



## Modeling and Optimization of Water Allocation Using a Hybrid LSTM–HHOA Approach under Climate Change Conditions

Parisa-Sadat Ashofteh<sup>1\*</sup>, Leila Shakarami<sup>2</sup>

1 -Associate Professor, Faculty of Engineering, University of Qom, Qom, Iran.

2 -Ph.D. Student, Faculty of Engineering, University of Qom, Qom, Iran.

\*Corresponding Author: [ps.Ashofteh@qom.ac.ir](mailto:ps.Ashofteh@qom.ac.ir)

### Keywords:

Climate change, Long Short-Term Memory (LSTM), Horse Herd Optimization Algorithm (HHOA), Water allocation optimization, Resiliency

### Received:

22 Aug 2025

### Revised:

06 Oct 2025

### Accepted:

20 Oct 2025

### Extended Abstract

#### Introduction

In recent decades, water resource management—particularly in arid and semi-arid regions—has faced increasing challenges due to climate variability (Helmi et al., 2023) and rising water demand. Climate change alters rainfall patterns, river flows, and evaporation rates, thereby complicating reservoir operation decisions. These changes affect both water storage and agricultural requirements. To address this complexity, mathematical models and intelligent algorithms have been widely applied to optimize reservoir operation. Metaheuristic methods such as Genetic Algorithms (GA), Particle Swarm Optimization (PSO), and Cuckoo Search (CS) (Ming et al., 2015) facilitate scenario analysis and the identification of effective solutions. These algorithms aim to reduce water deficits (Akbari-Alashti et al., 2014), enhance hydropower generation (Hincal et al., 2011), and improve overall reservoir performance (Karami et al., 2019). This study proposes a novel framework that integrates Long Short-Term Memory (LSTM) networks with the Horse Herd Optimization Algorithm (HHOA) to optimize water allocation for Iran's Qaranku Dam under climate change conditions, with a particular focus on agricultural resilience and sustainability.

#### How to cite this article:

Ashofteh, P.-S.; & Shakarami, L. (2025). Modeling and Optimization of Water Allocation Using a Hybrid LSTM–HHOA Approach under Climate Change Conditions. *Journal of Drought and Climate change Research (JDCR)*, 4(13), 131-158. <https://doi.org/10.22077/jdcr.2025.9958.1165>



## Materials and Methods

In this study, the climate prediction process at the basin scale consists of three main steps: selecting an appropriate RCP scenario, employing Atmosphere–Ocean General Circulation Models (AOGCMs) within the CMIP5 framework, and applying proportional downscaling to generate localized climate data. To model reservoir inflow, a Long Short-Term Memory (LSTM) neural network is employed and trained on normalized temperature and precipitation data, with its performance evaluated using metrics such as the Nash–Sutcliffe Efficiency (NSE), Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Kling–Gupta Efficiency (KGE). Downstream irrigation demand is estimated using the CROPWAT software in conjunction with the FAO Penman–Monteith equation, incorporating crop growth stages and relevant climatic variables. The Horse Herd Optimization Algorithm (HHOA), inspired by the social behavior of horses, balances exploration and exploitation and is applied for the first time to water resource allocation problems. The objective function is designed to minimize the average relative deficit in meeting stakeholder demands. Genetic Programming (GP) is also employed for performance comparison. Finally, the resilience index is introduced as a key criterion for evaluating water system performance, reflecting the system's ability to return to optimal operation following disruptions.

## Results and Discussion

This study evaluated 22 climate models from the IPCC's Fifth Assessment Report under the RCP 2.6 scenario to identify the most accurate models for monthly temperature and precipitation forecasting. GFDL-ESM2G exhibited superior performance in temperature simulation, while NorESM1-ME performed best for precipitation. These models were selected for future projections (2070–2099) based on their consistency with historical observations. Monthly runoff for the Qaranku River was forecasted using LSTM neural networks. Trained on data from 1971 to 2000, the model demonstrated strong capability in capturing temporal patterns, although it showed lower accuracy in predicting extreme events such as floods or droughts. Future climate projections indicated a 12.7% decrease in precipitation and a 23% reduction in runoff, accompanied by a 21% increase in average temperature, particularly in July. Agricultural water demand is projected to rise by 20%, especially during the dry months (June–August), thereby intensifying pressure on water resources. Single-objective optimization using the Horse Herd Optimization Algorithm (HHOA) resulted in improved water allocation efficiency for the future period. Despite reduced reservoir releases and increased water shortages, system resilience increased by 17%. Sensitivity analysis revealed that larger population sizes enhanced model stability, while higher learning rates accelerated convergence but increased the risk of overfitting.

## Conclusion

This study identified GFDL-ESM2G and NorESM1-M as the most reliable climate models for simulating temperature and precipitation, respectively, based on historical data from 1971 to 2000. These models were selected for future projections (2070–2099) under the RCP2.6 scenario, which indicate rising temperatures and fluctuating rainfall, potentially increasing drought risk and altering reservoir inflow patterns. The LSTM model effectively simulated monthly runoff, achieving high accuracy (NSE > 0.98 during training and 0.87 during testing), although it exhibited reduced precision in predicting extreme events. Future runoff is expected to decline and become more irregular, raising concerns regarding agricultural water supply. CROPWAT modeling revealed a 20% increase in irrigation demand due to higher temperatures and reduced rainfall efficiency, particularly for long-season crops such as maize and alfalfa. Comparative optimization results showed that HHOA outperformed Genetic Programming (GP), reducing water deficits by 22% and providing more balanced monthly releases. Reservoir resilience improved from 67% to 79%, with HHOA contributing an additional 17% gain through more effective release strategies. Overall, integrating climate models, deep learning approaches, and metaheuristic algorithms—particularly HHOA—offers a robust framework for sustainable water resource management under climate change. Future studies should explore multi-objective extensions of HHOA to further enhance system reliability, vulnerability, and economic efficiency.



## مدل‌سازی و بهینه‌سازی تخصیص آب با ترکیب مدل LSTM و الگوریتم HHOA تحت تغییر اقلیم

پریساسادات آشفته<sup>۱\*</sup>، لیلا شاکرمی<sup>۲</sup>

۱- دانشیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران.  
 ۲- دانشجوی دکتری، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران.

\*نویسنده مسئول: Ps.Ashofteh@qom.ac.ir

### چکیده

### واژه‌های کلیدی:

پژوهش حاضر با هدف بهینه‌سازی تخصیص منابع آب سد قرنقو در افق آینده (۲۰۹۹-۲۰۷۰) و ارتقای تاب‌آوری سامانه تأمین آب انجام شد. از مدل‌های اقلیمی CMIP5، NorESM1-M و GFDL-ESM2G برای بارش به‌عنوان بهترین گزینه‌ها انتخاب شدند. سپس با به‌کارگیری شبکه‌های حافظه‌دار بلندمدت<sup>۱</sup> (LSTM)، رواناب ماهانه حوضه شبیه‌سازی گردید که نتایج از دقت مناسبی برخوردار بود. نیاز آبی محصولات نیز با Cropwat برآورد و نشان داد که در آینده نیاز خالص آبیاری ۲۰ درصد افزایش خواهد یافت. در ادامه، عملکرد الگوریتم بهینه‌سازی گله‌اسب<sup>۲</sup> (HHOA) و برنامه‌ریزی ژنتیک<sup>۳</sup> (GP) برای توابع معیار راستریجین و روزنبروک نشان داد که HHOA بهتر عمل نموده است. بررسی عملکرد HHOA برای تخصیص آب نشان داد که HHOA توانست کسری آب را تا ۲۲ درصد کاهش و تاب‌آوری مخزن را از ۶۷ به ۷۹ درصد افزایش دهد. همچنین، LSTM با ضریب نش-ساتکلیف<sup>۴</sup> (NSE) برابر با ۰/۸۵ توانست رواناب ماهانه را با دقت مناسبی شبیه‌سازی کند.

تغییر اقلیم، HHOA، LSTM، بهینه‌سازی تخصیص آب، تاب‌آوری

### تاریخ دریافت:

۱۴۰۴/۰۵/۳۱

### تاریخ ویرایش:

۱۴۰۴/۰۷/۱۴

### تاریخ پذیرش:

۱۴۰۴/۰۷/۲۸

1. Long-Short Term Memory  
 2. Horse Herd Optimization Algorithm  
 3. Genetic Programming  
 4. Nash-Sutcliffe Efficiency

جستجوی موجودات هم‌زیست مبتنی بر برازش-فاصله-تعداد<sup>۶</sup> (FDB-SOS)، الگوریتم جستجوی هارمونی<sup>۷</sup> (HS)، الگوریتم رقابت استعماری<sup>۸</sup> (ICA) برای مدیریت بهینه سامانه‌های چندمخزنی در حوضه هلیل‌رود ایران مقایسه نمودند. مدل SOS-MSA موفق به تأمین بیش از ۸۸ درصد از تقاضای مخازن شد و شاخص پایداری بالاتری نسبت به سایر الگوریتم‌ها داشت. ییلماز و همکاران (Yilmaz et al., 2025) سه الگوریتم بهینه‌سازی مورچه<sup>۹</sup> (ALO)، الگوریتم مبتنی بر تیم‌نوردی<sup>۱۰</sup> (MTBO) و بهینه‌ساز گرگ خاکستری<sup>۱۱</sup> (GWO) را برای تعیین بهترین برنامه مدیریت شبکه آب شهری استفاده نمودند. الگوریتم GWO کم‌ترین سطح اتلاف اقتصادی را در سامانه‌های مختلف ارائه داد. مدل پیشنهادی برای تصمیم‌گیرندگان در مدیریت نشت و تخصیص منابع بسیار مفید ارزیابی شد. دابرال<sup>۱۲</sup> و همکاران (Dabral et al., 2025) به بهینه‌سازی بهره‌برداری از مخزنی در هند با استفاده از سه الگوریتم چندهدفه شامل NSGA-II، NSGA-III و MOPSO پرداختند. برای تحلیل تصمیم‌گیری، روش EMCP مبتنی بر آنترپوی به کار گرفته شد. NSGA-II موفق به تأمین ۸۳ درصد از تقاضا شد و عملکرد بهتری نسبت به سایر الگوریتم‌ها داشت. NSGA-III و MOPSO به ترتیب ۶۸ و ۴۴ درصد از تقاضا را پوشش دادند. نتایج نشان دادند که NSGA-II برای مسائل پیچیده بهینه‌سازی مخزن مناسب‌تر بود.

تحقیقات اخیر نشان می‌دهند که بهره‌گیری از الگوریتم‌های بهینه‌سازی در حل مسائل مرتبط با مدیریت منابع آب، جایگاه ویژه‌ای در مطالعات علمی و کاربردی یافته است. این اهمیت ناشی از پیچیدگی ذاتی سامانه‌های منابع آب، محدودیت‌های فیزیکی و اقتصادی، و نیاز به تصمیم‌گیری در شرایط عدم قطعیت است. الگوریتم‌های بهینه‌سازی-اعم از کلاسیک، فراابتکاری و ترکیبی قادرند با بررسی حجم عظیمی از داده‌ها و سناریوهای مختلف، بهترین

## مقدمه

در دهه‌های اخیر، چالش‌های مرتبط با مدیریت منابع آب به‌ویژه در مناطق خشک و نیمه‌خشک، به‌واسطه نوسانات اقلیمی (Helmi et al., 2023) و افزایش تقاضا، به یکی از دغدغه‌های اصلی برنامه‌ریزان حوزه آب تبدیل شده است. تغییرات اقلیمی با ایجاد اختلال در الگوهای بارندگی، دبی رودخانه‌ها و تبخیر، موجب پیچیده‌تر شدن فرآیند تصمیم‌گیری در بهره‌برداری از مخازن سدها شده‌اند. این تحولات، نه‌تنها بر میزان ذخیره‌سازی و رهاسازی آب اثرگذارند، بلکه بر نیازهای متغیر بخش کشاورزی نیز تأثیر مستقیم دارند.

