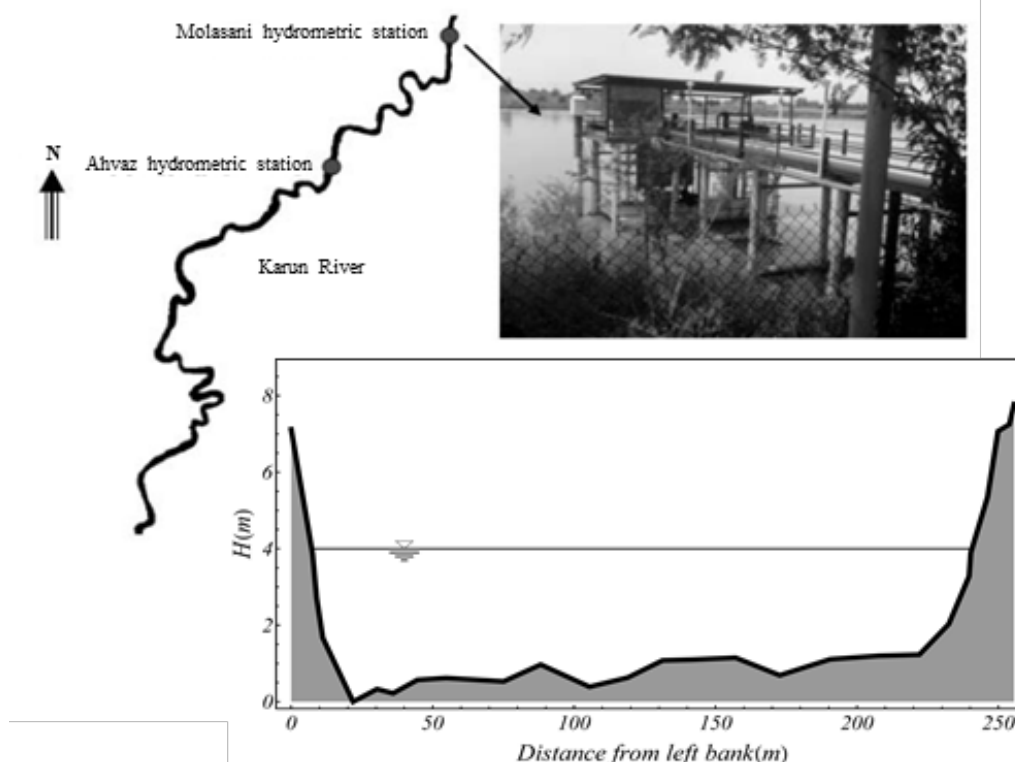


Fig. 3 A view of the Karun River and Molasani hydrometric station (Zahiri et al., 2009)

شکل ۳ نمایی از رودخانه‌ی کارون و ایستگاه آب‌سنجی ملاتانی (Zahiri et al., 2009)




Fig. 4 Streamflow data of the Karun River at Molasani hydrometry station

شکل ۴ داده‌های جریان رودخانه‌ی کارون ایستگاه ملاتانی

جدول ۲ میزان فراسنجه‌های آماری داده‌های جریان و تراز رودخانه کارون در ایستگاه ملاسانی

Table 2 The statistical characteristics of the streamflow and water level data of the Karun river at Molasani hydrometry station

Quantity	Mean value	Min value	Max value	Standard deviation	Coefficient of variation	Skewness	Kurtosis
Water level, H (m)	1.88	0.81	5.7	0.93	0.5	1.46	1.86
Streamflow, Q (m ³ /s)	346	117	1238	211	0.61	1.56	2.27

به‌ویژه هنگامی که واحدهای اندازه‌گیری متفاوتی وجود داشته باشد یا داده‌ها در بازه‌های متفاوتی باشند. دو روش متداول برای استانداردسازی داده‌ها شامل موارد زیر است:

روش اول) استانداردسازی Z (Z-score):

در این روش، از هر داده میانگین کل مجموعه داده‌ها کم شده و نتیجه بر انحراف معیار کل مجموعه تقسیم می‌شود. این کار باعث می‌شود که داده‌ها در توزیعی با میانگین صفر و انحراف معیار یک قرار گیرند. ترکیب‌بندی استانداردسازی Z به صورت رابطه‌ی (۱۵) بیان می‌شود:

$$X_i^n = \frac{(X_i - \mu_i)}{\sigma_i} \quad (15)$$

که در آن، X_i^n نشان‌دهنده‌ی مقدار استاندارد شده بوده، X_i مقدار اولیه‌ی داده، μ ؛ میانگین داده‌ها و σ ؛ انحراف معیار داده‌ها است.

