

Predicting the water level of Sefidrood Dam reservoir using an improved neural network along with several meta-heuristic algorithms

Seied Sajad Alipour¹, Hadi Modaberi^{2*}, Hossein Hakimi Khansar³

1- MSc. student in Civil Engineering-Hydraulic Structure, Higher-Education Institute of the Academic Center for Education, Culture and Research (ACECR), Rasht, Iran.

2- Assistance Professor, Department of Water Resources Monitoring, Environmental Research Institute of Academic Center for Education, Culture and Research (ACECR), Rasht, Iran.

3- Graduated from the University of Tabriz, PhD in Water Engineering, Hydraulic Structures Department.

Received:2026-02-17

Accepted:2026-07-19

Revised:2026-07-19

Published online:2026-06-20

*Corresponding Author's Email: modaberi8@gmail.com

ARTICLE INFO

ABSTRACT

Keywords:

Metaheuristic Algorithms,
Whale Optimization
Algorithm,
Reservoir Water Level,
Sepidrood Dam,
Artificial Neural Network

Background and Objectives

Reservoir water level prediction plays a critical and strategic role in optimal water resources management, especially in regions facing prolonged droughts and increasing manifestations of climate change. Accurate forecasting of daily reservoir water levels enables better decision-making regarding water allocation, flood control, irrigation scheduling, hydropower generation, and environmental flow maintenance. Traditional physically-based hydrological models often face significant limitations when modeling reservoir level dynamics due to the high complexity, non-linearity, numerous uncertainties, and the lack of comprehensive physical equations capable of fully describing the integrated effects of hydrological, meteorological, operational, and anthropogenic factors. The primary objective of this study is to develop and comparatively evaluate four hybrid Artificial Neural Network (ANN) models optimized by metaheuristic algorithms (WOA, GWO, HHO, and ACOR) for daily forecasting of the Sefidrood Dam reservoir water level. In recent decades, data-driven artificial intelligence (AI) approaches, particularly Artificial Neural Networks (ANNs), have gained remarkable popularity in hydrological forecasting due to their outstanding ability to capture hidden non-linear relationships without requiring explicit representation of physical processes. However, conventional ANN training methods, mainly gradient-based algorithms such as Levenberg-Marquardt, often suffer from entrapment in local optima, slow convergence, and sensitivity to initial parameter settings. To overcome these drawbacks, hybridization of ANNs with modern metaheuristic optimization algorithms has been increasingly explored. These population-based algorithms provide powerful global search capabilities and significantly enhance the probability of identifying near-global optimum weights and biases of neural networks. The main objective of the present study was to develop and compare four hybrid ANN-metaheuristic models for daily reservoir water level prediction at Sepidrood Dam (Manjil station), which consisted of ANN models optimized using Whale Optimization Algorithm (WOA), Grey Wolf Optimizer (GWO), Harris Hawks Optimization (HHO), and Ant Colony Optimization for Continuous domains (ACOR), in order to identify the most accurate and robust model among them.

Methodology

Daily hydrological time-series data spanning 15 years (2007–2022 / 1386–1401) were collected from

How to cite:

Sajad Alipour, S. Modaberi, H. Hakimi Khansa, H. *Predicting the water level of Sefidrood Dam reservoir using an improved neural network along with several meta-heuristic algorithm.* Journal of Hydraulics and Water Science, 36 (1):25-43
<https://doi.org/10.22034/hws.2026.71513.1045>



This is an open-access article under the CC BY NC license
(<https://creativecommons.org/licenses/by-nc/4.0/>)



Sepidroud Dam (Manjil gauging station). The main variables comprised inflow discharge, outflow discharge, reservoir storage volume, reservoir surface area, and reservoir water level, with water level considered as the target variable. Cross-correlation analysis (CCF) and partial autocorrelation function (PACF) were employed to determine the most influential lagged input variables. The final input structure consisted of five variables, which included inflow discharge of the previous day (QI_{-1}), outflow discharge of the previous day (QO_{-1}), reservoir surface area of the current day (RA), reservoir volume of the current day (RV), and reservoir water level of the previous day (RL_{-1}). All input and output data were normalized to the range [0.1, 0.9], and the dataset was randomly divided into 70% training and 30% testing subsets. The base model consisted of a Multi-Layer Perceptron (MLP) neural network with one hidden layer. Instead of classical gradient-based training, the optimization framework comprised four metaheuristic algorithms, including WOA, GWO, HHO, and ACOR, which were employed to optimize the weights and biases of the MLP.

Model performance evaluation comprised a comprehensive set of statistical indices, which included coefficient of determination (R^2), mean absolute error (MAE), normalized root mean square error (NRMSE), scatter index (SI), mean bias error (MBE), Kling-Gupta efficiency (KGE), 95% uncertainty band width, and Global Performance Index (GPI), with GPI considered as the main ranking criterion. All implementations were performed in MATLAB R2018b environment.

Findings

The testing-phase results indicated that the hybrid ANN-WOA model achieved the highest overall performance. Its performance statistics included $R^2 = 0.9991$, $MAE = 0.4028$ m, $NRMSE = 0.0101$, $SI = 0.0101$, and the lowest GPI value, corresponding to the best rank. The ranking structure consisted of ANN-WOA as the first model, followed by ANN-GWO, ANN-ACOR, and ANN-HHO. Overall model performance indicators comprised SI values below 0.1 and NRMSE values below 0.03 for all hybrid models, demonstrating very high accuracy for practical engineering applications. Nevertheless, ANN-WOA clearly outperformed the others, as its error distribution included the smallest interquartile range (IQR) in the box-plot analysis, nearly unbiased predictions with a median error of approximately -0.02 m, and the most stable convergence behavior. The comparative analysis of error box-plots and convergence curves showed that the optimization dynamics of WOA consisted of a more effective balance between exploration and exploitation, enabling more robust escape from local optima and improved final solution quality compared to the other metaheuristics. The achieved accuracy substantially exceeded most previously reported results in the literature, which typically consisted of R^2 values ranging between 0.90 and 0.97.

Conclusion

The hybridization of Artificial Neural Networks with metaheuristic optimization algorithms, particularly the Whale Optimization Algorithm (WOA), significantly enhances the accuracy, stability, and reliability of daily reservoir water level forecasting. The superior performance of the ANN-WOA model in this study demonstrates its strong potential to serve as a reliable operational tool for reservoir management under complex and uncertain hydrological conditions. The results also highlight the importance of global optimization techniques in overcoming the limitations of classical ANN training methods. Considering the very high accuracy achieved, it is recommended to further test the ANN-WOA model under different climatic and operational scenarios, on other reservoirs, and potentially for prediction of other reservoir variables (inflow, outflow, evaporation, etc.). Integration of emerging explainable AI (XAI) techniques and newer metaheuristics are also suggested as promising directions for future research.



پیش‌بینی تراز سطح آب مخزن سد سفیدرود به وسیله شبکه عصبی بهبود یافته با چند الگوریتم فرا ابتکاری

سید سجاد علی پور^۱، هادی مدبری^{۲*}، حسین حکیمی خوانسر^۳

تاریخ پذیرش: ۱۴۰۵/۰۴/۲۸

تاریخ دریافت: ۱۴۰۴/۱۱/۲۸

تاریخ انتشار آنلاین: ۱۴۰۵/۰۳/۳۱

تاریخ ویرایش: ۱۴۰۵/۰۴/۲۸

- ۱- دانشجوی کارشناسی ارشد مهندسی عمران سازه های هیدرولیکی موسسه آموزش عالی جهاد دانشگاهی رشت، ایران
- ۲- استادیار گروه پایش منابع آب پژوهشکده محیط زیست جهاد دانشگاهی گیلان. رشت.
- ۳- دانش آموخته دکترای مهندسی آب گرایش سازه های آبی دانشگاه تبریز

* نویسنده مسئول: E-mail: modaberi8@gmail.com

چکیده

پیش‌بینی تراز مخزن در شرایط تشدید خشکسالی و تغییر اقلیم، برای مدیریت بهینه منابع آب ضروری است. مدل‌های فیزیکی مبنا به دلیل پیچیدگی غیر خطی و عدم قطعیت‌های هیدرولوژیکی، در شبیه‌سازی این پدیده محدودیت دارند. هدف پژوهش حاضر، توسعه و مقایسه چهار مدل ترکیبی شبکه عصبی مصنوعی با الگوریتم‌های فرا ابتکاری شامل الگوریتم بهینه‌سازی وال (Whale Optimization Algorithm - WOA)، الگوریتم گرگ خاکستری (Grey Wolf Optimizer - GWO)، الگوریتم شاهین هریس (Harris Hawks Optimization - HHO) و الگوریتم کلونی مورچگان برای دامنه‌های پیوسته (Ant Colony Optimization for Continuous Domains - ACOR) برای پیش‌بینی روزانه تراز آب مخزن سد سفیدرود است. این رویکرد با هدف غلبه بر محدودیت‌های روش‌های آموزش کلاسیک شبکه عصبی (مانند گیر افتادن در بهینه‌های محلی) و ارائه ابزاری عملیاتی و قابل اعتماد برای مدیریت روزانه مخزن در شرایط پیچیده و عدم قطعیت‌های هیدرولوژیکی طراحی شده است. جهت داده‌های روزانه پانزده ساله (۱۳۸۶-۱۴۰۱) جمع‌آوری و متغیرهای ورودی با تحلیل همبستگی متقاطع و خودهمبستگی جزئی گزینش شدند. شبکه پرسپترون چندلایه به عنوان چلیب انتخاب شد و وزن‌ها و آستانه‌های آن به جای روش‌های گرادیان محور، توسط الگوریتم‌های مذکور بهینه گردید. داده‌ها به نسبت ۷۰ به ۳۰ درصد تفکیک و مدل‌ها با شاخص‌های R^2 ، MAE، NRMSE، SI و GPI ارزیابی شدند. در مرحله آزمون، مدل ANN-WOA با R^2 برابر ۰/۹۹۹۱، MAE برابر ۰/۴۰۲۸ متر، NRMSE برابر ۰/۰۱۰۱ و SI برابر ۰/۰۱۰۱ بالاترین دقت را کسب کرد و بر اساس GPI رتبه نخست را به دست آورد. مدل‌های ANN-GWO، ANN-ACOR و ANN-HHO در جایگاه‌های بعدی قرار گرفتند. تحلیل توزیع خطاها نشان داد ANN-WOA با محدوده بین چارکی ۰/۰۸ متر و میانه خطای ۰/۰۲- متر، کمترین پراکندگی و سوگیری را داراست. ترکیب شبکه عصبی با الگوریتم‌های فرا ابتکاری، به ویژه وال، دقت و پایداری پیش‌بینی را ارتقا می‌دهد. برتری WOA ناشی از تعادل مؤثر میان اکتشاف و بهره‌برداری است که از گیر افتادن در بهینه‌های محلی جلوگیری می‌کند. این مدل قابلیت کاربرد عملیاتی در مدیریت روزانه مخزن سد سفیدرود را داراست.