در پاسخ به این پیچیدگی‌ها، مدل‌های ریاضی و الگوریتم‌های هوشمند برای تدوین سیاست‌های بهره‌برداری بهینه از مخازن به کار گرفته شده‌اند. استفاده از روش‌های فراابتکاری مانند الگوریتم‌های ژنتیک<sup>۱</sup> (GA)، بهینه‌سازی ازدحام ذرات<sup>۲</sup> (PSO)، جستجوی فاخته<sup>۳</sup> (CS) (Ming et al., 2015)، و سایر الگوریتم‌های الهام‌گرفته از طبیعت، امکان بررسی سناریوهای مختلف و دستیابی به راه‌کارهای مؤثرتر را فراهم کرده است. این الگوریتم‌ها با هدف کاهش کسری آب (Akbari-Alashti et al., 2014)، افزایش تولید انرژی برق‌آبی (Hincal et al., 2011)، و ارتقاء شاخص‌های عملکردی مخازن (Karami et al., 2019)، در مطالعات متعدد مورد ارزیابی قرار گرفته‌اند.

باویا و الانگو (Bhavya and Elango, 2023) به بررسی کاربرد الگوریتم‌های کلونی مورچه‌ها<sup>۴</sup> (ACO) در مسائل پیچیده مدیریت منابع آب مانند بهره‌برداری از مخازن، طراحی شبکه‌های زهکشی شهری و مدیریت آبخوان‌های ساحلی پرداختند. الگوریتم‌های ACO در حل مسائل غیرخطی و چندهدفه عملکرد قابل توجهی داشتند. نسخه‌های ترکیبی ACO نتایج بهتری نسبت به نسخه‌های سنتی ارائه داد. اکبری‌فرد و ذونعمت (Akbarifard and Zounemat-Kermani, 2024)، الگوریتم ترکیبی جستجوی موجودات هم‌زیست براساس الگوریتم ازدحام پروانه‌ها<sup>۵</sup> (SOS-MSA) را با الگوریتم

6. Fitness-Distance-Balance-Based Symbiotic Organisms Search  
7. Harmony Search  
8. Imperialist Competitive Algorithm  
9. Ant Lion Optimizer  
10. Mountaineering Team-Based Optimization  
11. Grey Wolf Optimizer  
12. Dabral

1. Genetic Algorithm  
2. Particle Swarm Optimization  
3. Cuckoo Search  
4. Ant Colony Optimization  
5. Symbiotic Organisms Search based on Moth Swarm Algorithm

است. منابع تغذیه حوضه، برف‌های سنگین کوهستان سهند، کوه‌های اربت‌داغ، آغ‌داغ و هرم‌داغ است. رودخانه اصلی این حوضه آبریز رودخانه قرنقو است. این محدوده شامل منطقه‌ای نیمه‌خشک با فرسایش شدید در بخش‌های بالادست بوده و مستعد لغزش‌های زمین و رسوب‌گذاری بالا است. منبع رودخانه قرنقو از کوه‌های سهند سرچشمه گرفته است. مسیر جریان رودخانه از غرب به شرق با عبور از شهرستان‌های هشترود و چارویماق بوده است. این رودخانه یکی از مهم‌ترین و پرآب‌ترین شاخه‌های رود قزل‌اوزن است. زیست‌بوم این محدوده دارای گونه‌هایی مانند ماهی قزل‌آلا و ماهی سفید است. مشخصات این سد در جدول ۱ و موقعیت حوضه آبریز در شکل ۱ آورده شده است.

کاربری اصلی سد قرنقو آبیاری زمین‌های کشاورزی شهرستان میانه و هشترود است. شوری آب رودخانه قرنقو در پایاب سد قرنقو باعث آسیب به زمین‌های کشاورزی شده است.

در این پژوهش، ابتدا داده‌های اقلیمی شامل میانگین‌های ماهانه دما و بارش از ایستگاه تونل‌هفت برای دو بازه زمانی مجزا، یعنی سال‌های ۱۹۷۱ تا ۲۰۰۰ به‌عنوان دوره مرجع (به‌روزی و همکاران (Behroozi et al., 2023)) و سال‌های ۲۰۷۰ تا ۲۰۹۹ به‌عنوان دوره آینده، گردآوری شد. به‌منظور ارزیابی عملکرد مدل‌های اقلیمی در بازسازی و پیش‌بینی رفتار جوی منطقه، مجموعه‌ای از ۲۲ مدل جهانی ارائه‌شده در گزارش پنجم هیئت بین‌دولتی تغییر اقلیم (IPCC) تحت سناریوی انتشار گازهای گلخانه‌ای RCP 2.6 مورد تحلیل قرار گرفت. داده‌های مورد نیاز از پایگاه رسمی IPCC استخراج شده و با بهره‌گیری از مختصات جغرافیایی ایستگاه تونل‌هفت، اطلاعات اقلیمی منطقه قرنقو در محیط نرم‌افزار ArcGIS پردازش و استخراج گردید.

از منظر توسعه منابع آب، احداث سد مخزنی در منطقه قرنقو با هدف مدیریت جریان‌های سطحی و تأمین پایدار آب برای اراضی زراعی برنامه‌ریزی شده است. این طرح با ایجاد شبکه‌های آبیاری منسجم، بخش قابل توجهی از زمین‌های کشاورزی را تحت پوشش قرار می‌دهد و زمینه‌ساز افزایش بهره‌وری در تولید

راه‌کارها را برای تخصیص، بهره‌برداری و حفاظت از منابع آب ارائه دهند. به‌ویژه در شرایطی که منابع آب با فشارهای ناشی از تغییرات اقلیمی، رشد جمعیت و توسعه صنعتی مواجه‌اند، استفاده از این الگوریتم‌ها به تصمیم‌گیرندگان کمک می‌کند تا با دقت و سرعت بیش‌تری به راه‌حل‌های پایدار دست یابند. ضرورت استفاده از این روش‌ها زمانی بیش‌تر آشکار می‌شود که بدانیم مدیریت سنتی منابع آب اغلب مبتنی بر روش‌های تجربی و خطی بوده و توانایی پاسخ‌گویی به مسائل پیچیده و چندبعدی امروز را ندارد. در مقابل، الگوریتم‌های بهینه‌سازی با قابلیت مدل‌سازی غیرخطی، جست‌وجوی فضای پاسخ وسیع، و تطبیق‌پذیری با شرایط متغیر، ابزارهایی قدرتمند برای ارتقای بهره‌وری و پایداری در مدیریت منابع آب محسوب می‌شوند.

با توجه به مرور مطالعات پیشین، می‌توان نتیجه گرفت که ترکیب مدل‌های هوش مصنوعی با الگوریتم‌های بهینه‌سازی در مدیریت منابع آب هنوز به‌طور کامل بررسی نشده است. پژوهش حاضر تلاش دارد با استفاده از LSTM و HHOA چارچوبی نوین برای تخصیص بهینه آب سد قرنقو تحت شرایط تغییر اقلیم ارائه دهد. در این پژوهش، تمرکز بر استفاده از الگوریتم بهینه‌سازی گله اسب<sup>۱</sup> (HHOA) برای بهینه‌سازی بهره‌برداری از مخزن قرنقو در ایران است. این الگوریتم برای نخستین‌بار در زمینه مدیریت منابع آب این منطقه به‌کار گرفته می‌شود و هدف آن کاهش کمبود آب در بخش کشاورزی تحت شرایط متغیر اقلیمی است. با توجه به نقش حیاتی این مخزن در تأمین آب اراضی پایین‌دست، بهینه‌سازی عملکرد آن می‌تواند تأثیر قابل‌توجهی بر پایداری اقتصادی و زیست‌محیطی منطقه داشته باشد. ارزیابی اثربخشی الگوریتم پیشنهادی از طریق شاخص تاب‌آوری مخزن صورت خواهد گرفت.

## مواد و روش‌ها

### منطقه مورد مطالعه

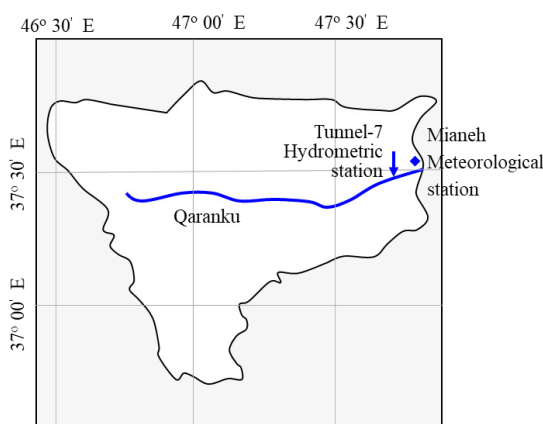
موقعیت جغرافیایی حوضه آبریز قرنقو در دامنه‌های شرقی کوهستان سهند در استان آذربایجان شرقی

1. Horse Herd Optimization Algorithm

جدول ۱. مشخصات سد قرنکو

Table 1. Specifications of the Qaranku Dam

| ویژگی<br>Feature   | مقدار<br>Value  |
|--|---|
| محل<br>Location  | ۲۶ کیلومتری جنوب شرقی هاشترود<br>26 km southeast of Hashtroud   |
| نوع سد<br>Type of dam                                    | سد خاکی با هسته رسی<br>Earthfill dam with clay core   |
| ارتفاع از پی<br>Height from foundation                   | ۵۹ متر<br>59 meter  |
| طول سرریز<br>Crest Length                                | ۴۵۰ متر<br>450 meter  |
| ظرفیت نرمال مخزن<br>Normal reservoir capacity            | ۱۶۵ میلیون متر مکعب<br>165 million cubic meters   |
| ظرفیت مفید مخزن<br>Useful reservoir capacity             | ۱۳۵ میلیون متر مکعب<br>135 million cubic meters   |
| حجم سالانه آب تنظیم‌شده<br>Regulated annual water volume | ۱۱۷ میلیون متر مکعب<br>117 million cubic meters   |
| هدف<br>Purpose   | تامین آب کشاورزی و شرب برای منطقه هاشترود<br>Supplying agricultural and drinking water for the Hashtroud region |



شکل ۱. حوضه آبریز منطقه مورد مطالعاتی

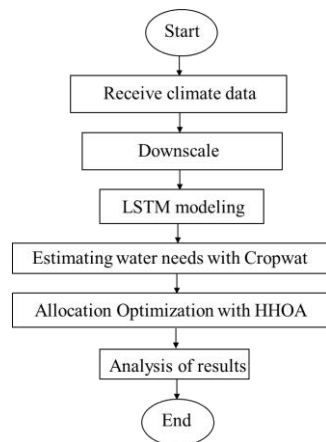
Fig 1. Basin of the studied area

ورودی به مخزن، از مدل LSTM استفاده شده و به‌منظور برآورد نیاز آبی بخش کشاورزی در پایین‌دست مخزن، مدل Cropwat به‌کار گرفته شده است. در ادامه، الگوریتم بهینه‌سازی HHOA معرفی شده و عملکرد آن در حل توابع هدف ریاضی با الگوریتم برنامه‌ریزی ژنتیک<sup>۱</sup> (GP) مقایسه گردیده و برای مسئله تخصیص بهینه منابع آب به‌کار گرفته شد. در پایان نیز شاخص تاب‌آوری در تأمین آب مخزن برای منطقه مطالعاتی

1. Genetic Programming

محصولات کشاورزی خواهد بود. ترکیب محصولات زراعی شامل گندم، جو، یونجه، سویا، ذرت علوفه‌ای، ذرت دانه‌ای، سیب‌زمینی و گردو بوده و میزان سطح زیرکشت هریک در محدوده مطالعاتی به‌ترتیب برابر با ۱۲، ۸، ۱۲، ۸، ۵، ۸، ۱۲ و ۳۵ درصد می‌باشد. در این بخش، روند اجرای تحقیق به‌صورت مرحله‌به‌مرحله تشریح می‌شود. ابتدا از داده‌های پیش‌بینی اقلیمی ارائه‌شده در گزارش پنجم IPCC بهره‌برداری شده است. سپس برای شبیه‌سازی جریان

در دو بازه زمانی-دوره پایه و دوره متأثر از تغییر اقلیم- نمایش داده شده است. محاسبه شده‌اند. نمای کلی مراحل تحقیق در شکل ۲



شکل ۲. روندنمای تحقیق

Fig 2. Flowchart of the research

مؤثر بر تغییرات اقلیم نظیر رشد جمعیت، توسعه فناوری و میزان انتشار آلاینده‌ها، چشم‌اندازهای مختلفی از آینده اقلیم جهانی را ترسیم می‌کنند. سناریوهای RCP شامل چهار مسیر اصلی با سطوح متفاوتی از واداشت تابشی هستند که از سناریوی خوش‌بینانه RCP 2.6 تا سناریوی به‌شدت آلوده RCP 8.5 را در بر می‌گیرند.