روش دوم) استانداردسازی کمینه-بیشینه

در این روش استانداردسازی، مقدار کمینه در کل مجموعه داده‌ها از هر داده کسر می‌شود. آن‌گاه، حاصل بر دامنه (تفاوت بین بیشترین و کمترین مقدار) تقسیم می‌شود. این فرآیند باعث می‌شود که همه داده‌ها در بازه‌ی صفر تا یک قرار گیرند. ترکیب‌بندی استانداردسازی کمینه-بیشینه به صورت رابطه‌ی (۱۶) است:

$$X_i^n = \frac{(X_i - X_{min})}{X_{max} - X_{min}} \quad (16)$$

که در آن X_{min} و X_{max} به ترتیب کمینه و بیشینه مقدار داده‌ها هستند.

مرحله‌های استفاده از KDE برای تشخیص نقطه‌های پرت به شرح زیر است:

۱- داده‌های مربوط به جریان رودخانه گردآوری می‌شود.

۲- فراسنجه پهنای نوار برای تنظیم نرمی منحنی چگالی برآورد شده با استفاده از تابع کرنل مناسب مانند توزیع گاوسی تعیین می‌شود.

۳- با استفاده از تابع کرنل و پهنای نوار انتخاب شده، تابع چگالی احتمال برای داده‌های نمونه محاسبه می‌شود.

۴- با استفاده از تابع چگالی برآورد شده، مقدار آستانه تعیین می‌شود.

۵- نقطه‌های پرت به عنوان داده‌هایی با احتمال پایین‌تر از آستانه تعریف می‌شود.

دو رویکرد کلی برای مواجهه با داده‌های گمشده وجود دارد: حذف و جایگزینی. در این پژوهش، برای مدیریت داده‌های گمشده از روش جایگزینی با درونیابی استفاده شده است. این روش بر پایه‌ی برآورد داده‌های گمشده بر مبنای داده‌های مجاور استوار است. روش‌های چندی برای درونیابی وجود دارد که هر کدام برتری‌ها و کاستی‌های خاص خود را دارند. در این بررسی، از روش درونیابی اسپلاین^۱ استفاده شده است. باید توجه داشت که داده‌های پرت می‌توانند تأثیر قابل توجهی بر فرآیند درونیابی داشته باشند و ممکن است منجر به برآوردهای نادرست برای داده‌های گمشده شوند.

استانداردسازی داده‌ها فرآیندی است که داده‌ها را به یک مقیاس واحد تبدیل می‌کند. این عمل، مقایسه‌ی داده‌ها بین متغیرها یا مشاهده‌های متفاوت را ساده‌تر می‌سازد،

1. Spline

۷-۲- ارزیابی مدل

ارزیابی مدل گامی ضروری برای اطمینان از کارایی و تعمیم‌پذیری آن است. این فرآیند شامل بررسی عملکرد مدل بر روی داده‌های دیده‌نشده برای شناسایی نقطه‌های قوت و ضعف آن است. همچنین، برای تعیین ابرفراسنجی‌های مدل، لازم است که مدل آموزش‌دیده بر روی مجموعه داده‌های اعتبارسنجی ارزیابی شود.

اعتبارسنجی متقابل^۶ یک روش آماری است که برای ارزیابی عملکرد مدل‌های یادگیری ماشین استفاده می‌شود. در این پژوهش از روش‌های اعتبارسنجی متقابل K-Fold استفاده شده است. در اعتبارسنجی متقابل K-Fold، داده‌ها به K قسمت با اندازه‌ی یکسان تقسیم می‌شوند. مدل بر روی K-1 قسمت از مجموعه داده آموزش داده شده و بر روی قسمت باقی‌مانده ارزیابی می‌شود. این فرآیند K بار تکرار می‌شود، به طوری که هر قسمت یک‌بار به‌عنوان مجموعه‌ی اعتبارسنجی استفاده می‌شود.