واژه‌های کلیدی: الگوریتم فرا ابتکاری، الگوریتم وال، تراز سطح آب مخزن، سد سفیدرود، شبکه عصبی مصنوعی

۱- مقدمه

با توجه به وابستگی ذخیره‌سازی بهینه آب سدها به عوامل هیدرولوژیکی و کمی‌سازی آن عمدتاً از طریق تراز سطح آب، توسعه مدل‌های پیش‌بینی‌کننده دقیق برای بررسی رفتار این تراز، از ارکان اصلی مدیریت پایدار منابع آبی محسوب می‌شود (Hipni et al., 2013; Sammen et al., 2017).

در سال‌های اخیر، مدل‌های هوش مصنوعی در حوزه پیش‌بینی متغیرهای هیدرولوژیکی کاربرد وسیعی یافته‌اند. آن‌ها برخلاف مدل‌های مبتنی بر قوانین فیزیکی، الزامی به توصیف جزئی مکانیزم‌های فیزیکی ندارند و تنها از طریق شناسایی روابط غیرخطی پنهان در داده‌های ورودی و خروجی، موفق به شبیه‌سازی دقیق رفتار سیستم‌های پیچیده هیدرولوژیکی می‌شوند (Barzegar et al., 2017; Das et al., 2016). تراز سطح آب مخازن سد و تالاب‌ها تابعی پیچیده از عوامل متعدد هواشناسی، هیدرولیکی، ویژگی‌های خاک و زمین‌شناسی و همچنین مداخلات انسانی است (Modaberi & Shokoohi, 2020). برای مطالعه دقیق‌تر و بهتر پیش‌بینی تراز سطح آب مخازن از مدل‌های هیدرولوژیکی و هیدرولیکی استفاده شد. تحقیقات نشان داد که این مدل‌های فیزیکی به دلیل کمبود داده‌های مناسب، وجود عدم قطعیت‌های زیاد، پیچیدگی‌های دینامیکی و نبود یک رابطه فیزیکی صریح و جامع با محدودیت‌ها و چالش‌های اساسی به منظور پیش‌بینی تراز آب مواجه بودند (Modaberi et al., 2017).

امروزه روش‌های هوش مصنوعی از جمله شبکه‌های عصبی مصنوعی^۱ (ANN)، ماشین‌های بردار پشتیبان^۲ (SVM)، رگرسیون بردار پشتیبان^۳ (SVR)، جنگل تصادفی^۴ (RF) و به‌ویژه مدل‌های یادگیری عمیق^۵ (DR) به دلیل توانایی فوق‌العاده در شناسایی و یادگیری روابط غیرخطی، چندمتغیره و پنهان در داده‌ها، به‌عنوان جایگزین‌های قدرتمند و کارآمد برای پیش‌بینی تراز آب مخزن شناخته شده‌اند (Kişi, 2008). مرور منابع این مقاله با تمرکز بر بررسی عملکرد مدل‌های نرم و رویکردهای هیبریدی در پیش‌بینی پدیده‌های هیدرولوژیکی و همچنین مزایا و معایب این مدل‌ها در افزایش دقت، کاهش عدم قطعیت و ارتقای قابلیت کاربرد مدل‌ها در شرایط واقعی عملیاتی انجام گرفت. Kişi et al. (2012) تراز سطح آب دریاچه ایزنیک واقع در غرب ترکیه را با به‌کارگیری سه مدل شبکه عصبی مصنوعی، سیستم استنتاج عصبی-فازی تطبیقی^۶ (ANFIS) و برنامه‌نویسی بیان ژنی^۷ (GEP) پیش‌بینی کردند. نتایج پژوهش نشان داد که مدل GEP در مقایسه با ANN و ANFIS از دقت بالاتر و عملکرد بهتری برخوردار است. در

مطالعه‌ای دیگر (Valizadeh & El-Shafie, 2013) اقدام به توسعه مدل استنتاج عصبی - فازی تطبیقی بر پایه دو نوع تابع عضویت گوسی و زنگوله‌ای جهت پیش‌بینی تراز سطح آب مخزن سد کلانگ گیتس^۸ در مالزی نمودند. نتایج بیانگر دقت بالای مدل پیشنهادی در مقایسه با مدل‌های رایج موجود بود. بررسی‌های صورت گرفته توسط Buyukyildiz et al. (2014) نشان داد که مدل رگرسیون بردار پشتیبان از پتانسیل بالایی نسبت به مدل‌های استنتاج عصبی-فازی تطبیقی، شبکه عصبی پرسپترون چندلایه^۹ (MLP) و شبکه عصبی تابع پایه شعاعی^{۱۰} (RBFNN) در پیش‌بینی تراز سطح آب دریاچه بیسیر برخوردار می‌باشد.

تعیین مناسب‌ترین ورودی با استفاده از آزمون گاما جهت پیش‌بینی ماهانه تراز سطح آب مخزن سد خانپور در پاکستان بر پایه مدل‌های شبکه عصبی مصنوعی و مدل رگرسیون محلی توسط Shamim et al. (2016) مورد مطالعه قرار گرفت. نتایج پژوهش نشان داد که به‌کارگیری آزمون گاما منجر به بهبود قابل‌توجه دقت پیش‌بینی تراز سطح آب در مخزن شده است که این امر عمدتاً ناشی از توانایی این روش در انتخاب بهینه ترکیب ورودی‌های مؤثر است. Das et al. (2016) از مدل غیرخطی شبکه بیزین هیبریدی برای تخمین تراز سطح آب مخزن مایوراکشی استفاده کرده‌اند. یافته‌های این پژوهش حاکی از برتری معیارهای عملکردی رویکرد پیشنهادی در مقایسه با مدل‌های متداول پیش‌بینی از جمله شبکه عصبی مصنوعی، شبکه بیزین استاندارد و مدل‌های سری‌زمانی است. Soleymani et al. (2016) مدل ترکیبی RBF-FFA را برای پیش‌بینی تراز سطح آب رودخانه توسعه دادند که در آن از الگوریتم کرم شب‌تاب^{۱۱} (FFA) برای آموزش و بهینه‌سازی مدل نرم RBF بهره گرفته شد. نتایج مطالعات پیشین نشان‌دهنده کارایی بالای مدل‌های داده‌محور در پیش‌بینی تراز سطح آب بود اما از طرفی، مرور جامع ادبیات پژوهش حاکی از آن بود که تاکنون هیچ مطالعه‌ای به‌طور خاص از استراتژی استکینگ^{۱۲} یا ترکیب پیش‌بینی چندین مدل محاسبات نرم به‌عنوان ورودی یک مدل سطح دوم برای پیش‌بینی تراز سطح آب مخزن سد استفاده نکرده است.

در پژوهش حاضر، پیش‌بینی و مدل‌سازی تراز سطح آب مخزن سد سفیدرود به وسیله شبکه عصبی بهبودیافته با چند الگوریتم فراابتکاری در دستور کار قرار گرفت. در این راستا ابتدا مدل‌های شبکه عصبی مصنوعی با الگوریتم‌های فراابتکاری بهینه‌سازی شد. این الگوریتم‌ها شامل کلونی مورچگان پیوسته^{۱۳} (ACO)، شاهین هریس^{۱۴} (HHO)،

⁸ Klang Gates⁹ Multi- Layer Perceptron¹⁰ Radial Basis Function Neural Network¹¹ Function-Firefly Algorithm¹² Stacked Generalization¹³ Ant Colony Optimization for Continuous Domains¹⁴ Harris Hawks Optimization¹ Artificial Neural Network² Support vector machines³ Support Vector Regression⁴ Random Forest⁵ Deep Learning⁶ Adaptive Neuro-Fuzzy Inference System⁷ Gene Expression Programming

مزیت مشترک این الگوریتم‌ها در مسائل هیدرولوژیکی، توانایی آن‌ها در فرار از بهینه‌های محلی، مدیریت روابط غیرخطی پیچیده و مقاومت در برابر عدم قطعیت‌های ذاتی داده‌های هیدرولوژیکی است. در این مدل‌های پیشنهادی، وزن‌ها و سوگیری‌های شبکه پرسپترون چندلایه از روش‌های گرادیان‌محور سنتی کنار گذاشته شد و به جای آن، هر یک از الگوریتم‌های مذکور، مسئولیت بهینه‌سازی کامل را بر عهده گرفتند. این راهکار، مدل‌ها را قادر ساخت تا از توانایی یادگیری غیرخطی شبکه‌های عصبی استفاده نمایند و همزمان، جستجوی سراسری الگوریتم‌های تکاملی نیز انجام گیرد تا در حد امکان از گیر افتادن در بهینه‌های محلی جلوگیری شده و بدین صورت دقت مدل بالاتر شده و پایداری پیش‌بینی نیز افزایش یابد.

تعیین تعداد نوروهای لایه پنهان در این پژوهش طی یک فرآیند دوگانه صورت گرفت. در گام نخست، از فرمول‌های تجربی معتبر برای تعیین محدوده اولیه استفاده شد. مهم‌ترین این فرمول‌ها شامل رابطه Hecht-Nielsen (1988) با پیشنهاد $n_{h+1} = 2n_i$ ، که برای ۵ متغیر ورودی و ۱ متغیر خروجی، محدوده‌ای بین ۴ تا ۱۱ نرون را پیشنهاد می‌کردند. در گام دوم، به‌منظور تأیید صحت این فرمول‌ها، یک تحلیل حساسیت کامل با تغییر تعداد نوروها از ۱ تا ۲۰ انجام شد. نتایج این تحلیل نشان داد که در محدوده ۴ تا ۱۱ نرون، تغییر تعداد نوروها تأثیر معناداری بر دقت پیش‌بینی ندارد. این پدیده احتمالاً ناشی از توانایی الگوریتم‌های فراابتکاری در بهینه‌سازی وزن‌ها فارغ از پیچیدگی ساختار شبکه است. با توجه به این مشاهده و به منظور حفظ سادگی مدل، از فرمول Hecht-Nielsen (1988) استفاده شد و ۱۱ نرون در لایه پنهان انتخاب گردید.

تمامی مراحل کار شامل پیاده‌سازی مدل‌ها، آموزش، بهینه‌سازی، اعتبارسنجی و بررسی نتایج در محیط MATLAB نسخه R2018b انجام گرفت. با توجه به ماهیت تصادفی الگوریتم‌های فراابتکاری، فرآیند بهینه‌سازی هر مدل در محیط MATLAB طی ۵ اجرای مستقل تکرار شد. کد پیاده‌سازی شده به‌طور خودکار کمترین خطای آموزش را در پایان هر اجرا ثبت کرده و بهترین اجرا را به‌عنوان مدل نهایی برای مرحله آزمون انتخاب می‌کند. این رویکرد، نتایج گزارش‌شده را از اثرات مقداردی اولیه تصادفی مصون می‌دارد. فلوچارت چارچوب پیشنهادی در شکل ۲ نمایش داده شد. این فلوچارت، مکانیزم بهره‌گیری از الگوریتم‌های فراابتکاری را مشخص نموده و چگونگی جستجو برای بدست آوردن بهترین مجموعه وزن‌ها و آستانه‌ها در شبکه پرسپترون چندلایه را نمایان می‌سازد.