در مرحله دوم، برای شبیه‌سازی رفتار اقلیم جهانی، از مدل‌های گردش عمومی جو و اقیانوس<sup>۳</sup> (AOGCM) بهره گرفته می‌شود. این مدل‌ها با حل معادلات فیزیکی و دینامیکی در مقیاس‌های بزرگ، توانایی پیش‌بینی تغییرات بلندمدت اقلیمی را دارند. در چارچوب پروژه بین‌المللی CMIP5، مجموعه‌ای از این مدل‌ها تحت سناریوهای مختلف اقلیمی اجرا شده‌اند تا نتایج قابل‌اعتماد برای مطالعات منطقه‌ای فراهم گردد (IPCC, 2014). مدل‌های اقلیمی مورد استفاده در این طرح توسط مراکز تحقیقاتی معتبر از کشورهای مختلف توسعه یافته‌اند و تنوع ساختاری آن‌ها امکان بررسی عدم قطعیت در خروجی‌ها را فراهم می‌سازد. مرحله سوم به ریزمقیاس‌نمایی نتایج مدل‌های اقلیمی اختصاص دارد. از آنجا که خروجی مدل‌های GCM در مقیاس‌های بزرگ ارائه می‌شوند، برای کاربرد در مطالعات محلی باید به مقیاس حوضه آبریز

## تغییر اقلیم و سناریوها

تغییر اقلیم، یعنی هرگونه تغییر واضح و مشخص در الگوهای مورد انتظار برای وضعیت آب و هوایی که در طولانی‌مدت برای یک اقلیم رخ خواهد داد. برای بررسی اثر تغییر اقلیم در تحقیق حاضر، از خروجی مدل‌های GFDL-ESM2G و NorESM1-M تحت سناریوی RCP 2.6 در بازه ۲۰۷۰-۲۰۹۹ استفاده خواهد شد. انتخاب سناریوی RCP 2.6، به این دلیل انجام شد که این سناریو، شرایط خوش‌بینانه کاهش انتشار گازهای گلخانه‌ای را نشان می‌دهد و در مطالعات مشابه در ایران نیز به‌عنوان سناریوی مرجع استفاده شده است.

## فرآیند پیش‌بینی اقلیم در مقیاس حوضه آبریز

پیش‌بینی وضعیت اقلیمی آینده در مطالعات منابع آب نیازمند طی سه مرحله کلیدی است که به‌صورت پیوسته اجرا می‌شوند. نخستین گام، انتخاب سناریوی اقلیمی مناسب است که برپایه مسیره‌های غلظت گازهای گلخانه‌ای<sup>۱</sup> (RCPs) تعریف شده و در گزارش پنجم هیئت بین‌دولتی تغییر اقلیم<sup>۲</sup> (IPCC) ارائه گردیده است. این سناریوها با در نظر گرفتن عوامل

1. Representative Concentration Pathways  
2. Intergovernmental Panel on Climate Change

3. Atmosphere-Ocean General Circulation Model

$$P_{future} = P_{baseline} \times \left( \frac{\bar{P}_{GCM\_future}}{\bar{P}_{GCM\_baseline}} \right) \quad (1)$$

$$P_{future} = P_{baseline} \times \left( \frac{\bar{P}_{GCM\_future}}{\bar{P}_{GCM\_baseline}} \right) \quad (2)$$

این داده‌ها به‌عنوان ورودی در مراحل بعدی مدل‌سازی منابع آب مورد استفاده قرار می‌گیرند. مدل‌های اقلیمی به‌کاررفته در چارچوب CMIP5 در جدول ۲ آورده شده است.

تبدیل شوند. در این تحقیق، روش ریزمقیاس‌نمایی تناسبی به‌کار گرفته شده است. در این روش، ابتدا میانگین بلندمدت متغیرهای اقلیمی (دما و بارندگی) در دوره پایه و دوره آینده محاسبه می‌شود. سپس با استفاده از ضرایب تغییر اقلیم، سری زمانی جدیدی از داده‌های اقلیمی تولید می‌گردد که شرایط آینده را در مقیاس محلی بازتاب می‌دهد. روابط (۱) و (۲) مبنای محاسبات قرار گرفتند:

### جدول ۲. مروری بر مدل‌های اقلیمی منتخب در چارچوب پروژه

**Table 2. Overview of the selected climate models within the project framework**

| شماره<br>ID | نام مدل اقلیمی<br>Climate model name | کشور<br>Country                                 |
|-------------|--------------------------------------|---|
| A01         | Inmcm4                               | Russia<br>روسیه                                 |
| A02         | CCSM4                                | United States of America<br>ایالات متحده آمریکا |
| A03         | CESM1-BGC                            | United States of America<br>ایالات متحده آمریکا |
| A04         | CESM1(CAM5)                          | United States of America<br>ایالات متحده آمریکا |
| A05         | CESM1-FASTCHEM                       | United States of America<br>ایالات متحده آمریکا |
| A06         | GFDL-ESM2G                           | United States of America<br>ایالات متحده آمریکا |
| A07         | GISS-E2-H                            | United States of America<br>ایالات متحده آمریکا |
| A08         | CSIRO-Mk3-6-0                        | Australia<br>استرالیا                           |
| A09         | ACCESS1-0                            | Australia<br>استرالیا                           |
| A10         | ACCESS1-3                            | Australia<br>استرالیا                           |
| A11         | CanESM2                              | Canada<br>کانادا                                |
| A12         | BNU-ESM                              | China<br>چین                                    |
| A13         | FIO-ESM                              | China<br>چین                                    |
| A14         | BCC-csm1-1                           | China<br>چین                                    |
| A15         | MPI-ESM-LR                           | Germany<br>آلمان                                |
| A16         | MPI-ESM-MR                           | Germany<br>آلمان                                |
| A17         | MPI-ESM-P                            | Germany<br>آلمان                                |
| A18         | NorESM1-M                            | Norway<br>نروژ                                  |
| A19         | NorESM1-ME                           | Norway<br>نروژ                                  |
| A20         | IPSL-CM5A-MR                         | France<br>فرانسه                                |
| A21         | CNRM-CM5                             | France<br>فرانسه                                |

دقیق انتخاب شد. تابع محرک ReLU در لایه‌های مخفی و تابع خطی در لایه خروجی استفاده شد. مدل در محیط برنامه‌نویسی Python و با استفاده از کتابخانه‌های تخصصی مانند TensorFlow یا Keras توسعه داده می‌شود. در مرحله آموزش، پارامترهایی نظیر تعداد لایه‌ها، تعداد واحدهای حافظه، نرخ یادگیری و تعداد دوره‌های آموزشی (epochs) به صورت تجربی تنظیم می‌شوند تا خطای پیش‌بینی کمینه شود.

پس از آموزش مدل، عملکرد آن با استفاده از شاخص‌های آماری مانند ضریب نش-ساتکلیف<sup>۳</sup> (NSE)، میانگین خطای مطلق<sup>۴</sup> (MAE)، ریشه میانگین مربعات خطا<sup>۵</sup> (RMSE)، ضریب همبستگی<sup>۶</sup> (r) و کارایی کلینگ-گوپتا<sup>۷</sup> (KGE) مطابق با روابط (۳) تا (۶) ارزیابی می‌شود. به نظر می‌رسد استفاده از شاخص کارایی کلینگ-گوپتا<sup>۸</sup> (KGE) مطابق با رابطه (۷) بتواند به ارزیابی جامع‌تر و دقیق‌تر منجر شود (Zhou et al., 2024). در نهایت، مدل آموزش‌دیده برای پیش‌بینی جریان ورودی در سال‌های آینده به کار گرفته می‌شود و نتایج آن در تحلیل‌های بعدی مورد استفاده قرار می‌گیرد.

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (4)$$

$$RMSE = \sqrt{\left[ \sum (P_i - O_i)^2 / n \right]} \quad (5)$$

$$r = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \cdot \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \quad (6)$$

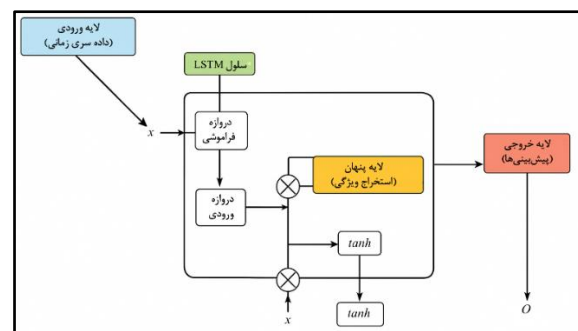
$$KGE = 1 - \sqrt{(r - 1)^2 + \left(\frac{\sigma_P}{\sigma_O} - 1\right)^2 + \left(\frac{\bar{P}}{\bar{O}} - 1\right)^2} \quad (7)$$

که در آن،  $P_i$  = مقدار پیش‌بینی‌شده برای نمونه  $i$  در مجموعه داده،  $\bar{P}$  = میانگین مقادیر پیش‌بینی‌شده برای

3. Nash-Sutcliffe Efficiency
4. Mean Absolute Error
5. Root Mean Square Error
6. Coefficient of Correlation
7. Kling-Gupta Efficiency
8. Kling-Gupta Efficiency

## مدل‌سازی جریان ورودی به مخزن با استفاده از یادگیری عمیق<sup>۱</sup> (DL)

در راستای پیش‌بینی دقیق دبی جریان در سال‌های آتی، از روش‌های DL بهره گرفته می‌شود که توانایی بالایی در استخراج الگوهای پنهان از داده‌های سری‌زمانی دارند. یکی از مناسب‌ترین ساختارهای شبکه عصبی برای این نوع داده‌ها، شبکه‌های حافظه‌دار بلندمدت<sup>۲</sup> (LSTM) هستند که با حفظ وابستگی‌های زمانی در داده‌ها، عملکردی قابل‌اتکا در مدل‌سازی فرآیندهای آب‌شناسی ارائه می‌دهند. شبکه LSTM از واحدهای بازگشتی تشکیل شده که قادرند اطلاعات مربوط به زمان‌های گذشته را در حافظه نگه‌دارند و در تصمیم‌گیری‌های آینده لحاظ کنند. این ویژگی باعث می‌شود مدل بتواند تأثیرات تأخیری بارش و دما را بر جریان ورودی به مخزن به‌درستی شناسایی کند. ساختار این شبکه مطابق با شکل ۳ شامل لایه‌های ورودی، سلول‌های حافظه، دروازه‌های کنترل و لایه خروجی است که به صورت سلسله‌مراتبی سازمان‌دهی شده‌اند.