معیارهای ارزیابی مختلفی برای سنجش عملکرد مدل‌ها در بخش‌های گوناگون این تحقیق به کار گرفته شده است. این روش‌ها عبارت‌اند از: معیار کارایی کلینگ-گوپتا^۷ (KGE) (رابطه‌ی ۱۸)، شاخص پراکندگی^۸ (SI) (رابطه‌ی ۱۹)، شاخص توافق^۹ (d) (رابطه‌ی ۲۰) و درصد انحراف^{۱۰} (PBIAS) (رابطه‌ی ۲۱). رابطه‌های مربوطه در ادامه آورده شده است:

$$KGE = 1 - \sqrt{(r-1)^2 + \left(\frac{\bar{Q}_e}{\bar{Q}_o} - 1\right)^2 + \left(\frac{CV_e}{CV_o}\right)^2} \quad (18)$$

$$SI(\%) = \frac{RMSE}{\bar{Q}_o} \times 100 \quad (19)$$

$$d = 1 - \frac{\sum_{i=1}^N |Q_e - Q_o|}{2 \sum_{i=1}^N |Q_o - \bar{Q}_o|} \quad (20)$$

$$PBIAS(\%) = \frac{\sum_{i=1}^N [(Q_o)_i - (Q_e)_i] \times 100}{\sum_{i=1}^N (Q_o)_i} \quad (21)$$

که در آن‌ها زیرنویس‌های o و e به ترتیب به داده‌های

لازم به یادآوری است که بسیاری از الگوریتم‌های یادگیری ماشین، مانند رگرسیون خطی و شبکه‌های عصبی مصنوعی، برای دستیابی به عملکرد بهینه به داده‌های استاندارد شده نیاز دارند. در این پژوهش، از هر دو روش یاد شده استفاده شد و عملکرد آن‌ها به طور کامل بررسی شد. شایان یادآوری است، نتایج بهترین روش در بخش یافته‌ها ارائه خواهد شد.

انتخاب ویژگی فرآیندی است که در آن، از میان داده‌های موجود، زیرمجموعه‌ای از ویژگی‌ها که از اهمیت و ارتباط بالاتری برخوردارند، انتخاب می‌شوند. انتخاب ویژگی درست می‌تواند در جنبه‌های مختلف از جمله افزایش سرعت یادگیری، بهبود توانایی تعمیم و ساده‌سازی مدل نهایی مؤثر باشد.

روش‌های انتخاب ویژگی به سه دسته تقسیم می‌شوند: روش‌های فیلتر^۱، روش‌های بسته‌بندی^۲ و روش‌های جاسازی‌شده^۳. روش فیلتر، ساده‌ترین و رایج‌ترین روش در این میان است که به صورت مستقل از الگوریتم‌های یادگیری ماشین، ویژگی‌ها را رتبه‌بندی می‌کند و برای پایگاه‌های داده با ابعاد بالا مناسب است. این روش‌ها به‌طور معمول بر مبنای معیارهایی چون همبستگی^۴ و اطلاعات متقابل^۵ دسته‌بندی می‌شوند. در روش تحلیل همبستگی (رابطه‌ی ۱۷)، مقدار وابستگی هر ویژگی با خروجی مورد انتظار محاسبه می‌شود:

$$\rho_{X_K, Y} = \frac{\text{cov}(X_K, Y)}{\sigma_{X_K} \sigma_Y} \quad (17)$$

که در آن، کواریانس بین دو متغیر تصادفی X و Y با نماد $\text{cov}(X, Y)$ نشان داده می‌شود. σ_X و σ_Y به ترتیب انحراف معیارهای X و Y هستند. زیرنویس K به یکی از ویژگی‌های مجموعه‌ی X اشاره دارد. ضریب همبستگی نیز با ρ معرفی می‌شود. ویژگی‌هایی که ضریب همبستگی بالاتری دارند، مناسب‌تر تلقی می‌شوند.

6. Cross-validation
7. Kling-Gupta efficiency
8. Scatter index
9. Index of agreement
10. Percent bias

1. Filter
2. Wrapper
3. Embedded
4. Correlation
5. Mutual information

بنابراین، از بین P و T فراسنجه T که همبستگی کمتری نسبت به Q دارد، حذف می‌شود. در نتیجه، توان a₃ در مدل MPRC (معادله ۲) برابر صفر می‌شود. در این مدل با تغییر فراسنجه‌های هیدرولیکی با تراز اثر تغییر ناگهانی در مقطع عرضی (اثر سیلاب‌دشت) در برآورد دبی رودخانه لحاظ می‌شود.