گرگ خاکستری^۱ (GWO) و وال^۲ (WAO) بودند. در مرحله بعد برای پیش‌بینی روزانه تراز مخزن سد سفیدرود از داده‌های روزانه و بلندمدت ایستگاه سد سفیدرود در منجیل استفاده شد. این داده‌ها شامل متغیرهای هیدرولوژیکی دبی ورودی، دبی خروجی، حجم ورودی روزانه، سطح مخزن و حجم آن و متغیرهای هواشناسی شامل بارندگی، دما، رطوبت نسبی، سرعت باد، تابش خورشیدی و تبخیر بودند. این متغیرها به عنوان ورودی مدل‌های هوشمند انتخاب شده، استفاده شدند. پس از پیاده‌سازی، مدل‌ها آموزش دیده و عملکردشان با معیارهای آماری سنجیده شدند. در انتها، ساختار هیبریدی بهینه انتخاب شد. این ساختار به عنوان مدل برتر برای پیش‌بینی تراز سطح آب مخزن سد سفیدرود معرفی شد.

۲- مواد و روش‌ها

۲-۱- شبکه‌ی عصبی مصنوعی

در پژوهش حاضر، مدل پایه هوش مصنوعی از نوع شبکه پرسپترون چندلایه (MLP) انتخاب شد. آموزش این شبکه بر پایه الگوریتم پس‌انتشار خطا و روش لوبز-مارکوارت بود. از مزایای این روش می‌توان به سرعت بالاتر و پایداری بیشتر در کارهای مشابه اشاره کرد. در لایه‌های پنهان، تابع فعال‌سازی سیگموئید منطقی^۳ به کار گرفته شد و لایه خروجی نیز با تابع فعال‌سازی خطی^۴ تنظیم شد. این ترکیب، مدل‌سازی روابط غیرخطی پیچیده را ممکن ساخت. در نظر گرفتن خروجی پیوسته نیز برای پیش‌بینی تراز سطح آب مخزن ضروری بود. به طور کلی معماری شبکه عصبی به کار رفته در این پژوهش در شکل ۱ نشان داده شده است. در پژوهش حاضر، چهار مدل ترکیبی بر پایه شبکه عصبی مصنوعی توسعه یافت. این مدل‌ها با الگوریتم‌های وال یا نهنگ‌عنبری، گرگ خاکستری، شاهین هریس و کلونی مورچگان پیوسته ترکیب شده و تراز سطح آب مخزن سد سفیدرود را به صورت روزانه پیش‌بینی نمودند. انتخاب این چهار الگوریتم فراابتکاری بر اساس سه معیار اصلی صورت گرفت:

(۱) پوشش خانواده‌های مختلف الگوریتم‌های فراابتکاری (الهام‌گرفته از رفتار شکار، ساختار اجتماعی و هوش جمعی) برای انجام مقایسه‌ای جامع

(۲) کارایی اثبات‌شده در مطالعات پیشین حوزه هیدرولوژی و منابع آب (Barzegar et al., 2017; Maroufpoor et al., 2019; Kişi et al., 2012)


(۳) تفاوت در استراتژی‌های جستجو که امکان ارزیابی تأثیر مکانیزم‌های مختلف بهینه‌سازی بر دقت پیش‌بینی تراز مخزن را فراهم می‌سازد.

³ Logistic Sigmoid

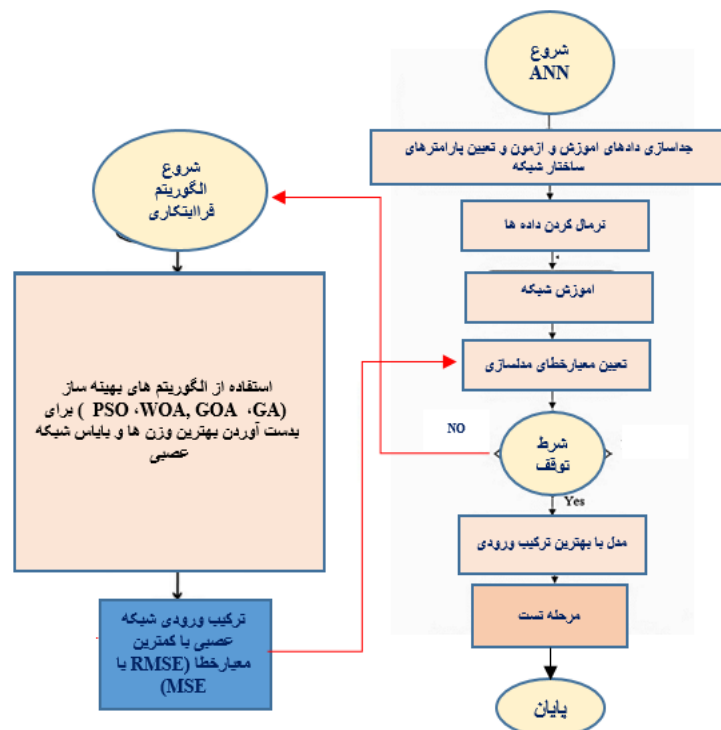
⁴ Purelin

¹ Grey Wolf Optimizer

² Whale Optimization Algorithm



شکل ۱. معماری شبکه عصبی چندلایه پرسپترون (MLP) استفاده شده
Fig 1. Architecture of the Multi-Layer Perceptron (MLP) neural network used.



شکل ۲. ساختار ترکیبی شبکه عصبی مصنوعی با الگوریتم های فراابتکاری برای بهینه سازی وزن ها و بایاس های شبکه
Fig 2. Hybrid structure of an artificial neural network combined with metaheuristic algorithms for optimizing network weights and biases.

شاخص میزان هم خطی (هم راستایی) بین مقادیر پیش بینی شده و مشاهده شده را ارزیابی کرده و در فرآیند بهینه سازی و مقایسه مدل ها نقشی مؤثر ایفا می کند (Behar et al., 2015).

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O}_i)(E_i - \bar{E}_i)}{\sqrt{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \sum_{i=1}^n (E_i - \bar{E}_i)^2}} \right)^2 \quad (4)$$

۲-۲-۴- شاخص پراکندگی (SI)

این شاخص بر اساس شاخص RMSE ساخته شده و مانند آن نیز عمل می کند. مزیت این شاخص نسبت به RMSE این است که می توان آن را طبقه بندی نمود. بر اساس این شاخص، مقایسه کیفی عملکرد مدل ها به ۴ قسمت بسیار عالی، خوب، منصفانه و ضعیف طبقه بندی می شوند. شاخص پراکندگی بر اساس معادله معادله ۵ محاسبه شد.

$$SI = \frac{RMSE}{\bar{E}} \quad (5)$$

با توجه به پیشنهاد Li et al. (2013) مقایسه کیفی عملکرد مدل بر اساس شاخص SI به شرح معادله ۶ ارائه شد.

$$\begin{cases} SI < 0.1 & \text{بسیار عالی} \\ 0.1 < SI < 0.2 & \text{خوب} \\ 0.2 < SI < 0.3 & \text{متوسط} \\ SI > 0.3 & \text{ضعیف} \end{cases} \quad (6)$$

۲-۲-۵- میانگین خطای اریبی (MBE)

خطای میانگین انحراف معیاری است که برای تشخیص جهت سوگیری مدل به کار می رود؛ مقادیر مثبت MBE نشان دهنده بیش برآزش و مقادیر منفی آن بیانگر کم برآزش توسط مدل هستند (Ma & Iqbal, 1984). این میانگین از معادله ۷ بدست می آید.

$$MBE = \frac{1}{n} \sum_{i=1}^n (E_i - O_i) \quad (7)$$

۲-۲-۶- خطای (T_{stat})

این شاخص ترکیبی مطابق معادله ۸، تابعی از خطای سوگیری و میانگین مربعات خطا است و به طور گسترده ای در ارزیابی مدل های پیش بینی به کار می رود. با این حال، استفاده انفرادی از آن ممکن است به انتخاب نادرست «بهترین مدل» از میان گزینه های موجود منجر شود. بنابراین، به کارگیری هم زمان این شاخص در کنار سایر معیارهای آماری، می تواند ارزیابی سریع تر و قابل اطمینان تری از عملکرد مدل ها فراهم آورد (Stone, 1993).

$$T_{stat} = \sqrt{\frac{(n-1)MBE^2}{RMSE^2 - MBE^2}} \quad (8)$$

۲-۲-۷- عدم قطعیت با سطح اطمینان ۹۵٪ (U₉₅)

فاصله اطمینان معیاری برای سنجش عدم قطعیت در تخمین اثر یا

۲-۲- شاخص های آماری

به منظور سنجش جامع دقت، پایداری و کارایی مدل های توسعه یافته، چندین معیار آماری شناخته شده و استاندارد انتخاب گردید. علاوه بر شاخص های آماری رایج، برای ارزیابی جامع تر و چندبعدی عملکرد مدل های هیبریدی، از سه معیار پیشرفته تر شامل عدم قطعیت ۹۵ درصدی U₉₅، آماره T_{stat} و شاخص عملکرد کلی (GPI) استفاده شد. شاخص U₉₅ به عنوان معیاری برای سنجش انحراف کلی نتایج تخمینی از مقادیر مشاهداتی به کار گرفته می شود و اطلاعاتی درباره پراکندگی و عدم قطعیت خطا ارائه می دهد. از سوی دیگر، GPI به عنوان یک شاخص ترکیبی چندمعیاره، امکان رتبه بندی یکپارچه مدل ها را فراهم می کند و به همین دلیل برای مقایسه نهایی مدل های پیش بینی کننده توصیه می شود.