شکل ۳. ساختار LSTM

Fig 3. LSTM structure

برای پیاده‌سازی مدل، داده‌های ماهانه دما و بارش مربوط به دوره پایه به‌عنوان ورودی به شبکه داده می‌شوند. این داده‌ها پس از نرمال‌سازی  $X_{norm} = (X - X_{min}) / (X_{max} - X_{min})$ ، به دو بخش آموزش (۷۵ درصد) و آزمون (۲۵ درصد) تقسیم می‌گردند. این نسبت براساس مطالعات مشابه (Pedregosa et al., 2021) و به‌منظور تعادل میان آموزش کافی و ارزیابی

1. Deep Learning
2. Long-Short Term Memory

هیدرولوژیکی و برنامه‌ریزی آبیاری محسوب می‌شود. این نرم‌افزار بر پایه معادله پنمن-مانتیث فائو، میزان تبخیر-تعرق مرجع را در مقیاس ماهانه محاسبه کرده و نتایج آن را برای تعیین نیاز آبی گیاهان (با لحاظ کردن ضریب گیاهی) و زمان‌بندی آبیاری به کار می‌گیرد.

برای برآورد ضریب گیاهی، اطلاع از طول و ویژگی‌های چهار مرحله اصلی رشد (آغاز رشد، توسعه رویشی، مرحله میانی و پایانی) ضروری است. همچنین داده‌هایی همچون تبخیر-تعرق پتانسیل، میانگین رطوبت نسبی و سرعت باد در مقیاس ماهانه از ورودی‌های اصلی مدل به‌شمار می‌روند. مراحل محاسبه نیاز آبی در جدول ۳ نشان داده شده است.

کل نمونه‌ها در مجموعه داده،  $\sigma_P$  = انحراف معیار مقادیر پیش‌بینی‌شده برای کل نمونه‌ها در مجموعه داده،  $O_i$  = مقدار مشاهده‌شده برای نمونه  $i$  در مجموعه داده،  $\bar{O}$  = میانگین مقادیر مشاهده‌شده برای کل نمونه‌ها در مجموعه داده،  $\sigma_O$  = انحراف معیار مقادیر مشاهده‌شده برای کل نمونه‌ها در مجموعه داده، و  $n$  = کل نمونه‌ها، هستند.

### برآورد نیاز آبیاری پایین‌دست مخزن با استفاده از مدل Cropwat

نرم‌افزار Cropwat که توسط سازمان خواربار و کشاورزی ملل متحد (FAO) توسعه یافته است (Doorenbos & Pruitt, 1984)، ابزاری کارآمد برای محاسبات

جدول ۳- روند محاسبه تقاضای آب آبیاری با مدل Cropwat

Table 3. Process of calculating irrigation water demand with the Cropwat model

| گام محاسباتی<br>Computational step | توصیف پارامتر<br>Parameter description   | رابطه محاسباتی<br>Computational relationship   |
|------------------------------------|--|--|
| گام ۱<br>Step 1                    | تبخیر-تعرق مرجع<br>برآوردشده<br>Reference estimated evapotranspiration<br>( $ETo$ )            | $(EVT_0)_t = \frac{(0.408 \times \Delta \times ((R_n)_t - G)) + \gamma \frac{900}{(TEM_t + 273)} \times u_2 (e_s - e_d)}{\Delta + \gamma \times (1 + 0.34u_2)}$        |
| گام ۲<br>Step 2                    | تبخیر-تعرق واقعی<br>محاسبه‌شده محصول<br>Calculated actual crop evapotranspiration<br>( $ETc$ ) | $(EVT_c)_{t,j} = (K_c)_{t,j} \times (EVT_0)_t$   |
| گام ۳<br>Step 3                    | باران مؤثر تعیین‌شده<br>Determined effective rainfall<br>( $RAI_{EFF}$ )                       | $(RAI_{EFF})_t = \begin{cases} \frac{(RAI)_t \times (125 - 0.2(RAI)_t)}{125} & (RAI)_t \leq 250 \text{ mm} \\ 0.2(RAI)_t + 125 & (RAI)_t > 250 \text{ mm} \end{cases}$ |
| گام ۴<br>Step 4                    | نیاز خالص آبی گیاه<br>Net crop water requirement<br>( $NetWR$ )                                | $(NetWR)_{t,j} = (EVT_c)_{t,j} - (RAI_{EFF})_t$  |
| گام ۵<br>Step 5                    | حجم آب مورد نیاز<br>پایین‌دست سد<br>Volume water demand downstream of the dam (VDEM)           | $(VDEM)_{t,j} = (NetWR)_{t,j} \times (AREA)_{t,j} \times 10^{-5}$  |

روزانه دمای هوا ( $^{\circ}C$ )،  $u_2$  = میانگین روزانه سرعت باد در ارتفاع دو متری ( $m/sec$ )،  $e_s$  = فشار بخار اشباع ( $KPa$ )،  $e_d$  = فشار بخار واقعی ( $KPa$ )،  $e_s - e_d$  = کمبود

در روابط فوق،  $(EVT_0)_t$  = تبخیر-تعرق مرجع ( $mm/day$ )،  $R_n$  = تابش خالص ورودی به سطح گیاه ( $MJ/m^2.day$ )،  $G$  = شار گرمای خاک ( $MJ/m^2.day$ )،  $TEM$  = میانگین

متفاوتی دارند. برای تعیین بردار سرعت، شش رفتار زیستی و اجتماعی اسبها به عنوان الگو در نظر گرفته شده است: چریدن، رعایت سلسله مراتب، اجتماعی بودن، تقلید، دفاع از خود، و پرسه زنی. روابط (۹) این موضوع را نشان می دهد:

$$\begin{aligned} \vec{V}_m^{Iter,\alpha} &= \vec{G}_m^{Iter,\alpha} + \vec{D}_m^{Iter,\alpha} \\ \vec{V}_m^{Iter,\beta} &= \vec{G}_m^{Iter,\beta} + \vec{H}_m^{Iter,\beta} + \vec{S}_m^{Iter,\beta} + \vec{D}_m^{Iter,\beta} \\ \vec{V}_m^{Iter,\gamma} &= \vec{G}_m^{Iter,\gamma} + \vec{H}_m^{Iter,\gamma} + \vec{S}_m^{Iter,\gamma} + \vec{I}_m^{Iter,\gamma} + \vec{D}_m^{Iter,\gamma} + \vec{R}_m^{Iter,\gamma} \\ \vec{V}_m^{Iter,\delta} &= \vec{G}_m^{Iter,\delta} + \vec{I}_m^{Iter,\delta} + \vec{R}_m^{Iter,\delta} \end{aligned} \quad (9)$$

که در آن،  $G =$  چریدن،  $H =$  رعایت سلسله مراتب،  $S =$  اجتماعی بودن،  $I =$  تقلید،  $D =$  سازوکار دفاعی،  $R =$  پرسه زنی اسب، هستند.

ترکیب این شش رفتار باعث می شود HHOA تعادلی مناسب بین اکتشاف و استخراج برقرار کند. در نتیجه این الگوریتم توانایی بالایی در حل مسائل بهینه سازی با ابعاد زیاد و پیچیدگی بالا از خود نشان می دهد. شکل ۴ روندنمای HHOA را نشان می دهد.

از آنجا که HHOA تاکنون در زمینه تخصیص منابع آب به کار نرفته است، در این پژوهش ابتدا کارایی آن در مسائل تک هدفه با الگوریتم های شناخته شده ای هم چون GP مقایسه می شود و سپس قابلیت آن در مسأله تخصیص منابع آب مورد بررسی قرار خواهد گرفت. در نهایت، برای هر الگوریتم بهینه سازی نرخ پارامترهای مورد استفاده در پژوهش در جدول ۴ آورده شده است.

#### توابع معیار تک هدفه

در فرآیند ارزیابی عملکرد الگوریتم های فراابتکاری، استفاده از توابع معیار استاندارد نقش مهمی در سنجش دقت و توانایی الگوریتم ها دارد. این توابع با ویژگی های ریاضی خاص خود، امکان بررسی رفتار الگوریتم در مواجهه با سطوح مختلف پیچیدگی را فراهم می سازند. در این پژوهش، سه تابع شناخته شده راستریجین و روزنبروک به عنوان معیارهای سنجش انتخاب شده اند تا عملکرد مدل HHOA در مقایسه با GP مورد بررسی قرار گیرد.

برای ایجاد شرایط آزمایشگاهی منصفانه، پارامترهای اجرایی برای هر دو الگوریتم به صورت یکسان تنظیم

فشار بخار اشباع (KPa)،  $\Delta =$  شیب منحنی فشار بخار اشباع (KPa/°C)،  $=$  ضریب ثابت سایکرومتری (KPa/°C)،  $(EVT_C)_{t,j} =$  تبخیر و تعرق گیاه زام در ماه  $t$ ام،  $(K_C)_{t,j} =$  ضریب گیاهی برای گیاه زام در ماه  $t$ ام،  $(EVT_0)_t =$  تبخیر و تعرق گیاه مرجع یا تبخیر و تعرق پتانسیل در ماه  $t$ ام،  $(RAI_{EFF})_t =$  میانگین بارندگی مؤثر در ماه  $t$ ام (میلی متر)،  $(RAI)_t =$  میانگین بارندگی در ماه  $t$ ام (میلی متر)،  $(NetWR)_{t,j} =$  نیاز خالص آبی برای گیاه زام در ماه  $t$ ام (میلی متر)،  $(NetWR)_{t,j} =$  حجم تقاضای آب برای گیاه زام در ماه  $t$ ام (میلیون متر مکعب)، و  $(AREA)_{t,j} =$  سطح زیر کشت برای گیاه زام (هکتار)، هستند.

#### الگوریتم بهینه سازی گله اسب (HHOA)

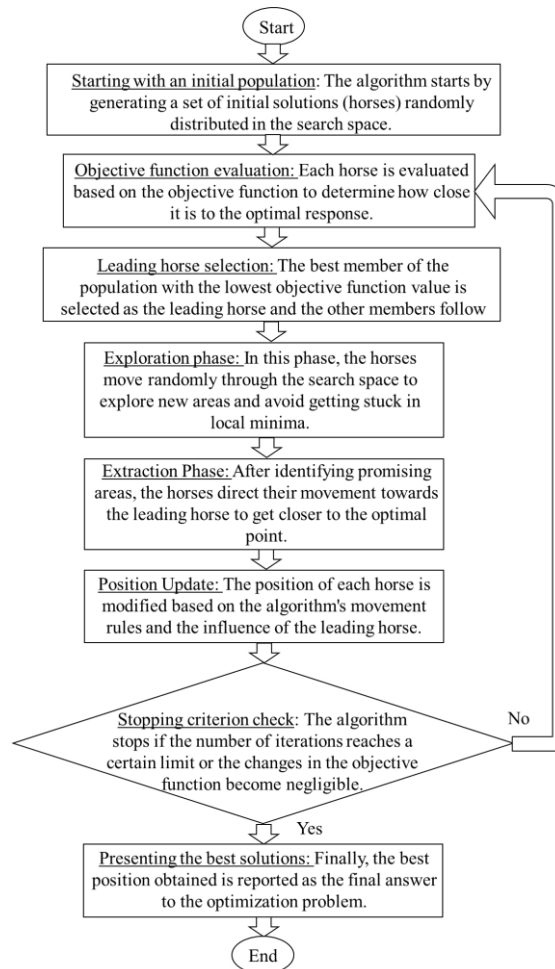
HHOA که نخستین بار توسط میانرئیمی و همکاران (MiarNaeimi et al., 2021) معرفی شد، یکی از رویکردهای فراابتکاری نوین در حوزه بهینه سازی است. الگوریتم های فراابتکاری به طور معمول با الهام از پدیده ها و رفتارهای طبیعی طراحی می شوند و به همین دلیل توانایی بالایی در جستجوی هوشمندانه فضاهای پیچیده و پرابعد دارند. دو ویژگی اساسی این نوع الگوریتم ها یعنی اکتشاف (جستجوی کلی در فضای مسأله) و استخراج (تمرکز روی نواحی امیدبخش) امکان فرار از بهینه های محلی و حرکت به سوی بهینه سراسری را فراهم می کند.