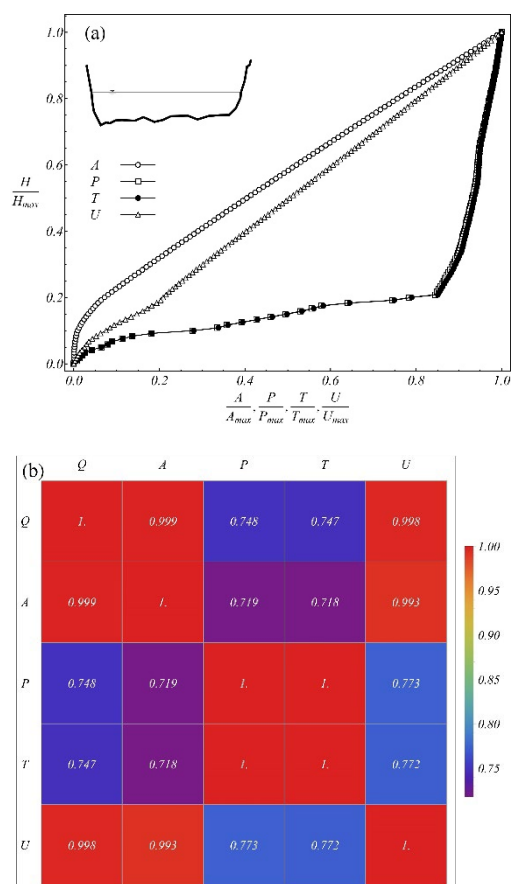


Fig. 6 (a) Changes of hydraulic parameters with stages and (b) correlation between hydraulic parameters and discharge in Karun River

شکل ۶ (a) تغییرپذیری فراسنجه‌های هیدرولیکی با تراز و (b) میزان همبستگی بین فراسنجه‌های هیدرولیکی و دبی جریان در رودخانه‌ی کارون

پس از انجام فرآیند واسنجی با کمک روش MCMC، مقادیر بهینه‌ی فراسنجه‌های مدل MPRC، a₁، a₂ و a₄ به ترتیب عبارتند از: ۰/۲۶۵، ۰/۰۸۲- و ۰/۷۴۳. شکل ۷ نتایج برآورد دبی جریان توسط این مدل را بر روی داده‌های آزمایشی نشان می‌دهد. این نتایج نشان‌دهنده‌ی سازگاری قابل قبولی بین مقدارهای پیش‌بینی‌شده توسط مدل و داده‌های

مشاهده‌ای و برآوردشده اشاره دارند. N شمار داده‌های مشاهده‌شده است و RMSE ریشه‌ی میانگین مربعات خطا است. \bar{Q}_e و \bar{Q}_o به ترتیب میانگین دبی مشاهده‌شده و دبی برآوردی هستند. r ضریب همبستگی^۱ و CV ضریب تغییر^۲ است. هر چه KGE و d به یک و SI و PBIAS به صفر نزدیک‌تر باشند، عملکرد مدل بهتر است.

روندنمای کلی تحقیق در شکل ۵ ارائه شده است.

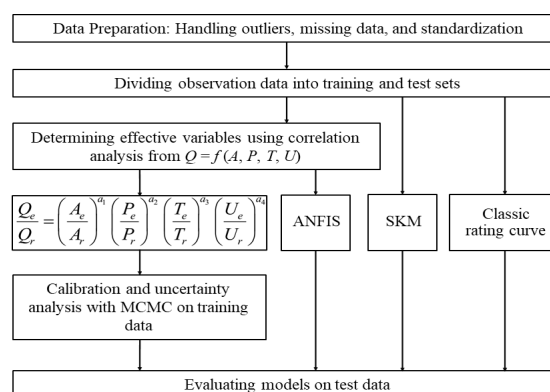


Fig. 5 Flowchart of research steps

شکل ۵ روندنمای مراحل تحقیق

۳- نتایج و بحث

در این بخش، عملکرد مدل‌های دبی-اشل توانی چندمتغیره (MPRC) (رابطه‌ی ۲)، مدل ANFIS، مدل دبی-اشل کلاسیک (CRC) (رابطه‌ی ۱۳) و مدل هیدرولیکی SKM بررسی می‌شود. این بررسی بر روی ایستگاه ملاتانی واقع در رودخانه‌ی کارون انجام شده است. شکل ۴، داده‌های مشاهده‌شده دبی را پس از حذف داده‌های پرت با استفاده از روش برآورد چگالی هسته (KDE) نشان می‌دهد. برای واسنجی مدل پیشنهادی، از روش MCMC استفاده شده است. پیش از واسنجی، لازم است که فراسنجه‌های هیدرولیکی تأثیرگذار شناسایی شوند. شکل ۶ نمایش‌دهنده‌ی تغییرپذیری‌های فراسنجه‌های هیدرولیکی با تراز و نمودار همبستگی بین این فراسنجه‌ها و خروجی است. همان‌طور که در شکل ۶ (b) مشاهده می‌شود، سه فراسنجه A، U و P بیشترین همبستگی را با دبی دارند. لازم به یادآوری است، با توجه به رابطه خطی بین فراسنجه P و T و ایجاد هم‌خطی چندگانه^۳ تولید یکی از فراسنجه‌ها بین P و T حذف شود.