۲-۲-۱- خطای جذر میانگین مربعات (RMSE) و ریشه

میانگین مربعات خطای نرمال شده (NRMSE)

ریشه میانگین مربعات خطا اطلاعاتی درباره عملکرد کوتاه مدت مدل را با مقایسه نظریه به نظیر مقادیر پیش بینی شده و مشاهده شده ارائه می دهد (Ma & Iqbal, 1984) اما به عنوان معیاری برای تعیین خطای متوسط مناسب نیست، زیرا مقدار آن تحت تأثیر سه ویژگی اصلی مجموعه خطاها شامل اندازه، علامت و پراکندگی قرار دارد و نمی تواند به طور مستقل عملکرد مدل را در مقیاس مطلق توصیف کند (Willmott & Matsuura, 2006). معادلات ۱ و ۲ روابط مربوط به این دو شاخص آماری را نشان می دهد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{N}} \quad (1)$$

$$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{N}}}{\bar{O}_i} \quad (2)$$

۲-۲-۲- میانگین خطای مطلق (MAE)

میانگین قدر مطلق خطا به دلیل سادگی مفهومی و محاسباتی، معیاری پر کاربرد برای مقایسه عملکرد مدل های پیش بینی در مورد یک سری داده یا چندین سری داده با واحدهای یکسان محسوب می شود. از دیدگاه آماری، روشی که MAE را به حداقل می رساند، به تخمین میانه داده ها منجر می شود و به طور گسترده ای در ادبیات فنی مورد استفاده قرار می گیرد (Lewis-Beck, 2005). معادله ۳ میانگین خطای مطلق را نشان می دهد.

$$MAE = \frac{\sum_{i=1}^n |E_i - O_i|}{n} \quad (3)$$

۲-۲-۳- ضریب تبیین (R²)

ضریب تبیین مطابق معادله ۴، درواقع بخشی از واریانس مقادیر مشاهده شده را که توسط مدل تبیین می شود، نشان می دهد. این

انتخاب بازه [۰/۹, ۰/۱] به جای بازه متداول [۰, ۱] بر اساس سه ملاحظه فنی صورت گرفت. نخست، با توجه به استفاده از تابع فعال سازی سیگموئید منطقی در لایه پنهان، مقادیر نزدیک به ۰ و ۱ باعث اشباع نورون ها و میل کردن مشتق تابع به سمت صفر می شوند که فرآیند پس انتشار خطا را مختل می سازد. بازه [۰/۹, ۰/۱] نورون ها را در ناحیه فعال نگه می دارد و از بروز پدیده محو شدن گرادیان جلوگیری می کند. دوم، با عنایت به وجود مقادیر پرت در داده های هیدرولوژیکی سد سفیدرود (به ویژه دبی ورودی با کشیدگی ۱۵)، این بازه یک حاشیه امن ۱۰ درصدی در هر طرف ایجاد می کند تا در صورت مواجهه با داده های آزمون خارج از محدوده آموزش، مقادیر نرمال شده از بازه مجاز خارج نشوند. سوم، قرارگیری خروجی های میانی در ناحیه فعال سیگموئید، فضای جستجوی الگوریتم های فراابتکاری را هموارتر کرده و همگرایی سریع تر و پایدارتر وزن ها را ممکن می سازد.

۲-۳-۲- نمودار جعبه ای به منظور برآورد خطاهای مدل های هیبریدی

خطاهای مدل های هیبریدی مبتنی بر ANN را در مرحله آزمون به صورت نمودار جعبه ای نشان داده شد. در این نمودار، خطا به عنوان تفاضل بین مقادیر واقعی تراز مخزن سد سفیدرود و مقادیر پیش بینی شده توسط هر مدل محاسبه شده است. در این تعریف، خطاهای مثبت نشان دهنده تخمین های کمتر از مقدار واقعی و خطاهای منفی بیانگر تخمین های بیشتر از مقدار واقعی هستند. نمودار جعبه ای یک روش استاندارد برای توصیف توزیع خطا از طریق چهار مؤلفه کلیدی شامل چارک اول (Q1)، چارک سوم (Q3)، میانه (که با خط داخل جعبه نشان داده می شود) و محدوده بین چارکی (IQR = Q3 - Q1) تعریف می گردد. هرچه مقدار IQR کوچک تر باشد، پراکندگی خطا کمتر و در نتیجه دقت مدل بالاتر خواهد بود (Maroufpoor et al., 2019).

۳- نتایج و بحث

در این بخش، عملکرد مدل های هوشمند پیشنهادی با داده های واقعی ایستگاه سد سفیدرود که در منجیل استقرار دارد، ارزیابی گردید و با تکیه بر معیارهای آماری استاندارد، مدل های هیبریدی برتر شناسایی شدند. این مدل ها از نظر دقت، پایداری و قابلیت تعمیم به داده های جدید، بالاترین رتبه را کسب کردند.

۳-۱- آمار توصیفی و آنالیز همبستگی

در این پژوهش از سری زمانی روزانه ۱۵ ساله از سال ۱۳۸۶ تا سال ۱۴۰۱ سد سفیدرود استفاده شد. ۸ پارامتر بارندگی، تبخیر، تراز، حجم و مساحت دریاچه، دما، ورودی و خروجی به عنوان ویژگی های ورودی و

پارامتر مورد نظر است و بازه ای را مشخص می کند که با احتمال معینی معمولاً ۹۵ یا ۹۹ درصد مقدار واقعی پارامتر در جامعه آماری درون آن بازه قرار دارد. بین فاصله اطمینان ۹۵٪ و آزمون معنی داری دوطرفه با آلفای ۰/۰۵ رابطه مستقیمی برقرار است به طوریکه اگر بازه اطمینان ۹۵٪، مقدار صفر (یا مقدار مرجع فرض صفر) را در بر نگیرد، آزمون فرض در سطح معنی داری ۵٪ فرض صفر را رد می کند. این بدان معنی است که این دو روش کاملاً معادل یکدیگر هستند و نتیجه یکسانی ارائه می دهند (Patino & Ferreira, 2015). در معادله ۹ ضریب اطمینان، کمی سازی شده است. در این معادله SD شاخص انحراف استاندارد، برای نشان دادن انحراف مقادیر برآورد شده از مقادیر مشاهده شده است.

$$U_{95} = 1.96\sqrt{(SD^2 + RMSE^2)} \quad (9)$$

۲-۲-۸- شاخص عملکرد جهانی (GPI)

این شاخص مطابق معادله ۱۰ از ضرب پنج شاخص آماری به دست می آید. GPI مزایای تمام شاخص ها یعنی ضریب تبیین (R^2)، میانگین خطای مطلق (MAE)، شاخص پراکندگی (SI)، عدم قطعیت با ۹۵٪ سطح اطمینان (U_{95}) و T_{stat} را ترکیب می کند. این شاخص عملکرد کوتاه مدت و بلندمدت و نیز خطی بودن مدل ها را نشان می دهد، بنابراین می توان از آن برای رتبه بندی مدل ها استفاده کرد. یک مزیت مهم شاخص GPI، طبقه بندی آسان تر و واقع بینانه تر مدل های کاربردی است (Behar et al., 2015).

$$GPI = MBE \times RMS \times U_{95} \times T_{stat} \times (1 - R^2) \quad (10)$$

در روابط بالا O_i ، E_i و $(\bar{O}_i)$ به ترتیب برابر مقادیر تراز مخزن برآورد شده، مقادیر تراز مخزن مشاهده شده، میانگین مقادیر تراز مخزن برآورد شده و میانگین مقادیر تراز مخزن مشاهده شده و n تعداد داده های مشاهده شده است. در مقایسه عملکرد مدل با شاخص های فوق، مدل برتر مدلی است که در آن مقادیر همه شاخص ها (به استثنای R^2 به صفر و شاخص R^2 به عدد یک میل نماید).

لازم به ذکر است با توجه به ماهیت کاملاً داده محور مدل های شبکه عصبی و عدم وابستگی آن ها به شناخت قبلی روابط فیزیکی حاکم بر پدیده، انجام پیش پردازش مناسب داده ها به ویژه نرمال سازی و مقیاس بندی ویژگی ها نقش حیاتی در افزایش سرعت همگرایی، جلوگیری از تسلط متغیرهای با دامنه بزرگ تر و در نهایت ارتقای دقت و پایداری عملکرد مدل ایفا می کند (Hakimi Khansar, 2021). در این پژوهش، داده ها با استفاده از رابطه (۱۱) به بازه [۰/۹, ۰/۱] نرمال سازی شدند.

$$x_n = \left(0.8 * \left(\frac{(x - x_{min})}{(x_{max} - x_{min})} \right) \right) + 0.1 \quad (11)$$

مقادیر x_n ، x ، x_{min} ، x_{max} به ترتیب داده های نرمال شده، داده های اصلی، کمینه داده ها، بیشینه داده ها هستند.

(Parsa et al., 2021). در این راستا از تابع همبستگی متقاطع^۱ برای شناسایی مقادیر گذشته متغیرهای ورودی که بیشترین رابطه آماری را با تراز مخزن سد در هر روز دارند، استفاده گردید.

حجم مخزن به عنوان متغیر هدف انتخاب گردیدند. جدول ۱، واحدها و نمادهای اختصاری متغیرهای مورد استفاده را نشان می دهد. برای انتخاب بهینه ورودی های مدل هوشمند و تعیین تأخیرهای زمانی مناسب، تحلیل های همبستگی با استفاده از نرم افزار SPSS انجام شد

جدول ۱- واحدها و نمادهای اختصاری متغیرهای مورد استفاده

Table 1 – Units and abbreviations of the variables used

متغیر	متوسط دما	تبخیر	بارندگی	ورودی	خروجی	تراز متوسط مخزن	مساحت دریاچه	حجم مخزن
واحد	o ^c	MCM	mm	m3/s	m3/s	m	km2	MCM
اختصار	T	E	R	QI	QO	RL	RA	RV


(et al., 2009) تا هم آموزش کافی مدل ها تأمین شود و هم قابلیت تعمیم و عملکرد بر داده های نادیده به شکل مستقل سنجیده گردد.

تحلیل آمار توصیفی داده ها، نقش مهمی در شناخت توزیع آن ها و گزینش ویژگی های مناسب برای مدل سازی ایفا می کند. جدول ۲، تحلیل آمار توصیفی متغیرهای ثبت شده توسط ابزار دقیق سد را نشان می دهد. این آمار شامل میانگین، میانه، انحراف معیار، حداقل، حداکثر، ضریب چولگی و ضریب کشیدگی بوده و با استفاده از نرم افزار SPSS محاسبه شده اند. متغیرهای بررسی شده شامل حجم مخزن، مساحت مخزن، دبی ورودی، دبی خروجی و تراز مخزن بود. جدول ۲، آمار توصیفی جامع متغیرهای کلیدی ثبت شده در سد سفیدرود منجیل را نشان می دهد. حجم مخزن با میانگین ۵۰۱ و انحراف معیار ۳۰۲ میلیون مترمکعب، بیشترین پراکندگی را میان متغیرها نشان داد. این تنوع گسترده، حجم مخزن را به یکی از فاکتورهای مهم پیش بینی کننده تراز سطح آب مخزن تبدیل کرد. انحراف معیار دبی ورودی و دبی خروجی به ترتیب ۸۷ و ۹۲ مترمکعب بر ثانیه برآورد شد. این نوسانات قابل توجه نشان داد که تغییرات فصلی و رویدادهای هیدرولوژیکی شدید بر دبی ورودی و خروجی مخزن سد تأثیر زیادی دارد. انحراف معیار تراز سطح آب مخزن ۱۱ متر بوده که نشان می دهد این فاکتور پایداری بیشتری نسبت به دبی ورودی و خروجی از خود نشان می دهد. در فاکتورهای حجم مخزن، مساحت سطح آب، دبی ورودی و دبی خروجی چولگی مثبت مشاهده شد. این شکل نامتقارن، دم راست طولانی را نشان می دهد. به عبارت دیگر، احتمال وقوع مقادیر بسیار بزرگ، مانند سیلاب ها یا افزایش ناگهانی حجم مخزن، بیشتر است. تنها تراز سطح آب مخزن چولگی منفی داشت. این ویژگی، تمایل توزیع به سمت مقادیر پایین تر را آشکار می سازد. این موضوع می تواند به دلیل محدودیت فیزیکی تراز حداکثر سد. کشیدگی منفی در حجم مخزن و مساحت سطح آب باشد.