در این الگوریتم از رفتار اجتماعی اسبها در مراحل مختلف زندگی الهام گرفته شده است. چرخه حرکتی هر اسب در تکرارهای الگوریتم، براساس رابطه (۸) تعریف می شود:

$$X_m^{Iter,AGE} = \vec{V}_m^{Iter,AGE} + X_m^{(Iter-1),AGE}, \quad AGE = \alpha, \beta, \gamma, \delta \quad (8)$$

که در آن،  $X_m^{Iter,AGE} =$  موقعیت اسب  $m$  ام در محدوده سنی  $AGE = Iter$ ، شماره حلقه تکرار،  $\vec{V}_m^{Iter,AGE} =$  بردار سرعت و جابجایی اسب نسبت به چرخه قبل، هستند.

چهار گروه سنی تعریف شده اند:  $\delta =$  اسبهای ۰ تا ۵ سال،  $\gamma = 5$  تا ۱۰ سال،  $\beta = 10$  تا ۱۵ سال و  $\alpha =$  بیش از ۱۵ سال. اسبها در هر گروه سنی الگوهای حرکتی



شکل ۴. روندنمای مدل HHOA در حل مسأله

Fig 4. Flowchart of the HHOA model in problem solving

جدول ۴. پارامترهای مورد استفاده در هر الگوریتم

Table 4. Used parameters in each algorithm

| الگوریتم<br>Algorithm               | مسئله<br>Problem               | جمعیت<br>Population<br>size | تعداد تکرارها<br>Number of<br>iterations | نرخ جهش<br>Mutation<br>rate | نرخ یادگیری<br>Learning<br>rate | معیار توقف<br>Stopping<br>criterion   |
|-------------------------------------|--------------------------------|-----------------------------|--|-----------------------------|---------------------------------|---------------------------------------|
| الگوریتم بهینه‌سازی گله اسب<br>HHOA | ریاضی<br>Math                  | 100                         | 100                                      | -                           | 0.01                            | تعداد تکرار<br>Number of<br>iteration |
| برنامه‌ریزی ژنتیک<br>GP             |                                | 100                         | 100                                      | 0.1                         | -                               | تعداد تکرار<br>Number of<br>iteration |
| الگوریتم بهینه‌سازی گله اسب<br>HHOA | منابع آب<br>Water<br>resources | 500                         | 500                                      | 0.1                         | 0.01                            | تعداد تکرار<br>Number of<br>iteration |

ثبت گردیده است. تابع راسترین، تابعی غیرمحدب با تعداد زیادی کمینه محلی است. ساختار آن ترکیبی از تابع درجه دوم و تابع کسینوسی است. فضای جستجوی آن بسیار نوسانی است، به طوری که الگوریتم‌ها به راحتی در

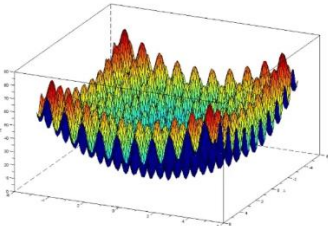
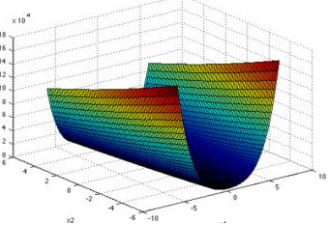
شده‌اند؛ به طوری که جمعیت اولیه برابر با ۱۰۰ و تعداد تکرارها معادل ۱۰۰ در نظر گرفته شده است. هم‌چنین، به منظور کاهش اثرات تصادفی و افزایش اعتبار نتایج، هر الگوریتم به صورت مستقل ۱۰ بار اجرا شده و میانگین خروجی‌ها به عنوان پاسخ نهایی

دارند. این تابع مناسب برای بررسی پایداری الگوریتم و توانایی آن در دنبال کردن مسیرهای پیچیده است. مشخصات ریاضی و مقادیر بهینه این توابع در جدول ۵ ارائه شده‌اند تا مبنای مقایسه عملکرد الگوریتم‌ها فراهم گردد.

کمینه‌های محلی گیر می‌افتند. این تابع مناسب برای ارزیابی توانایی الگوریتم در اکتشاف و عبور از موانع پیچیده است. تابع روزنبروک، تابعی غیرمحدب با یک دره باریک و خمیده بوده که به نقطه بهینه منتهی می‌شود. به دلیل شکل خاص دره، الگوریتم‌ها برای همگرایی به نقطه بهینه نیاز به دقت بالا

جدول ۵. مشخصات ریاضی و مقادیر بهینه توابع معیار مورد استفاده در ارزیابی مدل HHOA تک‌هدفه

Table 5. Mathematical specifications and optimal values of criterion functions used in evaluating the single-objective HHOA model

| نام تابع<br>Function name | شکل تابع<br>Function form  | معادله<br>Equation  | مقدار بهینه<br>Optimal value |
|---------------------------|--|---|------------------------------|
| راستریگن<br>Rastrigen     |   | $f = 10n + \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i)), n = 9$<br>$-5.12 \leq x_i \leq 5.12$ | $f(0, 0, \dots, 0) = 0$      |
| روزنبروک<br>Rosenbrook    |  | $f(x, y) = (a - x)^2 + b(y - x^2)^2$  | $f(x, y) = 0$                |

بهینه‌سازی، به تعیین مقادیر مناسب برای متغیرهای تصمیم با رعایت محدودیت‌های حاکم بر سامانه منجر می‌شود، به گونه‌ای که تابع هدف بهینه گردد. در این پژوهش، تابع هدف به صورت کمینه‌سازی مجدد میانگین کمبودهای نسبی در تأمین نیازهای ذی‌نفعان مختلف (از جمله کشاورزی، صنعت، شرب و محیط زیست) در طول دوره بهره‌برداری تعریف شده است. روابط ریاضی مربوط به تابع هدف و قیود مسئله به شرح روابط (۱۰) تا (۱۴) هستند:

$$\text{Min: } OF = \frac{1}{N} \sum_{t=1}^N \left( \frac{DE_t - RE_t}{DE_{max}} \right)^2 \quad \forall t = 1, 2, \dots, N \quad (10)$$

$$ST_{t+1} = ST_t + IN_t - RE_t - SP_t - ((EV_t * AR_t)/1000) \quad (11)$$

$$\forall t = 1, 2, \dots, N$$

پس از تحلیل نتایج حاصل از اجرای مدل‌های HHOA و GP بر روی دو تابع معیار (راستریگن و روزنبروک) در چارچوب بهینه‌سازی تک‌هدفه، از این الگوریتم‌ها برای حل مسأله تخصیص منابع آب بهره‌برداری خواهد شد.

شایان ذکر است که عملکرد الگوریتم‌ها در توابع معیار فقط بیان‌گر توانایی آنها در حل مسائل استاندارد است و نتایج آن به صورت مشابه در مطالعه موردی تکرار نمی‌شود. این تحلیل به‌عنوان مبنای مقایسه اولیه در نظر گرفته شد.

#### مسأله تخصیص بهینه منابع آب

در مسأله تخصیص بهینه منابع آب با رویکرد تک‌هدفه، هدف دستیابی به یک معیار مشخص است که می‌توان آن را در قالب یک مدل ریاضی تعریف نمود. حل این مدل با بهره‌گیری از روش‌های

تاکنون در حوزه‌های مختلفی مانند بهینه‌سازی، داده‌کاوی، مدل‌سازی سامانه‌های غیرخطی، و کنترل هوشمند مورد استفاده قرار گرفته است.

GP از اصول زیست‌شناسی تکاملی الهام گرفته و با استفاده از مفاهیمی مانند انتخاب طبیعی، جهش<sup>۱</sup>، ترکیب ژنتیکی<sup>۲</sup> و بقای اصلح، به جستجوی ساختارهای برنامه‌ای بهینه می‌پردازد.

در GP، هر فرد در جمعیت اولیه به جای یک رشته دودویی (مانند GA)، یک درخت برنامه‌ای است که گره‌های آن شامل توابع و عملگرها (مانند جمع، ضرب، شرطی‌ها) و برگ‌های آن شامل متغیرها یا مقادیر عددی هستند. مراحل اصلی GP به شرح زیر هستند: (۱) تولید جمعیت اولیه

- مجموعه‌ای از درخت‌های تصادفی تولید می‌شود که هر کدام نمایان‌گر یک برنامه یا مدل هستند.

(۲) ارزیابی برازندگی<sup>۳</sup>

- هر برنامه با توجه به میزان تطابق خروجی‌اش با داده‌های واقعی یا هدف مسأله، ارزیابی می‌شود. تابع شایستگی به‌طور معمول براساس خطای مدل یا میزان موفقیت در انجام وظیفه تعریف می‌شود.

(۳) اعمال عملگرهای ژنتیکی

- ترکیب: دو درخت انتخاب‌شده با یکدیگر ترکیب می‌شوند تا فرزندان جدیدی تولید کنند.
- جهش: بخشی از یک درخت به صورت تصادفی تغییر می‌کند تا تنوع حفظ شود.
- تکثیر: افراد برتر به‌طور مستقیم به نسل بعد منتقل می‌شوند.

(۴) تکرار فرآیند تکامل

- این مراحل تا رسیدن به معیار توقف (مانند تعداد نسل‌ها یا رسیدن به خطای مطلوب) ادامه می‌یابد.

مزایای GP شامل (۱) مدل‌سازی سامانه‌های پیچیده و غیرخطی بدون نیاز به فرم تحلیلی دقیق، (۲) استخراج روابط ریاضی یا قوانین تصمیم‌گیری از داده‌های

$$ST_{min} \leq ST_t \leq ST_{max} \quad \forall t = 1, 2, \dots, N \quad (12)$$

$$0 \leq RE_t \leq DE_t \quad \forall t = 1, 2, \dots, N \quad (13)$$

$$SP_t = \begin{cases} ST_t + IN_t - (EV_t \times AR_t / 1000) - ST_{max} \\ 0 \end{cases} \quad (14)$$

$$\text{if } ST_t + IN_t - (EV_t \times AR_t / 1000) \geq ST_{max} \\ \text{otherwise}$$

$$\forall t = 1, 2, \dots, N$$

که در آن،  $OF$  = تابع هدف؛  $DE_t$  = تقاضای آب در هر دوره  $t$ ؛  $RE_t$  = مقدار آب رهاسازی شده در هر دوره  $t$ ؛  $ST_t$  و  $ST_{t+1}$  = حجم ذخیره مخزن به ترتیب در ابتدا و انتهای هر دوره  $t$ ؛  $IN_t$  = حجم جریان ورودی به مخزن در دوره  $t$ ؛  $EV_t$  = ارتفاع تبخیر مخزن در دوره  $t$ ؛  $ST_{min}$  و  $ST_{max}$  = به ترتیب بیش‌ترین و کم‌ترین حجم ذخیره مخزن در کل دوره بهره‌برداری؛  $SP_t$  = حجم سرریز از مخزن در دوره  $t$ ؛  $N$  = طول دوره بهره‌برداری؛  $AR_t$  = مساحت دریاچه مخزن در شروع دوره  $t$  ( $AR_t = aST_t^2 + bST_t + c$ )، و  $a$ ،  $b$  و  $c$  = مقادیر ثابت منحنی سطح دریاچه-حجم ذخیره مخزن، هستند.