3. Multicollinearity

1. Correlation coefficient
2. Coefficient of variation

شکل ۹ ارائه شده است. مشاهده می‌شود که این مدل در برآورد دبی اوج دچار بیش‌برازش شده است. در رابطه با مدل SKM نیز با توجه به اطلاعات زبری و شیب بستر رودخانه، نتایج برآورد جریان بر روی داده‌های آزمایش در شکل ۱۰ نمایش داده شد. سازگار نبودن مناسب بین داده‌های مشاهده‌ای و این مدل در جریان‌های کم و بالا مشهود است. جدول ۳ مقایسه کمی نتایج مدل‌های مورد بررسی بر روی داده‌های آزمایش را نشان می‌دهد. مشاهده می‌شود که مدل MPRC و CRC بر مبنای ۳ معیار KGE, SI, d و نتایج همانندی دارند. با این حال، مقدار منفی در معیار PBIAS نشان‌دهنده بیش‌برآورد در مدل CRC است. مدل SKM بدترین عملکرد را با توجه به ۴ معیار عملکردی در مقایسه با دیگر مدل‌ها از خود نشان داده است. با این حال، مدل ANFIS با $KGE=0.988$ ، $d=0.994$ ، $SI=0.9\%$ و $PBIAS=0.41\%$ عملکرد بسیار بهتری را نسبت به سه مدل دیگر ارائه می‌دهد.

مشاهده شده است. همچنین، لازم به یادآوری است که همه‌ی داده‌های مشاهداتی در درون فاصله‌ی اطمینان ۹۵ درصد قرار دارند. بنابراین می‌توان نتیجه گرفت، که روش MCMC عملکرد مطلوبی در واسنجی و تحلیل عدم قطعیت در مدل MPRC ارائه می‌دهد.

به منظور ارتقاء دقت برآورد، می‌توان از مدل‌های یادگیری ماشینی به جای مدل MPRC بهره برد. در این راستا، از مدل ANFIS برای برآورد دبی در ایستگاه ملاثانی استفاده می‌شود. متغیرهای ورودی این مدل همانند مدل پیشنهادی هستند. نتایج برآورد در شکل ۸ ارائه شده است. دقت برآورد دبی اوج با مدل ANFIS در مقایسه با مدل پیشنهادی، از عملکرد بهتری برخوردار است. به منظور مقایسه با دو مدل پیشین، از منحنی دبی-اشل کلاسیک (CRC) و مدل هیدرولیکی SKM استفاده می‌شود. معادله‌ی حاکم بر مدل CRC با اتکا بر داده‌های آموزشی به صورت $Q=155.6H^{1.23}$ است. برآورد جریان با این روش در




Fig. 7 Estimation of the streamflow time series and its uncertainty analysis in the test phase using the proposed model by Maghrebi & Ahmadi (2017) in the Karun River

شکل ۷ برآورد دوره زمانی جریان و تحلیل عدم قطعیت آن در مرحله‌ی آزمایش با استفاده از مدل پیشنهادی Maghrebi & Ahmadi (2017) در رودخانه‌ی کارون




Fig. 8 Estimation of the streamflow time series in the test phase using the ANFIS in the Karun River

شکل ۸ برآورد دوره زمانی جریان در مرحله‌ی آزمایش با کمک مدل ANFIS در رودخانه‌ی کارون




Fig. 9 Estimation of the streamflow time series in the test phase using the classic rating curve in the Karun River

شکل ۹ برآورد دوره زمانی جریان در مرحله‌ی آزمایش با مدل دبی-اشل کلاسیک در رودخانه‌ی کارون




Fig. 10 Estimation of the streamflow time series in the test phase using SKM model in the Karun River

شکل ۱۰ برآورد دوره زمانی جریان در مرحله‌ی آزمایش با مدل SKM در رودخانه‌ی کارون

جدول ۳ مقایسه کمی بین نتایج مدل‌های مورد مطالعه در رودخانه‌ی کارون بر روی داده‌های آزمایش

Table 3 Quantitative comparison between the results of the models studied in the Karun River on the test data