در پژوهش حاضر، برای بررسی وابستگی های زمانی تراز آب مخزن و گزینش بهینه ویژگی های ورودی، تحلیل های همبستگی و خودهمبستگی جزئی به کار گرفته شد. تابع خودهمبستگی جزئی (PACF) با بازه تأخیر ± 20 روزه (از ۲۰ روز پیش تا ۲۰ روز پس از اتفاق) محاسبه گردید. فاصله اطمینان ۹۵ درصدی نیز به عنوان آستانه معنی داری ضرایب در نظر گرفته شد. شایان ذکر است تأخیرهای منفی برای گذشته و مثبت برای آینده مدنظر قرار گرفت. نتایج تحلیل همبستگی متقابل در شکل ۳ نشان داد که بالاترین ارتباط تراز مخزن در هر روز، با متغیرهای مساحت سطح آب، حجم مخزن و خود تراز مخزن در همان روز برقرار است.


شکل ۴ نمودار خودهمبستگی (ACF) تراز سطح آب مخزن را نشان می دهد. نتایج تحلیل این نمودار نشان داد که بالاترین همبستگی معنادار، میان تراز یک روز خاص و مقدار آن دقیقاً در روز قبل (تأخیر ۱-) دیده می شود. همچنین، بیشترین ضرایب همبستگی مثبت و معنادار مربوط به متغیرهای حجم مخزن (RV)، مساحت سطح آب (RA) و خود تراز مخزن (RL) در تأخیرهای صفر و یک روزه (تأخیر ۰ و ۱-) است. به عنوان مثال، ضریب همبستگی RV با RL در تأخیر صفر حدود ۰/۹۵ و RA با RL حدود ۰/۹۰ برآورد می شود که بیانگر رابطه قوی و آنی این متغیرها با تراز مخزن است. در مقابل، متغیرهای هواشناسی نظیر باران، دما و تبخیر در مقیاس روزانه، ضرایب همبستگی بسیار پایین (اغلب کمتر از ۰/۲) و اغلب غیرمعنادار نشان دادند. بنابراین با استناد به این تحلیل و نیز نتایج تابع خودهمبستگی جزئی (PACF)، پنج متغیر نهایی شامل دبی ورودی روز قبل (QI-1)، دبی خروجی روز قبل (QO-1)، مساحت مخزن روز جاری (RA)، حجم مخزن روز جاری (RV) و تراز مخزن روز قبل (RL-1) به عنوان ورودی های مدل های هیبریدی انتخاب شدند کل داده ها به طور تصادفی به دو بخش آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم گردیدند (Kohavi, 1995; Refaeilzadeh)

¹ Cross-Correlation Function



شکل ۳- همبستگی متقاطع تراز مخزن با متغیرهای ورودی (دبی خروجی، حجم، دبی ورودی، تبخیر، دما، باران، مساحت)

Fig 3- Cross-correlation of reservoir level with input variables (outflow, volume, inflow, evaporation, temperature, rainfall, area)



شکل ۴. نمودار خودهمبستگی (ACF) تراز مخزن

Fig 4. Autocorrelation function (ACF) plot of reservoir level.

جدول ۲- تحلیل آمار توصیفی متغیرهای ثبت شده توسط ابزار دقیق سد

Table 2 – Descriptive statistical analysis of variables recorded by the dam's instrumentation.

متغیر	میانگین	میانه	انحراف معیار	کمینه	بیشینه	چولگی	کشیدگی
حجم مخزن	500	430	302	52	1171	0.5	-0.87
مساحت مخزن	29	28	11	0	52	0.16	-1
دبی ورودی	58.4	31	87	0	854	3.4	15
دبی خروجی	58	7	92	1	600	2.2	6
تراز آب مخزن	256	255	11	230	273	-0.14	-0.9

WOA در صدر این رقابت ایستاده است. ضریب تبیین (R^2) برای این مدل به رقم خیره کننده ۰/۹۹۹۱ رسیده که نشان می دهد تقریباً تمام واریانس موجود در داده های تراز مخزن توسط شبکه شناسایی شده است. در کنار این همبستگی بالا، میانگین خطای مطلق (MAE) برابر با ۰/۴۰۲۸ متر ثبت شده است. شاخص پراکندگی (SI) برای مدل WOA برابر با ۰/۰۱۰۱ محاسبه شد. بر اساس طبقه بندی های استاندارد هیدرولوژیکی، هر مدلی که SI آن کمتر از ۰/۱ باشد، در رده «بسیار عالی» قرار می گیرد. فاصله زیاد این عدد تا مرز ۰/۱، حاشیه اطمینان بالایی را برای تصمیم گیری های حساس، مانند رهاسازی آب در شرایط بحرانی، فراهم می کند. همچنین، مقدار NRMSE برابر با ۰/۰۱۰۱ تأیید می کند که مدل در برابر پیک های ناگهانی دبی ورودی یا نوسانات شدید، دچار خطاهای بزرگ نمی شود و پایداری خود را حفظ می کند.

باید در نظر داشت که کشیدگی بسیار مثبت دبی ورودی و خروجی سبب ایجاد قله های تیز و دم های سنگین شده که نشانه ای از احتمال بالای پیک های شدید جریان یا سیلاب های ناگهانی در دوره مورد مطالعه است. تحلیل این ویژگی های آماری سبب شد تا پیش پردازش داده ها به صورت دقیق انجام گیرد و عملیات نرمال سازی، تبدیل لگاریتمی یا مدیریت داده های پرت در دستور کار قرار گرفته تا اثرات نامطلوب عدم تقارن و دم های سنگین بر همگرایی مدل های هوش مصنوعی کاهش یافته و دقت پیش بینی ها تا حد امکان بالاتر رفته و از خطاهای محتمل جلوگیری شود.

۲-۳- مقایسه مدل های هیبریدی

نگاهی به اعداد مندرج در جدول ۳، تصویر روشنی از رقابت میان این چهار الگوریتم را در مرحله آزمون به دست می دهد. مدل ANN-

جدول ۳- نتایج عملکرد مدل های هیبریدی برای تخمین تراز سطح آب مخزن در مرحله آموزش و آزمون

Table 3- Performance results of hybrid models for estimating reservoir water level during the training and testing phases.

آموزش				آزمون				مدل
NRMSE	MAE	SI	R^2	NRMSE	MAE	SI	R^2	-
0.0128	0.5151	0.0128	0.9988	0.0129	0.5152	0.0129	0.9987	ANN – GWO
0.0101	0.4028	0.0101	0.9991	0.0101	0.4029	0.0102	0.9992	ANN – WOA
0.0245	1.0588	0.0245	0.9950	0.0247	1.0589	0.0247	0.9951	ANN – HHO
0.0278	1.1877	0.0278	0.9975	0.0279	1.1878	0.0279	0.9974	ANN – ACOR


مطابق شکل ۵، مدل ANN-WOA با محدوده بین چارکی برابر ۰/۰۸ متر، میانه خطای ۰/۰۲- متر و انحراف معیار ۰/۰۵ متر، پایدارترین عملکرد را از خود نشان داد. در مقایسه، مدل ANN-HHO با IQR برابر ۰/۱۵ متر، میانه خطای ۰/۰۸ متر و انحراف معیار ۰/۱۲ متر در رتبه آخر قرار گرفت. مدل ANN-ACOR نیز با IQR برابر ۰/۱۲ متر، میانه خطای ۰/۰۵ متر و انحراف معیار ۰/۰۹ متر را به دست آورد. این ویژگی‌ها نشان داد که خطاهای مدل ANN-WOA علاوه بر پراکندگی کمتر نسبت به سایر مدل‌ها، به صورت متقارن و بدون سوگیری سیستماتیک، حول مقدار صفر توزیع شده بود. این الگوی خطا تأیید می‌کند که ANN-WOA در مقایسه با سایر مدل‌های هیبریدی عملکرد بهتر و قابلیت اطمینان بالاتری در پیش‌بینی تراز مخزن از خود نشان داده است. با توجه به موارد بالا می‌توان نتیجه گرفت که مدل ANN-WOA در شرایط واقعی پیش‌بینی تراز سطح آب مخزن، گزینه قابل اعتمادتری نسبت به سایر موارد به شمار می‌آید.

از نظر دقت پیش‌بینی، مدل ANN-WOA با دارا بودن ضریب تبیین (R^2) برابر ۰/۹۵ و ریشه میانگین مربعات خطای برابر ۰/۰۷ متر، برتری قابل‌ملاحظه‌ای نسبت به مدل‌های مقایسه‌ای نشان داد. مقادیر متناظر برای مدل‌های ANN-HHO و ANN-ACOR به ترتیب شامل R^2 برابر ۰/۸۷ و ۰/۹۱ و RMSE برابر ۰/۱۴ و ۰/۱۱ متر بود. از دیدگاه آماری، آزمون t-test جفتی انجام‌شده در سطح اطمینان ۹۵ درصد نشان داد که اختلاف عملکرد مدل ANN-WOA با سایر مدل‌ها از نظر آماری معنی‌دار است. این نتایج نشان داد که مدل ANN-WOA هم از نظر معیارهای دقت پیش‌بینی و هم از نظر پایایی آماری و قدرت تعمیم‌پذیری، عملکرد برتری در مقایسه با سایر مدل‌های مورد مطالعه در پیش‌بینی تراز سطح آب مخزن سد سفیدرود را دارا است.

در سوی دیگر این طیف، مدل ANN-HHO قرار دارد. با R^2 برابر ۰/۹۹۵ و MAE حدود ۱/۰۵۸۸ متر، این الگوریتم در مقایسه با سه رقیب دیگر، خطای بیشتری تولید کرده است. شاید در نگاه اول، قرار گرفتن در رتبه آخر، نقطه ضعف بزرگی به نظر برسد. اما باید متصفانه و با دید مهندسی به این اعداد نگریست. شاخص SI برای همین مدل به اصطلاح ضعیف‌تر، برابر با ۰/۲۴۵ است که همچنان بسیار کمتر از آستانه ۰/۱ بوده و در همان دسته بسیار عالی جای می‌گیرد. به عبارت دیگر، حتی وقتی الگوریتم شاهین هریس در بدترین حالت خود نسبت به سایرین عمل می‌کند، خروجی آن برای کاربردهای روزمره مدیریت مخزن کاملاً قابل اتکا و دقیق است.