برای تضمین رعایت قیود مربوط به حجم ذخیره و رهاسازی، توابع جریمه مطابق با روابط (۱۵) و (۱۶) به تابع هدف افزوده می‌شوند:

$$(15)$$

$$PF1_t = A' \cdot \left( \frac{|ST_{min} - ST_t|}{ST_{max} - ST_{min}} \right)^2 + B' \quad \forall t = 1, 2, \dots, N \quad (16)$$

$$PF2_t = C' \left( \frac{|RT_t|}{DE_t} \right) + D' \quad \forall t = 1, 2, \dots, N$$

که در آن،  $PF1_t$  و  $PF2_t$  = به ترتیب توابع جریمه حاصل از تخطی از قیود روابط (۱۲) و (۱۳) هستند. مقادیر پارامترهای جریمه به صورت تجربی برابر با  $\hat{A} = 10$ ،  $\hat{B} = 0.1$ ،  $\hat{C} = 5$  و  $\hat{D} = 0.01$  در نظر گرفته شدند.

### برنامه‌ریزی ژنتیک (GP)

برنامه‌ریزی ژنتیک (GP) یکی از زیرشاخه‌های مهم الگوریتم‌های فراابتکاری است که برای تولید خودکار برنامه‌های رایانه‌ای یا مدل‌های ریاضی برای حل مسائل پیچیده به کار می‌رود. این روش نخستین بار توسط کوزا (Koza, 1990) معرفی شد و از آن زمان

1. Mutation  
2. Crossover  
3. Fitness Evaluation  
4. Reproduction

عملکرد سامانه‌های آبی (در کنار قابلیت اطمینان و آسیب‌پذیری) شناخته می‌شود (Hashimoto et al., 1982). در طراحی و بهره‌برداری از مخازن، تاب‌آوری نشان می‌دهد که سامانه تا چه حد می‌تواند پس از یک دوره کمبود، به وضعیت تأمین پایدار بازگردد. این شاخص به‌ویژه در شرایط تغییر اقلیم و افزایش نوسانات هیدرولوژیکی اهمیت دارد، زیرا سامانه‌هایی با تاب‌آوری بالا می‌توانند در برابر شوک‌های محیطی بهتر عمل کنند. مخازن بزرگ‌تر به‌طور معمول تاب‌آوری بالاتری دارند. سیاست‌های بهره‌برداری هوشمندانه می‌توانند بازگشت سریع‌تری را تضمین کنند. استفاده از منابع جایگزین (چاه، انتقال بین‌حوضه‌ای) تاب‌آوری را افزایش می‌دهد. مدل‌های پیش‌بینی جریان و تقاضا نقش مهمی در افزایش تاب‌آوری دارند.

کاربردهای شاخص تاب‌آوری شامل (۱) ارزیابی سناریوهای بهره‌برداری در مدل‌های بهینه‌سازی مخزن، (۲) مقایسه عملکرد الگوریتم‌های تصمیم‌گیری در شرایط بحرانی، (۳) تحلیل حساسیت سامانه به تغییرات اقلیمی و خشکسالی، (۴) طراحی سیاست‌های تطبیقی برای مدیریت پایدار منابع آب، هستند.

### نتایج

#### بررسی عملکرد مدل‌های شبیه‌سازی اقلیم براساس داده‌های گزارش پنجم IPCC

برای دستیابی به برترین مدل‌های شبیه‌سازی اقلیم در زمینه پیش‌بینی دمای هوا و میزان بارش در مقیاس ماهانه، مجموعه‌ای از ۲۲ مدل اقلیمی معرفی شده در گزارش پنجم هیئت بین‌دولتی تغییر اقلیم (IPCC) تحت سناریوی RCP 2.6 که معرف آینده‌ای با سطح پایین انتشار گازهای گلخانه‌ای و مخاطرات اقلیمی محدود است، مورد بررسی قرار گرفت. این سناریو برپایه‌ی فرض کاهش چشم‌گیر در انتشار آلاینده‌ها از طریق سیاست‌های زیست‌محیطی و فن‌آوری‌های پاک، بنا شده است. پس از تحلیل دقیق عملکرد هر مدل، گزینه‌هایی با دقت بالاتر برای پیش‌بینی متغیرهای اقلیمی در دهه‌های آتی انتخاب شدند. جزئیات آماری این بررسی در جدول ۶ آمده است.

تجربی، و (۳) تولید خودکار کدهای رایانه‌ای برای حل مسائل خاص، هستند. چالش‌ها و محدودیت‌های GP شامل (۱) هزینه محاسباتی بالا به دلیل ساختار درختی و پیچیدگی عملیات، (۲) خطر بیش‌برازش<sup>۱</sup> در صورت عدم کنترل مناسب، (۳) نیاز به تنظیم دقیق پارامترها مانند اندازه جمعیت، نرخ جهش و ترکیب، و (۴) تفسیرپذیری پایین در برخی موارد، به‌ویژه در درخت‌های بزرگ، هستند.

#### شاخص تاب‌آوری در سامانه‌های تأمین آب مخزن

تاب‌آوری در سامانه‌های تأمین آب به توانایی سامانه در بازگشت سریع و مؤثر به عملکرد مطلوب پس از وقوع اختلال یا کمبود اشاره دارد (McMahon et al., 2006). این اختلال می‌تواند ناشی از خشکسالی، خرابی تجهیزات، نوسانات تقاضا یا تغییرات اقلیمی باشد. شاخص تاب‌آوری به‌عنوان یکی از معیارهای کلیدی در ارزیابی عملکرد بلندمدت مخازن و سامانه‌های مدیریت منابع آب شناخته می‌شود.

شاخص تاب‌آوری به‌طور معمول به‌صورت نسبت تعداد دفعاتی که سامانه پس از وقوع شکست<sup>۲</sup> به وضعیت عملکردی مطلوب بازمی‌گردد، به کل تعداد شکست‌ها تعریف می‌شود (Loucks and van Beek, 2017). در برخی مطالعات، این شاخص به‌صورت احتمال بازگشت سامانه به وضعیت تأمین کامل در دوره بعدی پس از وقوع کمبود مطابق با رابطه (۱۷) تعریف می‌شود:

$$ResI = \frac{Count_N[(RE_{t+1} \geq DE_{t+1})|(RE_t < DE_t)]}{Count_N(RE_t < DE_t)} \times 100$$

$$\forall t = 1, 2, \dots, N$$

که در آن،  $ResI$  شاخص برگشت‌پذیری در کل دوره بهره‌برداری =  $Count_N[(RE_{t+1} \geq DE_{t+1})|(RE_t < DE_t)]/N$  تعداد دوره‌های تأمین آب در دوره  $t+1$  به شرط عدم تأمین در دوره  $t$  هستند.

تاب‌آوری به‌عنوان یکی از سه شاخص اصلی

1. Overfitting
2. Failure

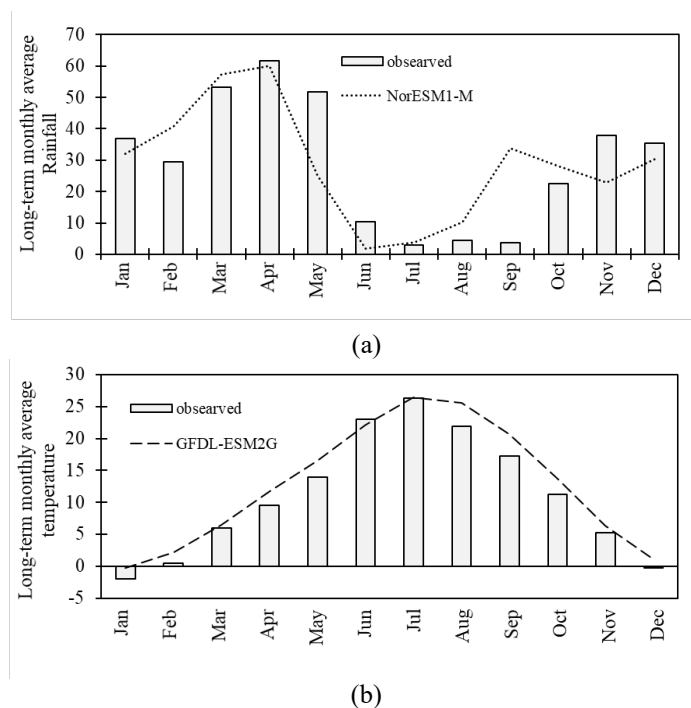
جدول ۶. عملکرد مدل‌های منتخب اقلیمی

Table 6. Performance of selected climate models

| مدل<br>Model | دما<br>Temperature  |                |               |                          |                          |
|--------------|---------------------|----------------|---------------|--------------------------|--------------------------|
|              | $r$<br>(%)          | $RMSE$<br>(°C) | $MAE$<br>(°C) | $NSE$<br>(Dimensionless) | $KGE$<br>(Dimensionless) |
| GFDL-ESM2G   | 99.06               | 2.07           | 1.78          | 0.95                     | 0.98                     |
| مدل<br>Model | بارندگی<br>Rainfall |                |               |                          |                          |
|              | $r$<br>(%)          | $RMSE$<br>(mm) | $MAE$<br>(mm) | $NSE$<br>(Dimensionless) | $KGE$<br>(Dimensionless) |
| NorESM1-M    | 74.72               | 13.42          | 9.90          | 0.54                     | 0.75                     |

از عملکرد مدل NorESM1-ME در شبیه‌سازی بارندگی بوده است، که با نتایج رضانی اعتدالی و کوهی (Ramezani Etedali and Khoohi, 2024) مطابقت دارد. در مرحله بعد، میانگین ماهانه بلندمدت خروجی مدل منتخب که کم‌ترین میزان خطا را در پیش‌بینی دما و بارندگی داشتند، محاسبه شد. این میانگین‌ها با داده‌های واقعی بلندمدت مقایسه گردیدند و نتایج در شکل ۵ به صورت دو بخش مجزا برای دما و بارندگی به تصویر کشیده شده‌اند.

در جدول مذکور، شاخص‌هایی نظیر  $MAE$ ،  $NSE$ ،  $RMSE$  و  $r$  برای هر مدل در دو بخش دما و بارندگی ارائه شده‌اند. این شاخص‌ها به‌طور مستقیم میزان تطابق خروجی مدل‌ها با داده‌های واقعی را نشان می‌دهند. براساس تحلیل داده‌ها، مدل NorESM1-ME در شبیه‌سازی بارندگی عملکرد مطلوب‌تری داشته‌اند، در حالی که مدل GFDL-ESM2G، در پیش‌بینی دما دقت بالاتری از خود نشان داده‌اند. به‌طور کلی، عملکرد مدل GFDL-ESM2G در شبیه‌سازی دما بهتر



شکل ۵. مقایسه میانگین بلندمدت ماهانه (الف) بارندگی و (ب) دما

Fig 5. Comparison of long-term monthly averages of (a) precipitation and (b) temperature

برای پیش‌بینی رواناب ماهانه رودخانه قرنقو در بازه زمانی ۲۰۷۰ تا ۲۰۹۹، از داده‌های تاریخی شامل بارندگی، دما و رواناب ماهانه مربوط به سال‌های ۱۹۷۱ تا ۲۰۰۰ بهره گرفته شد. این داده‌ها به‌عنوان ورودی به مدل یادگیری عمیق LSTM داده شدند. به‌منظور آموزش مدل، ۷۵ درصد داده‌ها (۱۹۷۱ تا ۱۹۹۳) برای یادگیری و ۲۵ درصد باقی‌مانده (۱۹۹۴ تا ۲۰۰۰) برای ارزیابی عملکرد مدل استفاده گردید. در فرآیند طراحی مدل، ساختار شبکه شامل چندین لایه LSTM با تنظیمات مختلف مورد آزمایش قرار گرفت. انتخاب تعداد نرون‌ها، نرخ یادگیری و تعداد دوره‌های آموزشی براساس آزمون‌های تجربی و بهینه‌سازی تدریجی انجام شد. پس از بررسی پیکربندی‌های مختلف، ساختاری با عملکرد مطلوب‌تر انتخاب گردید که در جدول ۷ قابل مشاهده است.