Model	KGE	SI (%)	d	PBIAS (%)
MPRC	0.954	3.27	0.972	1.85
ANFIS	0.988	0.90	0.994	0.41
CRC	0.955	3.57	0.971	-1.89
SKM	0.694	20.33	0.717	18.3

در شکل ۱۱ (ب)، پراکندگی برآوردها با یکدیگر مقایسه شده که مدل ANFIS از نظر توزیع برآورد دبی بیشترین نزدیکی را با داده‌های مشاهده‌ای دارد. پس از آن، مدل MPRC از نظر شاخص میانه، همانندی بیشتری با داده‌های مشاهده‌ای دارد. بیش برآورد در برآورد دبی اوج توسط مدل CRC و SKM قابل مشاهده است.

بنابراین، با توجه به معیارهای عملکردی و تحلیل‌های آماری صورت گرفته می‌توان نتیجه گرفت، ترکیب فراسنجه‌های هیدرولیکی با یک مدل یادگیری ماشین مانند ANFIS می‌تواند دقت برآورد را بهبود ببخشد.

در شکل ۱۱ (ا)، مقایسه بین مدل‌های مورد بررسی با کمک نمودار تیلور صورت گرفته است. همان‌طوری که مشاهده می‌شود مدل ANFIS همبستگی بیشتری نسبت به دیگر مدل‌ها دارد و به داده‌ی مشاهده‌شده نزدیک‌تر است. همچنین، انحراف معیار مشابهی با داده مشاهده‌شده دارد. دو مدل MPRC و CRC عملکرد همانندی را از نظر معیار همبستگی از خود نشان می‌دهند اما انحراف معیار متفاوتی نسبت به یکدیگر دارند. مدل MPRC انحراف معیار کمتری دارد. بنابراین، به‌طور میانگین پیش‌بینی‌های دقیق‌تری نسبت به CRC دارد. مدل SKM با اینکه انحراف معیار نزدیکی به انحراف معیار داده‌های مشاهده‌شده دارد اما کمترین همبستگی را دارد.

هیدرولیکی مانند مساحت مقطع، محیط مرطوب، عرض سطح آزاد آب و فراسنجه سرعت میانگین به‌دست آمده از منحنی‌های هم‌سرعت با یک مدل یادگیری ماشین مانند ANFIS، به جای استفاده از مدل MPRC، می‌تواند دقت برآورد دبی را تا حد زیادی بهبود بخشد. نتایج این پژوهش به‌ویژه برای منطقه‌هایی که داده‌های مشاهده‌شده کمی دارند سودمند خواهد بود.

۵- فهرست نشانه‌ها

A	سطح مقطع جریان (m^2)
C	ماتریس کوواریانس
ds	عنصر مرزی (m)
k_s	ارتفاع معادل زبری (mm)
n	ضریب زبری مانینگ ($ms^{-1/3}$)
N	شمار داده‌های مشاهده‌ای
P	محیط مرطوب (m)
P_i, Q_i, R_i	فراسنجه‌های تابع خروجی
Q	دبی (m^3/s)
Q_i, P_i	تابع‌های عضویت
r	بردار موقعیت (m)
S_0	شیب بستر
S_f	شیب اصطکاکی
T	عرض سطح آزاد آب (m)
U	فراسنجه سرعت میانگین (ms^{-1})
u	سرعت نقطه‌ای (ms^{-1})
u^*	سرعت برشی (ms^{-1})
V	میانگین سرعت واقعی (ms^{-1})
\bar{w}_i	درجه‌ی عضویت نرمال‌شده‌ی قانون i
X	داده ورودی
نشانه‌های یونانی:	
ρ	چگالی سیال (kgm^{-3})
τ_0	تنش برشی مرزی (Nm^{-2})
α	نسبت پذیرش
μ	مقدار میانگین
μ_{Ai}	درجه عضویت x در مجموعه A_i
σ	انحراف معیار بالانویس‌ها:
n	نرمال‌شده