نکته تأمل‌برانگیز دیگر، بررسی شکاف میان مرحله آموزش و آزمون است. برای هر چهار مدل، تفاوت مقادیر R^2 و MAE بین این دو مرحله بسیار ناچیز و در حد هزارم است. این همپوشانی نشان می‌دهد که الگوریتم‌های فراابتکاری توانسته‌اند به خوبی از پدیده بیش‌برازش جلوگیری کنند و وزن‌هایی را پیدا کنند که نه تنها داده‌های گذشته را حفظ کنند بلکه قابلیت تعمیم به داده‌های نادیده را نیز داشته باشند. در مجموع، می‌توان با اطمینان گفت که ترکیب شبکه عصبی با هر یک از این چهار الگوریتم، ابزاری کارآمد برای شبیه‌سازی تراز سد سفیدرود می‌سازد و انتخاب میان آن‌ها، بیشتر به اولویت‌های خاص پروژه مانند سرعت همگرایی در برابر دقت نهایی بستگی دارد.

شکل ۵ توزیع خطای پیش‌بینی مدل‌های هیبریدی بر پایه شبکه عصبی مصنوعی را در مرحله آزمون نشان می‌دهد. این توزیع به صورت نمودار جعبه‌ای رسم گردید و خطای پیش‌بینی و اختلاف میان مقادیر واقعی و پیش‌بینی‌شده تراز آب مخزن سد سفیدرود محاسبه شد. بر پایه بررسی‌های آماری انجام‌گرفته، مدل ANN-WOA کمترین پراکندگی را داشته و انحراف معیار آن نسبت به سایر مدل‌ها پایین‌تر بود. همچنین



شکل ۵- نمودار جعبه‌ای توزیع خطای در بخش آزمون برای مدل‌های هیبریدی. ۲۵٪: چارک پایینی خطاها، ۷۵٪: چارک بالای خطاها

Fig 5- Box plot of error distribution in the test set for hybrid models (25%: lower quartile of errors, 75%: upper quartile of errors)

مشخص امری اجتناب‌ناپذیر است؛ به‌طوری‌که کاهش همزمان اندازه جمعیت و تعداد تکرارها به زیر ۳۰، منجر به همگرایی زودرس^۱، ناتوانی الگوریتم‌ها در دستیابی به بهینه سراسری و افت چشمگیر عملکرد مدل‌ها می‌شود. این موضوع به‌وضوح تأیید می‌کند که برای رسیدن به نتایج پایدار و قابل‌اعتماد، وجود حداقل تعداد عامل‌های جستجو و دورهای تکرار ضروری است.

برای ارزیابی دقیق‌تر تأثیر مستقل تعداد تکرارها بر عملکرد، در حالی که پارامترهای اندازه جمعیت و محدوده جستجوی وزن‌ها و بایاس‌ها ثابت نگه داشته شدند، الگوریتم‌ها در پنج سطح تکرار شامل ۱۰، ۱۰۰، ۵۰۰، ۸۰۰ و ۱۰۰۰ مورد آزمون قرار گرفتند. جدول ۴، تغییرات شاخص NRMSE در مراحل مختلف بهینه‌سازی را نشان می‌دهد. مقادیر خطا برای تمامی مدل‌های هیبریدی از تکرار ۱۰۰ به بعد تقریباً بدون تغییر باقی مانده و از تکرار ۵۰۰ به بعد کاملاً به حالت اشباع و ثبات رسیده‌اند. این همگرایی زود هنگام نشان می‌دهد که الگوریتم‌ها پیش از رسیدن به سقف مجاز تکرار به جواب بهینه یا همسایگی بسیار نزدیک به آن دست یافته‌اند لذا می‌توان نتیجه گرفت که انتخاب ۱۰۰۰ تکرار نه تنها کاملاً کافی بلکه رویکردی محافظه‌کارانه و ایمن محسوب می‌شود که حاشیه اطمینان لازم را برای مسائل با پیچیدگی بالاتر فراهم می‌سازد. هرچند اعدادی در حدود ۶۰۰ تا ۷۰۰ تکرار نیز می‌توانستند کارآمد باشند.

علاوه بر پارامترهای عمومی، پارامترهای اختصاصی هر الگوریتم فراابتکاری نیز دقیقاً بر اساس تنظیمات پیشنهادی در مقالات مرجع و معتبر آن‌ها در جداول ۴ و ۶ تنظیم گردیدند. از جمله این تنظیمات می‌توان به پارامتر $b = 1$ برای کنترل شکل مارپیچ لگاریتمی در الگوریتم وال (Mirjalili & Lewis, 2016)، پارامتر $\beta = 1.5$ برای پرش لوی^۲ در الگوریتم شاهین هریس (Heidari et al., 2019)، و پارامترهای مربوط به آرشو و نرخ نمونه‌برداری در الگوریتم کلونی مورچگان پیوسته (Socha & Dorigo, 2008) اشاره کرد. جهت اطمینان از پایداری نتایج و حذف اثرات تصادفی ناشی از مقداردهی اولیه وزن‌ها، فرآیند آموزش هر مدل طی ۵ اجرای مستقل^۳ با مقداردهی اولیه تصادفی متفاوت تکرار شد. در این فرآیند، کد پیاده‌سازی شده به‌طور خودکار مقدار تابع هدف را در پایان هر اجرا ارزیابی کرده و بهترین اجرا که کمترین خطا و همگرایی مطلوب‌تری را ارائه داد به‌عنوان مدل نهایی برای گزارش‌دهی انتخاب گردید.

در نهایت، برای دستیابی به یک قضاوت نهایی و یکپارچه، از شاخص GPI به‌عنوان یک معیار پنج‌عاملی استفاده شد که بر اساس پیشنهاد Stone (1993) و Behar et al. (2015) و همچنین معادله ۱۰، از ترکیب پنج شاخص RMSE، U95، MBE، Tstat و R^2 تشکیل شده است. در این شاخص، هرچه مقدار GPI به عدد صفر نزدیک‌تر باشد، مدل از نظر دقت، عدم سوگیری و پایداری آماری برتری دارد. نتایج ارائه‌شده در شکل ۶ نشان می‌دهد که مدل ANN-WOA کمترین مقدار GPI را در بین تمامی مدل‌های ترکیبی کسب کرده است که این امر برتری قطعی آن را در تخمین تراز مخزن سد سفیدرود تأیید می‌کند. به‌منظور بررسی معنی‌داری آماری اختلاف عملکرد مدل ANN-WOA با سایر مدل‌های هیبریدی، آزمون t جفتی (Paired t-test) در سطح اطمینان ۹۵٪ بر روی خطاهای پیش‌بینی داده‌های آزمون انجام شد. نتایج این آزمون جدول ۵ نشان داد که در هر سه مقایسه، مقدار p-value کمتر از ۰/۰۰۱ است که بیانگر رد فرض صفر و وجود اختلاف معنی‌دار آماری بین مدل ANN-WOA و سایر مدل‌هاست. مقادیر بالای آماره t به ترتیب ۸/۶۷، ۱۶/۲۳ و ۱۶/۱۲ برای مقایسه با-ANN، ANN-ACOR، GWO و ANN-HHO نشان‌دهنده بزرگی اثر اختلاف و تأیید می‌کند که برتری مدل ANN-WOA نه تنها از نظر آماری معنی‌دار، بلکه از نظر عملی نیز قابل توجه است.


شکل ۶، مقادیر شاخص‌های آماری متفاوت شامل SI، NRMSE و MBE را برای ارزیابی مدل‌های مختلف هیبریدی نشان می‌دهد. بر این اساس، الگوریتم‌های فراابتکاری به ترتیب WOA، GWO، HHO و ACOR در بهینه‌سازی ساختار و پارامترهای شبکه عصبی مصنوعی عملکرد بهتری از خود نشان دادند. همچنین، شاخص‌های R^2 و MAE نیز روند مشابهی را تأیید کرده و همخوانی کاملی با سایر معیارهای خطا دارند.

در این پژوهش، به‌منظور فراهم آوردن یک بستر مقایسه‌ای عادلانه و استاندارد، پارامترهای عمومی بهینه‌سازی در تمامی مدل‌های ترکیبی به‌صورت یکسان تنظیم گردیدند. بر اساس رویکرد سیستماتیک آزمون و خطا و تحلیل حساسیت، اندازه جمعیت ۱۰۰ عامل، حداکثر تعداد تکرار ۱۰۰۰ دور و محدوده جستجو برای وزن‌ها و بایاس‌های شبکه عصبی در بازه $[-10, +10]$ انتخاب شد. نتایج نشان داد که در مسائل پیچیده و چندوجهی هیدرولوژیکی، تخصیص حداقل منابع محاسباتی

¹ Premature Convergence

² Lévy flight

³ Independent Runs



شکل ۶- مقادیر شاخص‌های آماری متفاوت برای مدل‌های مختلف هیبریدی
 Fig 6 - Values of various statistical indices for different hybrid models

جدول ۴- مقادیر NRMSE در دوره آموزش برای الگوریتم‌های متفاوت
 Table 4- NRMSE values during the training period for different algorithms

Iteration Number	ANN-GWO	ANN-HHO	ANN-WOA	ANN-ACOR
I=10	0.115	0.085	0.100	0.120
I=100	0.060	0.045	0.070	0.080
I=500	0.015	0.030	0.020	0.040
I=800	0.013	0.026	0.012	0.030
I=1000	0.0129	0.0247	0.0101	0.0279

جدول ۵. نتایج آزمون t جفتی برای مقایسه آماری مدل ANN-WOA با سایر مدل‌های هیبریدی

Table 5. Results of the paired t-test for the statistical comparison of the ANN-WOA model with other hybrid models.

نتیجه	p-value	درجه آزادی	آماره t	مقایسه
Significant	<0.001	1642	8.67	ANN-WOA vs. ANN-GWO
Significant	<0.001	1642	16.23	ANN-WOA vs. ANN-ACOR
Significant	<0.001	1642	16.12	ANN-WOA vs. ANN-HHO

جدول ۶- پارامترهای کنترلی بهینه مدل‌های هیبریدی

Table 6 - Optimal control parameters of the hybrid models

مدل	ANN - GWO	ANN-HHO	ANN-ACOR	ANN-WOA
تعداد جمعیت	100	100	100	100
حداکثر تعداد تکرار	1000	1000	1000	1000
حد پایین و بالای وزن‌ها و بایاس‌ها	(-10,10)	(-10,10)	(-10,10)	(-10,10)
پارامترهای دیگر	-	$\beta=1.5$	-	-

اجتماعی (رتبه‌های آلفا، بتا و دلتا) و رفتار شکار گروهی، رویکردی ساختار یافته‌تر را دنبال می‌کند. وجود این سلسله‌مراتب باعث می‌شود که جمعیت عامل‌ها به صورت هدفمند و با هدایت گرگ‌های برتر به سمت مناطق امیدبخش فضای جستجو حرکت کنند. این سازوکار ساده اما کارآمد، به GWO امکان می‌دهد تا در مراحل اولیه آموزش شبکه عصبی، همگرایی بسیار سریعی از خود نشان دهد.