نتایج مدل GFDL-ESM2G در بازسازی روندهای دمایی، بیش‌ترین تطابق را با داده‌های مشاهداتی دوره پایه (۱۹۷۱ تا ۲۰۰۰) داشته‌اند. هم‌چنین مدل NorESM1-M برای شبیه‌سازی یازندگی در دوره پایه تطابق قابل قبولی داشته است. با توجه به ارزیابی‌های عددی و تطابق‌های مشاهده‌شده، مدل NorESM1-M برای پیش‌بینی بارندگی و مدل GFDL-ESM2G برای پیش‌بینی دما در دوره آینده (۲۰۷۰ تا ۲۰۹۹) انتخاب شدند. این انتخاب براساس قابلیت اعتماد این مدل‌ها در بازسازی شرایط اقلیمی گذشته صورت گرفته است و می‌تواند مبنای مناسبی برای تحلیل‌های آینده‌نگر در حوزه تغییرات اقلیمی باشد.

#### بررسی حساسیت بارش-رواناب با استفاده از LSTM

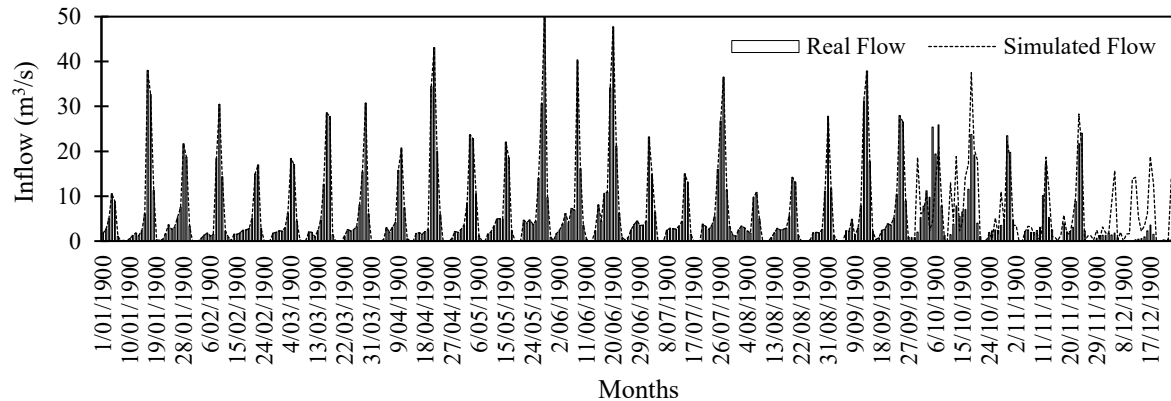
جدول ۷. تنظیمات بهینه مدل LSTM برای شبیه‌سازی رواناب

Table 7. Optimal settings of the LSTM model for runoff simulation

| پارامتر<br>Parameter                                     | مقدار منتخب<br>Selected value |
|--|-------------------------------|
| تعداد لایه‌های LSTM<br>Number of LSTM layers             | 2                             |
| تعداد نورون‌ها در هر لایه<br>Number of neurons per layer | 64                            |
| نرخ یادگیری<br>Learning rate                             | 0.001                         |
| تعداد دوره‌های آموزشی<br>Number of training sessions     | 1000                          |

ماهانه را در هر دو مرحله آموزش و آزمایش بازسازی کند. هم‌پوشانی مناسب بین داده‌های واقعی و پیش‌بینی‌شده در دوره آموزش نشان‌دهنده توانایی بالای مدل در یادگیری الگوهای پیچیده زمانی است. بنابراین، می‌توان نتیجه گرفت که شبکه LSTM ابزار مناسبی برای پیش‌بینی رواناب در دوره‌های آتی خواهد بود. اگرچه  $r$  در داده‌های آزمون پایین‌تر از نشان‌دهنده دقت قابل قبول می‌باشد. این موضوع ناشی از غیرایستا بودن داده‌های آزمون و شرایط هیدرواقلیمی متغیر منطقه است. بررسی‌ها نشان دادند که مدل در بازتولید مقادیر میانگین عملکرد مطلوبی دارد، اما در پیش‌بینی مقادیر حدی (سیلاب

در جدول ۷ انتخاب دو لایه مخفی با ۶۴ نرون براساس آزمون و خطا و مقایسه مدل‌های مختلف انجام شد. ساختارهای پیچیده‌تر (سه یا چهار لایه منجر به بیش‌برازش شدند، در حالی که ساختار ساده‌تر (یک لایه) دقت پایین‌تری داشت. بنابراین ساختار دو لایه با ۶۴ نرون به‌عنوان بهترین حالت انتخاب شد. در ادامه، شکل ۶ روند مقایسه بین داده‌های واقعی و خروجی مدل LSTM را در دوره پایه (۱۹۷۱ تا ۲۰۰۰) نشان می‌دهد. هم‌چنین جدول ۸ شامل شاخص‌های آماری برای ارزیابی دقت مدل در بخش‌های آموزش و آزمایش است. براساس نتایج حاصل از شکل ۶ و جدول ۸، مدل LSTM توانسته است با دقت قابل توجهی رواناب



شکل ۶. مقایسه رواناب واقعی و پیش‌بینی شده توسط مدل LSTM در دوره پایه

Fig 6. Comparison of actual and predicted runoff by the LSTM model in the base period

جدول ۸. شاخص‌های آماری عملکرد مدل LSTM در داده‌های آموزش و آزمایش

Table 8. Statistical indicators of the performance of the LSTM model on training and testing data

| نوع داده<br>Data type | ضریب همبستگی<br>Correlation<br>coefficient (r) | ریشه میانگین<br>مربعات خطا<br><i>RMSE</i> (m <sup>3</sup> /s) | میانگین خطای<br>مطلق<br><i>MAE</i> (m <sup>3</sup> /s) | کارایی نش-ساتکلیف<br><i>NSE</i><br>(Dimensionless) | کارایی کلینگ-گوپتا<br><i>KGE</i><br>(Dimensionless) |
|-----------------------|--|---|--|--|---|
| آموزش<br>Training     | 0.97   | 0.02  | 0.015  | 0.98   | 0.96  |
| آزمون<br>Test         | 0.74   | 0.065   | 0.005  | 0.87   | 0.76  |

پیش‌بینی شده دما و بارش به‌عنوان ورودی به LSTM که پیش‌تر آموزش دیده بود، وارد شد. خروجی این فرآیند شامل دبی جریان ماهانه برای بازه زمانی ۲۰۷۰ تا ۲۰۹۹ بود. میانگین‌های محاسبه‌شده برای سه متغیر اصلی دما، بارندگی و رواناب در جدول ۹ قابل مشاهده است که مقایسه‌ای بین دوره پایه (۱۹۷۱ تا ۲۰۰۰) و دوره آینده ارائه می‌دهد.

یا خشک‌سالی شدید) دقت کم‌تری مشاهده شد. این موضوع مطابق با یافته‌های پژوهش‌های اخیر (مانند Salarizaji et al., 2024) است.

**بررسی تغییرات پیش‌بینی‌شده پارامترهای هیدرواقليمی در آینده**  
پس از مدل‌سازی پارامترهای اقلیمی آینده، مقادیر

جدول ۹. میانگین دما، بارندگی و رواناب در دوره‌های گذشته و آینده

Table 9. Average temperature, precipitation, and runoff in the past and the future periods

| پارامتر<br>Parameter   | ۱۹۷۱-۲۰۰۰ (دوره پایه)<br>1971-2000 (baseline) | ۲۰۰۰-۱۹۷۱ (دوره پایه)<br>1971-2000 (baseline) |
|------------------------|---|---|
| دما<br>Temperature     | 11.1  | 13.4  |
| بارندگی<br>Rainfall    | 29.2  | 25.5  |
| نرخ جریان<br>Flow Rate | 6.1   | 4.7   |

شده‌اند. تحلیل نمودارهای شکل ۷ نشان می‌دهد که این افت به‌طور عمده در ماه‌های آوریل و مه، که به‌طور معمول بیش‌ترین رواناب را دارند، رخ داده است.

براساس داده‌های جدول ۹، میزان بارش و رواناب در دوره آینده نسبت به دوره پایه کاهش یافته‌اند؛ به‌طوری‌که بارندگی با افتی حدود ۱۲/۷ درصد و دبی جریان با کاهش تقریبی ۲۳ درصد مواجه

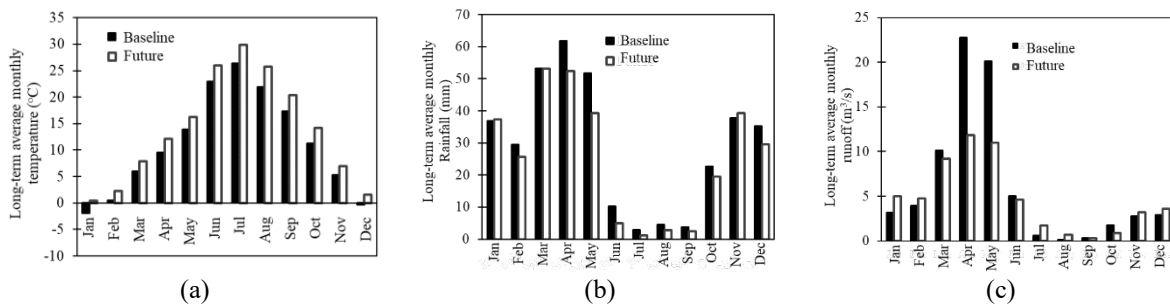
در آینده نقش مهمی در برنامه‌ریزی منابع دارد. براساس نتایج مدل‌سازی، میانگین ماهانه تقاضای کل آب کشاورزی در دوره آینده (۲۰۷۰-۲۰۹۹) نسبت به دوره پایه (۱۹۷۱-۲۰۰۰) با رشد ۲۰ درصدی مواجه بوده است. این افزایش عمدتاً در ماه‌های گرم و کم‌بارش سال، یعنی ژوئن تا آگوست، مشاهده می‌شود که نشان‌دهنده فشار بیش‌تر بر منابع آبی در فصل‌های بحرانی است.

شکل ۸ روند تغییرات تقاضای کل آب کشاورزی را در ماه‌های مختلف سال بین دو دوره مقایسه می‌کند. در این شکل، الگوی افزایش تقاضا در دوره آتی برای محصولات کشاورزی نمایش داده شده است. این افزایش در ماه‌های آوریل تا سپتامبر شدت بیش‌تری دارد که با دوره رشد و نیاز آبی بیش‌تر محصولات هم‌راستا است.

در مقابل، دمای متوسط در دوره آینده نسبت به دوره گذشته افزایش قابل توجهی داشته و حدود ۲۱ درصد بیش‌تر شده است. بررسی نمودار دما در شکل ۷ نشان می‌دهد که بیش‌ترین رشد دما در ماه ژوئیه اتفاق افتاده است.