Fig. 11 (a) Taylor diagram and (b) boxplot of the studied models

شکل ۱۱ (a) نمودار تیلور و (b) نمودار جعبه‌ای مدل‌های مورد مطالعه

۴- نتیجه‌گیری

با توجه به محدودیت‌های موجود در اندازه‌گیری مستقیم دبی، توسعه‌ی روش‌های نوین و دقیق برای برآورد دبی جریان رودخانه‌ها دارای اهمیت زیادی است. در این پژوهش، عملکرد مدل دبی-اشل تونلی چندمتغیره (MPRC)، مدل دبی-اشل کلاسیک (CRC)، مدل هیدرولیکی شیونو و نایت (SKM) و مدل یادگیری ماشین سامانه استنتاج عصبی فازی تطبیقی (ANFIS) به منظور برآورد دوره زمانی جریان رودخانه‌ی کارون، ایستگاه ملاثانی بررسی شد. نتایج نشان داد که مدل SKM ضعیف‌ترین عملکرد را در برآورد دوره زمان جریان داشت. همچنین، مدل‌های MPRC و CRC عملکرد همانندی در برآورد دبی جریان ارائه کردند. با این حال، مدل ANFIS با توجه به ۴ معیار ارزیابی، $KGE=0.988$ ، $SI=0.9\%$ ، $PBIAS=0.41\%$ و $d=0.994$ ، نمودار تیلور و جعبه‌ای عملکرد بهتری نسبت به دیگر مدل‌های مورد بررسی نشان داد. بنابراین، می‌توان نتیجه گرفت ترکیب متغیرهای

Hersch, R.W. (2009). Streamflow Measurement. Taylor & Francis. London, 536p.

Kiang, J.E., Gazorian, C., McMillan, H., Coxon, G., Le Coz, J., Westerberg, I.K., Belleville, A., Sevrez, D., Sikorska, A.E., Petersen-Øverleir, A., Reitan, T., Freer, J., Renard, B., Mansanarez, V. & Mason, R. (2018). A comparison of methods for streamflow uncertainty estimation. *Water Resour. Res.*, 54(10), 7149-7176.

Latecki, L.J., Lazarevic, A. & Pokrajac, D. (2007). Outlier detection with kernel density functions. In International workshop on machine learning and data mining in pattern recognition, MLDM 2007. Lecture Notes in Computer Science, vol 4571. Springer, Berlin, Heidelberg, 61-75. https://doi.org/10.1007/978-3-540-73499-4_6

Maghrebi, M.F. (2003). Discharge estimation in flumes using a new technique for the production of isovel contours. Proceeding of International Conference on Civil and Environment Engineering ICCEE.

Maghrebi, M.F. (2006). Application of the single point measurement in discharge estimation. *Adv. Water Resour.*, 29(10), 1504-1514.

Maghrebi, M.F. & Ahmadi, A. (2017). Stage-discharge prediction in natural rivers using an innovative approach. *J. Hydrol.*, 545, 172-181.

Maghrebi, M.F., Ahmadi, A., Attari, M. & Maghrebi, R.F. (2016). New method for estimation of stage-discharge curves in natural rivers. *Flow Meas. Instrum.*, 52, 67-76.

Manfreda, S. (2018). On the derivation of flow rating curves in data-scarce environments. *J. Hydrol.*, 562, 151-154.

Marjoram, P., Molitor, J., Plagnol, V. & Tavaré, S. (2003). Markov chain Monte Carlo without likelihoods. *PNAS*, 100(26), 15324-15328.

Pappenberger, F., Matgen, P., Beven, K.J., Henry, J.B., Pfister, L. & Fraipont, P. (2006). Influence of uncertain boundary conditions and model structure on flood inundation predictions. *Adv. Water Resour.*, 29(10), 1430-1449.

Petersen-Øverleir, A. (2004). Accounting for heteroscedasticity in rating curve estimates. *J. Hydrol.*, 292, 173-181.

Pham Van, C., de Brye, B., Deleersnijder, E., Hoitink, A.J.F., Sassi, M., Spinewine, B., Hidayat, H. & Soares-Frazaõ, S. (2016). Simulations of the flow in the Mahakam river-lake-delta system, Indonesia. *Environ. Fluid Mech.*, 16(3), 603-633.

زیرنویس‌ها:

e	برآورد شده
o	مشاهده شده
r	مرجع
min	کمینه
max	بیشینه
K	ویژگی
i	شمارنده
s	جریان دائمی

۶- سپاسگزاری

بدینوسیله از مسئولان و کارشناسان سازمان آب و برق خوزستان برای در اختیار گذاشتن داده‌های ایستگاه آب‌سنجی قردانی می‌شود.

۷- منابع‌ها

Abril, J.B. & Knight, D.W. (2004). Stage-discharge prediction for rivers in flood applying a depth-averaged model. *J. Hydraul. Res.*, 42(6), 616-629.