اگرچه این تمرکز بالا گاهی ریسک گیر افتادن در بهینه‌های محلی را افزایش می‌دهد، اما در این پژوهش، GWO تعادل بسیار مطلوبی بین سرعت محاسباتی و دقت نهایی برقرار کرد. الگوریتم شاهین هریس نیز با شبیه‌سازی رفتار شکار تعاونی و کمین این پرندگان، استراتژی متفاوتی را ارائه می‌دهد. ویژگی متمایز HHO، استفاده از پرش‌های لوی در فازهای مختلف محاصره است. این جهش‌های تصادفی با گام‌های متغیر به الگوریتم این قابلیت را می‌دهد که در صورت گیر افتادن در بهینه‌های محلی عمیق (که در فضای چندبعدی وزن‌های شبکه عصبی بسیار رایج است)، با یک جهش بزرگ از آن ناحیه خارج شود. همین ویژگی باعث شده تا HHO در مدیریت عدم قطعیت‌ها و نوسانات غیرخطی داده‌های هیدرولوژیکی، عملکرد قابل‌قبولی از خود نشان دهد. از سوی دیگر، الگوریتم کلونی مورچگان برای دامنه‌های پیوسته (ACOR)، با بازتعریف مفهوم ردپای فرمون برای فضاهای پیوسته، مکانیزمی مبتنی بر نمونه‌برداری از توزیع گاوسی ارائه می‌دهد. در این روش، راه‌حل‌های بهتر وزن بیشتری در آرشیو می‌گیرند و جستجوی اطراف آن‌ها را هدایت می‌کنند. این رویکرد برای تنظیم دقیق وزن‌ها و بایاس‌ها در همسایگی یک جواب خوب، بسیار کارآمد است. هرچند ممکن است سرعت کاوش سراسری آن در مقایسه با الگوریتم‌های مبتنی بر شکار کمی کندتر باشد اما پایداری آن در هموارسازی تابع خطا در مراحل پایانی آموزش، ارزشمند است.


در مجموع، برتری مدل ANN-WOA در پیش‌بینی تراز مخزن سد

شکل ۷ روند همگرایی الگوریتم‌های هیبریدی مختلف را طی فرآیند بهینه‌سازی نشان می‌دهد. این منحنی‌ها، تغییرات MSE را برای بهترین عامل جستجو در هر الگوریتم در طول تکرارها مشخص می‌سازد به طوری که بررسی درست این منحنی‌ها، تصویر روشنی از سرعت و کارایی هر روش فراابتکاری به دست می‌دهد. همان‌طور که از نمودار معلوم است مدل ANN-GWO همگرایی سریع‌تری داشته و پایداری آن نیز بیشتر بود. این مدل در تعداد تکرارهای کمتری به جواب نزدیک به بهینه رسید که این موضوع، توانایی بالای الگوریتم گرگ خاکستری را در برقراری تعادل میان جستجوی جهانی (اکتشاف) و جستجوی محلی (بهره‌برداری) تأیید می‌کند و در فضای پارامتری پیچیده شبکه‌های عصبی، فرار از بهینه‌های محلی را نیز آسان‌تر می‌سازد. اگرچه مدل ANN-GWO سرعت همگرایی بیشتری نسبت به مدل ANN-WOA دارد اما انتخاب الگوریتم بهینه‌ساز باید با توجه به اولویت‌هایی مانند سرعت محاسباتی یا دقت پیش‌بینی و یا ترکیبی از این دو مولفه انجام گیرد.

الگوریتم‌های فراابتکاری به کاررفته در این پژوهش، هر یک با الهام از پدیده‌های متفاوت طبیعی، مکانیزم‌های جستجوی منحصربه‌فردی را برای بهینه‌سازی وزن‌ها و بایاس‌های شبکه عصبی ارائه می‌دهند که درک این تفاوت‌ها، کلید تفسیر صحیح نتایج به دست آمده است. الگوریتم بهینه‌سازی وال بر پایه شبیه‌سازی رفتار تغذیه‌ای نهنگ‌های گوژپشت طراحی شده است. مکانیسم جستجوی حلزونی و حمله حباب‌محور در این الگوریتم، تعادل پویایی میان اکتشاف سراسری و بهره‌برداری محلی برقرار می‌کند. این ویژگی ذاتی، الگوریتم را قادر می‌سازد تا در مواجهه با توپوگرافی پیچیده و چندوجهی تابع خطای داده‌های هیدرولوژیکی، از گیر افتادن در بهینه‌های محلی اجتناب ورزد و همگرایی پایداری به سمت بهینه سراسری داشته باشد. در نتیجه، تنظیم دقیق‌تر پارامترهای شبکه و کسب بالاترین دقت پیش‌بینی توسط این مدل، دور از انتظار نبود. در مقابل، الگوریتم گرگ خاکستری با تکیه بر سلسله‌مراتب

این حال، عملکرد قابل قبول سه الگوریتم دیگر نیز تأیید می‌کند که پیوند شبکه‌های عصبی با هر یک از این روش‌های فراابتکاری، پتانسیل بالایی برای تبدیل شدن به ابزاری قابل اعتماد در مدل‌سازی پدیده‌های هیدرولوژیکی پیچیده و مدیریت عملیاتی منابع آب دارد.

سفیدرود را می‌توان به توانایی ذاتی این الگوریتم در برخورد با مسائل غیرخطی پیچیده و ایجاد تعادل هوشمندانه میان جستجو و استخراج نسبت داد. راهبرد حرکت تطبیقی و جستجوی هوشمند آن، همگرایی پایدارتری نسبت به دیگر الگوریتم‌های بررسی‌شده به همراه داشت. با



شکل ۷- روند همگرایی (کاهش خطا) مدل‌های مختلف هیبریدی در طول تکرار

Fig 7 - Convergence trend (error reduction) of various hybrid models across iterations.

شفافیت مدل، بینش ارزشمندی درباره رفتار آن در شرایط هیدرولوژیکی مختلف ارائه خواهد داد و پذیرش آن را توسط تصمیم‌گیران عملیاتی تسهیل می‌کند.

۴- نتیجه‌گیری نهایی

این پژوهش با هدف پیش‌بینی روزانه تراز آب مخزن سد سفیدرود، چهار مدل ترکیبی مبتنی بر شبکه عصبی مصنوعی و الگوریتم‌های فراابتکاری وال، گرگ خاکستری، شاهین هریس و کلونی مورچگان پیوسته را توسعه داد. بر اساس تحلیل‌های همبستگی متقاطع و خودهمبستگی، پنج متغیر ورودی کلیدی شامل دبی ورودی و خروجی روز قبل، مساحت و حجم مخزن در روز جاری، و تراز سطح آب روز قبل گزینش شدند.

نتایج ارزیابی نشان داد که مدل ANN-WOA با کسب کمترین مقادیر خطا و بالاترین ضریب تبیین ($R^2 = 0.9991$)، برتری محسوسی نسبت به سایر مدل‌ها دارد و بر اساس شاخص عملکرد جهانی نیز رتبه نخست را به‌دست آورد. مدل‌های ANN-GWO، ANN-ACOR و ANN-HHO به ترتیب در جایگاه‌های بعدی قرار گرفتند. این برتری ناشی از توانایی ذاتی WOA در ایجاد تعادل پویا میان اکتشاف و بهره‌برداری و اجتناب از بهینه‌های محلی است که منجر به دقتی فراتر از مطالعات پیشین نظیر Rehamnia & Mahdavi-Meymand (2025) و Hakimi Khansar et al. (2024) گردید. این نتایج هم‌راستا با روند رو به رشد کاربرد الگوریتم‌های فراابتکاری در بهینه‌سازی

داده‌های هیدرولوژیکی مورد استفاده در این پژوهش، علی‌رغم طول دوره ۱۵ ساله، از محدودیت‌هایی رنج می‌بردند که می‌توانستند بر کیفیت نهایی مدل‌ها اثر بگذارند. وجود چولگی مثبت و کشیدگی بالا در توزیع دبی ورودی (جدول ۲)، نشان‌دهنده حضور مقادیر پرت و پیک‌های شدید جریان است که فرآیند آموزش شبکه عصبی را با چالش مواجه می‌کنند. افزون بر این، احتمال وجود داده‌های گمشده یا نویزی در سری زمانی ۱۵ ساله، به‌ویژه در سال‌های اولیه دوره مطالعه، مسئله‌ای است که نمی‌توان آن را نادیده گرفت. محدودیت دیگر، عدم دسترسی به داده‌های ایستگاه‌های بالادست حوضه آبریز بود که می‌توانستند به‌عنوان متغیرهای کمکی، غنای اطلاعاتی مدل را افزایش دهند. با این حال، تلاش شد از طریق نرمال‌سازی داده‌ها به بازه $[0/1, 0/9]$ ، گزینش دقیق ورودی‌ها با تحلیل همبستگی متقاطع، و به‌کارگیری شاخص‌های ارزیابی چندمعیاره، اثرات این محدودیت‌ها تا حد ممکن کاهش یابد. پیشنهاد می‌شود در پژوهش‌های آتی، از روش‌های پیشرفته بازسازی داده‌های گمشده و همچنین ادغام داده‌های ایستگاه‌های متعدد حوضه آبریز استفاده شود تا پایداری مدل‌ها در شرایط واقعی‌تر سنجیده شود.

یکی از محدودیت‌های ذاتی مدل‌های توسعه‌یافته در این پژوهش، ماهیت جعبه سیاه شبکه‌های عصبی و فقدان قابلیت تفسیرپذیری است که می‌تواند پذیرش آن‌ها را در محیط‌های عملیاتی با چالش مواجه سازد. پیشنهاد می‌شود در مطالعات آتی، روش‌های هوش مصنوعی قابل توضیح (XAI) نظیر SHAP و LIME برای تحلیل سهم هر متغیر ورودی در پیش‌بینی نهایی به‌کار گرفته شوند. این رویکرد، ضمن افزایش

اقلیمی و عملیاتی متنوع سنجیده شود. همچنین، به منظور افزایش شفافیت و پذیرش عملیاتی، بهره‌گیری از روش‌های هوش مصنوعی قابل توضیح (XAI) برای تحلیل سهم هر متغیر ورودی در پیش‌بینی نهایی، مسیر پژوهشی ارزشمندی محسوب می‌شود. در مجموع، پتانسیل بالای پیوند شبکه‌های عصبی با الگوریتم‌های فراابتکاری، به‌ویژه الگوریتم وال، این رویکرد را به ابزاری کارآمد برای مدیریت هوشمند منابع آب در مخازن سدها تبدیل کرده است.

از مدل ANN WOA برای زمان‌بندی رهاسازی آب کشاورزی در ماه‌های بحرانی، بهینه‌سازی تولید برق در ساعات پیک، هشدار سیلاب با به‌روزرسانی روزانه، زمان‌بندی عملیات فلاشینگ رسوب و یکپارچه‌سازی در سامانه‌های تصمیم‌گیری سد استفاده شود. در آینده، مدل در دوره‌های ترسالی و خشکسالی آزمون شده و با روش‌های XAI برای شفافیت بیشتر ترکیب گردد.