Zahiri, A.R., Ayyoubzadeh, S.A. & Dahanzadeh, B. (2009). Numerical solution of velocity lateral distribution in rivers (Case study: Karoun river at Molasani station). *J. Agric. Sci. Natur. Resour.*, 16(2), 273-283. (In Persian)

Cobaner, M. (2011). Evapotranspiration estimation by two different neuro-fuzzy inference systems. *J. Hydrol.*, 398(3-4), 292-302.

Domeneghetti, A., Castellarin, A. & Brath, A. (2012). Assessing rating-curve uncertainty and its effects on hydraulic model calibration. *Hydrol. Earth Syst. Sci.*, 16(4), 1191-1202.

Dottori, F., Martina, M.L.V. & Todini, E. (2009). A dynamic rating curve approach to indirect discharge measurement. *Hydrol. Earth Syst. Sci.*, 13(6), 847-863.

Dymond, J.R. & Christian, R. (1982). Accuracy of discharge determined from a rating curve. *Hydrolog. Sci. J.*, 27(4), 493-504.

He, S., Niu, G., Sang, X., Sun, X., Yin, J. & Chen, H. (2023). Machine Learning Framework with Feature Importance Interpretation for Discharge Estimation: A Case Study in Huitanggou Sluice Hydrological Station, China. *Water*. 15(10), 1923, <https://doi.org/10.3390/w15101923>.

Primers., 1(1), <https://doi.org/10.1038/s43586-020-00001-2>.

Vatanchi, S.M., Etemadfar, H., Maghrebi, M.F. & Shad, R. (2023). A Comparative Study on Forecasting of Long-term Daily Streamflow using ANN, ANFIS, BiLSTM and CNN-GRU-LSTM. *Water Resour. Manag.*, 37(12), 4769-4785.

Vatanchi, S.M. & Maghrebi, M.F. (2024). Estimating streamflow by an innovative rating curve model based on hydraulic parameters. *Environ. Earth Sci.*, 83, 266, <https://doi.org/10.1007/s12665-024-11493-6>.

Vlachou, E., Karras, C., Karras, A., Tsolis, D. & Sioutas, S. (2023). EVCA Classifier: A MCMC-Based Classifier for Analyzing High-Dimensional Big Data. *Information*, 14(8), 451, <https://doi.org/10.3390/info14080451>.

Wang, H., Wang, C., Wang, Y., Gao, X. & Yu, C. (2017). Bayesian forecasting and uncertainty quantifying of stream flows using Metropolis-Hastings Markov Chain Monte Carlo algorithm. *J. Hydrol.*, 549, 476-483.

Yaseen, Z.M., Ebtahaj, I., Bonakdari, H., Deo, R.C., Danandeh Mehr, A., Mohtar, W.H.M.W., Diop, L., El-shafie, A. & Singh, V.P. (2017). Novel approach for streamflow forecasting using a hybrid ANFIS-FFA model. *J. Hydrol.*, 554, 263-276.

Pham Van, C. & Nguyen-Van, G. (2022). Three different models to evaluate water discharge: An application to a river section at Vinh Tuy location in the Lo river basin, Vietnam. *J. Hydroenviron. Res.*, 40, 38-50.

Reis, D.S. & Stedinger, J.R. (2005). Bayesian MCMC flood frequency analysis with historical information. *J. Hydrol.*, 313(1-2), 97-116.

Gelman, A., Gilks, W.R. & Roberts, G.O. (1997). Weak convergence and optimal scaling of random walk Metropolis algorithms. *Ann. Appl. Probab.*, 7(1), 110-120.

Rosenthal, J.S. (2014). *Statistics in Action*. Taylor & Francis. New York, 384p.

Shi, P., Yang, T., Yong, B., Xu, C.Y., Li, Z., Wang, X., Qin, Y. & Zhou, X. (2023). Some statistical inferences of parameter in MCMC approach and the application in uncertainty analysis of hydrological simulation. *J. Hydrol.*, 617, Part A, 128767, <https://doi.org/10.1016/j.jhydrol.2022.128767>.

Thanh, H.V., Binh, D.V., Kantoush, S.A., Nourani, V., Saber, M., Lee, K.K. & Sumi, T. (2022). Reconstructing Daily Discharge in a Megadelta Using Machine Learning Techniques. *Water Resour. Res.*, 58(5).

Van de Schoot, R., Depaoli, S., King, R., Kramer, B., Märtens, K., Tadesse, M.G., Vannucci, M., Gelman, A., Veen, D., Willemsen, J. & Yau, C. (2021). Bayesian statistics and modelling. *Nat. Rev. Methods*



© 2025 The Author(s). Published by Iranian Hydraulic Association, Tehran, Iran. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.