بهره‌برداری از مخازن است (Lai et al., 2022). مدل‌های توسعه‌یافته صرفاً بر روی یک مطالعه موردی (سد سفیدرود) در یک دوره ۱۵ ساله ارزیابی شده‌اند و آزمون مستقلی بر مخازن دیگر یا دوره‌های هیدرولوژیکی حدی صورت نگرفته است. ماهیت منحصر به فرد این سد و عملیات بهره‌برداری خاص آن، تعمیم نتایج را بدون اعتبارسنجی مستقل دشوار می‌سازد؛ چرا که وزن‌های بهینه‌شده مختص داده‌های این مطالعه هستند و نیازمند آموزش مجدد می‌باشند. افزون بر این، ماهیت «جعبه سیاه» شبکه‌های عصبی، تفسیرپذیری مدل‌ها را در محیط‌های عملیاتی محدود می‌کند و می‌تواند پذیرش آن‌ها را توسط تصمیم‌گیران با چالش مواجه سازد.

از این‌رو، پیشنهاد می‌شود در مطالعات آتی، کارایی این رویکرد در مخازنی با رژیم‌های هیدرولوژیکی متفاوت و نیز تحت سناریوهای

منابع

- Barzegar R, Fijani E, Moghaddam AA, and Tziritis E, 2017. Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models, *Science of the Total Environment*, 599, 20–31, [doi:10.1016/j.scitotenv.2017.04.189](https://doi.org/10.1016/j.scitotenv.2017.04.189).
- Behar O, Khellaf A, and Mohammedi K, 2015. Comparison of solar radiation models and their validation under Algerian climate – The case of direct irradiance, *Energy Conversion and Management*, 98, 236–251, [doi:10.1016/j.enconman.2015.03.067](https://doi.org/10.1016/j.enconman.2015.03.067).
- Buyukyildiz M, Tezel G, and Yilmaz V, 2014. Estimation of the change in lake water level by artificial intelligence methods, *Water Resources Management*, 28(13), 4747–4763, [doi:10.1007/s11269-014-0773-1](https://doi.org/10.1007/s11269-014-0773-1).
- Das M, Ghosh SK, Chowdary V, Saikrishnaveni A, and Sharma R, 2016. A probabilistic nonlinear model for forecasting daily water level in reservoir, *Water Resources Management*, 30(9), 3107–3122, [doi:10.1007/s11269-016-1334-6](https://doi.org/10.1007/s11269-016-1334-6).
- Das S, Forer L, Schönherr S, Sidore C, Locke AE, Kwong A, Vrieze SI, Chew EY, Levy S, and McGue M, 2016. Next-generation genotype imputation service and methods, *Nature Genetics*, 48(10), 1284–1287, [doi:10.1038/ng.3656](https://doi.org/10.1038/ng.3656).
- Rehamnia: [10.1038/ng.3656](https://doi.org/10.1038/ng.3656).
- Hakimi Khansar H, 2021. Simulation of behavior of the Kabudval Dam during construction with 3D numerical modeling, *Amirkabir Journal of Civil Engineering*, 53(9), 20–20, [doi:10.22060/ceej.2020.18172.6790](https://doi.org/10.22060/ceej.2020.18172.6790).
- Hakimi Khansar H, Salimi H, and Shiri J, 2024. Extended estimation of daily inflow of Sefidroud dam using meta-heuristic algorithms combined with fuzzy neural inference system, *Amirkabir Journal of Civil Engineering*, 56(1), 3–22, [doi:10.22060/ceej.2024.22456.8102](https://doi.org/10.22060/ceej.2024.22456.8102) (In Persian).
- Hecht-Nielsen R, 1988. Neurocomputing: Picking the human brain, *IEEE Spectrum*, 25(3), 36–41, [doi:10.1109/6.4520](https://doi.org/10.1109/6.4520).
- Heidari AA, Mirjalili S, Faris H, Aljarah I, Mafarja M, and Chen H, 2019. Harris hawks optimization: Algorithm and applications, *Future Generation Computer Systems*, 97, 849–872, [doi:10.1016/j.future.2019.02.028](https://doi.org/10.1016/j.future.2019.02.028).
- Hipni A, El-shafie A, Najah A, Karim OA, Hussain A, and Mukhlisin M, 2013. Daily forecasting of dam water levels: Comparing a support vector machine (SVM) model with adaptive neuro fuzzy inference system (ANFIS), *Water Resources Management*,

- 27(10), 3803–3823, doi.org/10.1007/s11269-013-0382-4.
- Kişî Ö, 2008. River flow forecasting and estimation using different artificial neural network techniques, *Hydrology Research*, 39(1), 27–40, [doi:10.2166/nh.2008.026](https://doi.org/10.2166/nh.2008.026).
- Kisi O, Shiri J, and Nikoofar B, 2012. Forecasting daily lake levels using artificial intelligence approaches, *Computers & Geosciences*, 41, 169–180, [doi:10.1016/j.cageo.2011.08.027](https://doi.org/10.1016/j.cageo.2011.08.027).
- Kohavi R, 1995. A study of cross-validation and bootstrap for accuracy estimation and model selection, In *Proceedings of the 14th International Joint Conference on Artificial Intelligence*, Morgan Kaufmann, 2, 1137–1145.
- Lai V, Huang YF, Koo CH, and Ahmed AN, 2022. A review of reservoir operation optimisations: from traditional models to metaheuristic algorithms, *Archives of Computational Methods in Engineering*, 29, 3435–3457, [doi:10.1007/s11831-021-09701-8](https://doi.org/10.1007/s11831-021-09701-8).
- Lewis-Beck MS, 2005. Election forecasting: Principles and practice, *The British Journal of Politics and International Relations*, 7(2), 145–164, [doi:10.1111/j.1467-856X.2005.00178.x](https://doi.org/10.1111/j.1467-856X.2005.00178.x).
- Li MF, Tang XP, Wu W, and Liu HB, 2013. General models for estimating daily global solar radiation for different solar radiation zones in mainland China, *Energy Conversion and Management*, 70, 139–148, [doi:10.1016/j.enconman.2013.03.004](https://doi.org/10.1016/j.enconman.2013.03.004).
- Ma C, and Iqbal M, 1984. Statistical comparison of solar radiation correlations monthly average global and diffuse radiation on horizontal surfaces, *Solar Energy*, 33, 143–148.
- Maroufpoor S, Maroufpoor E, Bozorg-Haddad O, Shiri J, and Yaseen ZM, 2019. Soil moisture simulation using hybrid artificial intelligent model: Hybridization of adaptive neuro fuzzy inference system with grey wolf optimizer algorithm, *Journal of Hydrology*, 575, 544–556.
- Mirjalili S, and Lewis A, 2016. The whale optimization algorithm, *Advances in Engineering Software*, 95, 51–67, [doi:10.1016/j.advengsoft.2016.01.008](https://doi.org/10.1016/j.advengsoft.2016.01.008).
- Modabberi H, Hashemi MMR, Ashournia M, and Rahimpour MA, 2017. Sensitivity analysis and vulnerability mapping of the Guilan aquifer using Drastic method, *Reviews on Environmental Health and Environmental Science*, 4(1), 27–41, [doi:10.18488/journal.80.2017.41.27.41](https://doi.org/10.18488/journal.80.2017.41.27.41).
- Modaberi H, and Shokoohi A, 2020. Determining water requirement of Anzali Wetland based on eco-tourism indices within the framework of IWRM, *Iranian Journal of Soil and Water Research*, 51(10), 2501–2517, [doi:10.22059/ijswr.2020.303554.6686](https://doi.org/10.22059/ijswr.2020.303554.6686) 33 (In Persian with English Abstract).
- Parsa J, Hakimi Khansar H, Hoseinzadeh Dalir A, and Shiri J, 2021. Simulation of soil stress in earth dams using artificial intelligence models and determination of effective features, *Amirkabir Journal of Civil Engineering*, [doi:10.22060/ceej.2021.18682.6925](https://doi.org/10.22060/ceej.2021.18682.6925).
- Patino CM, and Ferreira JC, 2015. Confidence intervals: A useful statistical tool to estimate effect sizes in the real world, *Jornal Brasileiro de Pneumologia*, 41, 565–566, [doi:10.1590/S1806-3756201500000003](https://doi.org/10.1590/S1806-3756201500000003) 14.
- Rehamnia I, and Mahdavi-Meymand A, 2025. Advancing reservoir water level predictions: evaluating conventional, ensemble and integrated swarm machine learning approaches, *Water Resources Management*, 39(2), 779–794, [doi:10.1007/s11269-024-03999-0](https://doi.org/10.1007/s11269-024-03999-0).
- Refaeilzadeh P, Tang L, and Liu H, 2009. Cross-validation, In Liu L and Özsu MT (Eds.), *Encyclopedia of Database Systems*, Springer, 532–538.
- Sammen SS, Mohamed T, Ghazali A, Sidek L, and El-Shafie A, 2017. An evaluation of existent methods for estimation of

embankment dambreach parameters, *Natural Hazards*, 87(1), 545566, [doi:10.1007/s11069-017-2764-z](https://doi.org/10.1007/s11069-017-2764-z).

Shamim MA, Hassan M, Ahmad S, and Zeeshan M, 2016. A comparison of artificial neural networks (ANN) and local linear regression (LLR) techniques for predicting monthly reservoir levels, *KSCE Journal of Civil Engineering*, 20(2), 971–977, [doi:10.1007/s12205-015-0298-z](https://doi.org/10.1007/s12205-015-0298-z).

- Socha K, and Dorigo M, 2008. Ant colony optimization for continuous domains, *European Journal of Operational Research*, 185(3), 1155–1173, [doi:10.1016/j.ejor.2006.06.046](https://doi.org/10.1016/j.ejor.2006.06.046).

Soleymani Z, Mahmoodabadi N, and Nouri MM, 2016. Language skills and phonological awareness in children with cochlear

implants and noral hearing, *International Journal of Pediatric Otorhinolaryngology*, 83, 16–21.

Stone RJ, 1993. Improved statistical procedure for the evaluation of solar radiation estimation models, *Solar Energy*, 51(4), 289–291.

Valizadeh N, and El-Shafie A, 2013. Forecasting the level of reservoirs using multiple input fuzzification in ANFIS, *Water Resources Management*, 27(9), 3319–3331, [doi:10.1007/s11269-013-0349-5](https://doi.org/10.1007/s11269-013-0349-5).

Willmott CJ, and Matsuura K, 2006. On the use of dimensioned measures of error to evaluate the performance of spatial interpolators, *International Journal of Geographical Information Science*, 20(1), 89–102, [doi:10.1080/13658810500286976](https://doi.org/10.1080/13658810500286976).