### تحلیل تقاضای کل آب کشاورزی در دوره‌های پایه و آتی

برای دستیابی به تخصیص بهینه منابع آبی میان بخش‌های مختلف مصرف‌کننده مانند شرب، صنعت و کشاورزی، ضروری است که میزان تقاضای هر بخش در بازه‌های زمانی مختلف به‌صورت جامع و دقیق برآورد شود. از آن‌جا که بخش کشاورزی در بسیاری از مناطق بیش‌ترین سهم مصرف آب را به‌خود اختصاص می‌دهد، بررسی روند تغییرات تقاضای کل این بخش



شکل ۷. مقایسه مقادیر پیش‌بینی شده (الف) دما، (ب) بارندگی و (پ) رواناب در دوره آینده با دوره پایه

Fig 7. Comparison of the predicted values for (a) temperature, (b) precipitation, and (c) runoff in the future period within the base period



شکل ۸. مقایسه تغییرات تقاضای کل در بازه آتی و پایه

Fig 8. Comparison of the changes in total demand in the future and the base periods

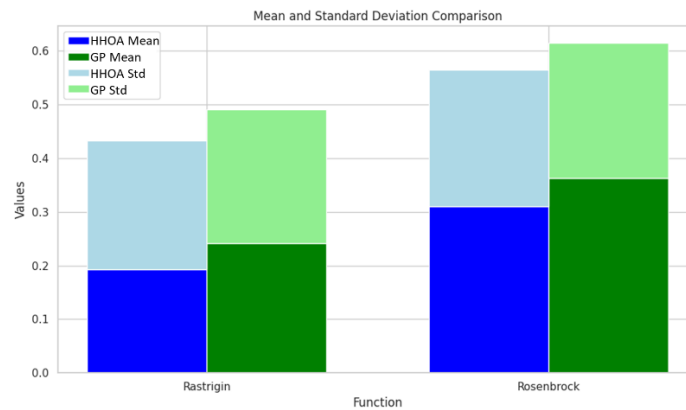
مورد بررسی قرار گرفته است. برای سنجش دقت و توانایی این روش‌ها در جستجوی فضای پاسخ، از دو تابع معیار پیچیده و پرکاربرد استفاده شده است: تابع راستریجین با ساختار چندقله‌ای و تابع روزنبروک دره باریک و کمینه سراسری.

بررسی نتایج حاصل از بهینه‌سازی تک‌هدفه تحلیل عملکرد الگوریتم‌ها در حل توابع ریاضی راستریجین و روزنبروک در این بخش، کارایی دو الگوریتم فراابتکاری شامل GP و HHOA در حل مسائل بهینه‌سازی تک‌هدفه

است. برای درک بهتر روند همگرایی الگوریتم‌ها، نمودارهای شکل ۱۰ ارائه شده‌اند. این نمودارها نشان می‌دهند که HHOA با سرعت بیشتری به سمت مقدار بهینه حرکت کرده و در مراحل پایانی نیز نوسانات کمتری نسبت به GP دارد. همچنین مسیر جستجوی الگوریتم‌ها در فضای تابع، بیان‌گر تفاوت در نحوه عبور از کمینه‌های محلی و رسیدن به نقطه بهینه است. با توجه به عملکرد قابل قبول HHOA نسبت به GP در ادامه از مدل HHOA برای مسأله تخصیص آب استفاده خواهد شد.


هر الگوریتم به صورت مستقل و در ۱۰ اجرای متوالی روی هر تابع اعمال شد تا نتایج حاصل از آن‌ها از نظر میانگین و پراکندگی آماری قابل مقایسه باشد. شکل ۹، مقادیر به دست آمده از اجرای الگوریتم‌ها را به صورت خلاصه ارائه می‌دهد.

نتایج شکل ۹ نشان می‌دهد که HHOA در هر دو تابع، عملکرد بهتری از نظر دقت نهایی و پایداری داشته است. مقدار میانگین کم‌تر و انحراف معیار پایین‌تر بیان‌گر توانایی این الگوریتم در یافتن پاسخ‌های نزدیک به بهینه و حفظ ثبات در تکرارهای مختلف



شکل ۹- مقایسه آماری عملکرد HHOA و GP در حل توابع راستریجین و روزنبروک

Fig 9. Statistical comparison of the performance of HHOA and GP in solving Rastrigin and Rosenbrock functions



شکل ۱۰. مقایسه گرافیکی عملکرد الگوریتم‌ها در حل توابع ریاضی (الف) راستریجین و (ب) روزنبروک

Fig 10. Graphical comparison of the algorithms' performance in solving mathematical functions (a) Rastrigin and (b) Rosenbrock


گرفته است. نتایج حاصل از اجرای مدل در دو بازه زمانی—دوره پایه و دوره آینده—در شکل ۱۱ نشان داد که مقدار تابع هدف در دوره پایه برابر با ۰/۰۴ و در دوره پیش‌بینی شده برابر با ۰/۰۳۴ بوده است.

تحلیل بهینه‌سازی تک‌هدفه در تخصیص منابع آب

در این بخش، فرآیند بهینه‌سازی تخصیص منابع آبی با تمرکز بر یک تابع هدف منفرد مورد بررسی قرار

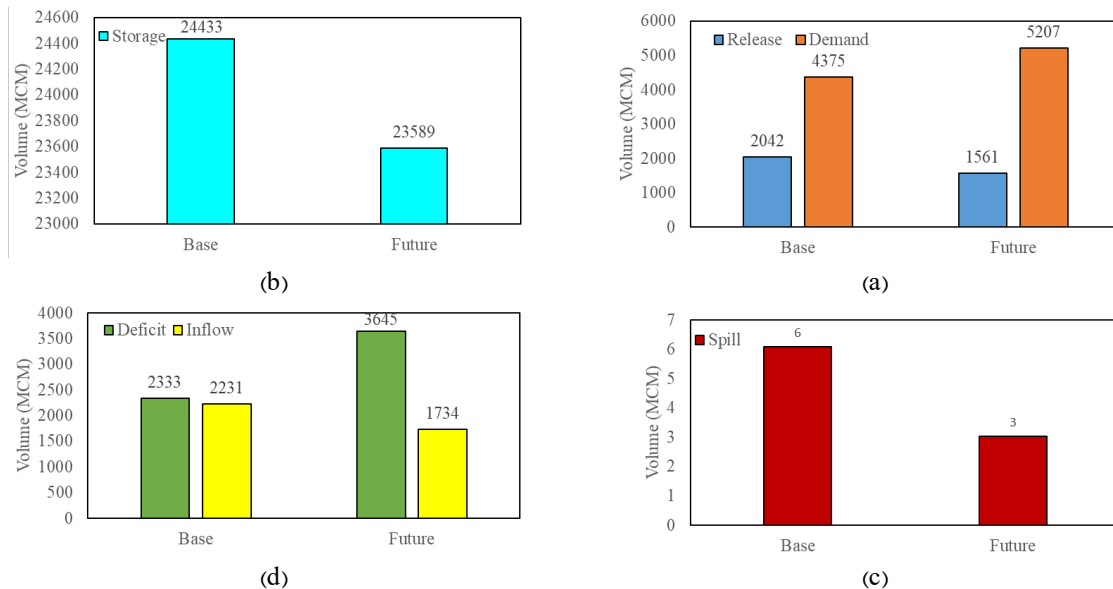
با دقت بالاتری پوشش دهد. مقایسه مقادیر حجم رهاسازی شده، تقاضا، سرریز، و کمبود در شکل ۱۲ برای دوره‌های پایه و آتی ارائه شده است.

این کاهش اندک در مقدار تابع هدف بیانگر آن است که مدل در دوره آتی توانسته است تخصیص منابع را با کارایی بیشتری انجام دهد و نیازهای آبی را



شکل ۱۱. مقادیر بهینه تابع هدف در دوره‌های پایه و آتی

Fig 11. Optimal values of the objective function in the base and future periods



شکل ۱۲. تحلیل اجزای حجمی مخزن شامل رهاسازی، ذخیره‌سازی، سرریز، و کمبود تأمین، در بازه زمانی پایه و آتی

Fig 12. Analysis of the reservoir volume components including release, storage, overflow, and supply shortage, in the base and future time periods

تقاضا باشد. شکل ۱۲ (پ) مقایسه حجم سرریز در دوره‌های آتی و پایه را نشان می‌دهد. به‌طور کلی سرریز به‌طور معمول به‌دلیل محدودیت ظرفیت مخزن و ورود ناگهانی آب اتفاق می‌افتد. سرریز در دوره آتی نسبت به دوره پایه کاهش می‌یابد. شکل ۱۲ (ت) مقایسه شاخص کمبود تأمین آب را در دوره‌های پایه و آتی را نشان می‌دهد. این شاخص یکی از مهم‌ترین معیارهای عملکرد سامانه است افزایش کمبود در دوره آتی می‌تواند هشداردهنده باشد و نیاز به بازنگری

همان‌طور که در شکل ۱۲ (الف) نشان داده شده است، مقدار رهاسازی در دوره آتی نسبت به دوره پایه کاهش یافته باشد، که می‌تواند ناشی از محدودیت منابع ورودی (مطابق شکل ۱۲ (ت)) یا سیاست‌های صرفه‌جویی باشد. در شکل ۱۲ (ب) مقایسه حجم ذخیره مخزن در دوره‌های آتی و پایه را نشان می‌دهد. حجم ذخیره‌شده در مخزن نقش حیاتی در پایداری سامانه دارد. کاهش ذخیره در دوره آتی می‌تواند ممکن است ناشی از افت ورودی‌ها یا افزایش فشار

دقت نتایج اثرگذار باشند.


هم‌چنین از محدودیت‌های پژوهش حاضر، عدم بررسی عدم قطعیت ناشی از مدل‌های اقلیمی و حساسیت‌سنجی پارامترهای الگوریتم است. پیشنهاد می‌شود در مطالعات آتی، تحلیل عدم قطعیت و حساسیت‌سنجی به‌طور جامع انجام گیرد و از روش‌های تحلیل سناریو و مونت کارلو برای بررسی عدم قطعیت استفاده شود. در ضمن، در این پژوهش تمرکز اصلی بر بهینه‌سازی تخصیص آب تحت سناریوهای تغییر اقلیم آینده بوده است. با این حال، به‌عنوان مسیر پیشنهادی برای پژوهش‌های آتی می‌توان عملکرد منحنی فرمان فعلی را در شرایط اقلیمی آینده از طریق شبیه‌سازی بررسی کرد تا میزان کارایی آن پیش از اعمال بهینه‌سازی مشخص شود.

### نتیجه‌گیری

یافته‌های این پژوهش نشان دادند که مدل GFDL-ESM2G برای شبیه‌سازی دما و مدل NorESM1-M برای بارش، بیش‌ترین انطباق را با داده‌های مشاهداتی دوره پایه (۲۰۰۰-۱۹۷۱) داشته‌اند. ضریب همبستگی بالا (بیش از ۰/۹۵ برای دما و ۰/۷۴ برای بارش) و مقادیر به‌نسبت پایین  $RMSE$  و  $MAE$ ، بیان‌گر قابلیت اطمینان این مدل‌ها در بازسازی روندهای اقلیمی گذشته است. بر همین اساس، این دو مدل برای شبیه‌سازی شرایط آینده (۲۰۷۰-۲۰۹۹) انتخاب شدند. نتایج حاصل از سناریوی RCP2.6 نشان می‌دهد که در افق بلندمدت، میانگین دما روندی افزایشی خواهد داشت، در حالی‌که بارش‌های سالانه با نوسانات قابل توجهی همراه خواهند بود. این تغییرات می‌تواند موجب تغییر الگوی تغذیه مخزن قرقو و افزایش احتمال وقوع خشک‌سالی‌های متوالی گردد. در گام بعدی عملکرد مدل LSTM برای شبیه‌سازی رواناب سنجیده شدند. مدل LSTM توانست با دقت قابل قبولی روندهای رواناب ماهانه را در دوره پایه شبیه‌سازی کند. شاخص‌های ارزیابی ( $NSE$ ) بیش از ۰/۹۸ در مرحله آموزش و ۰/۸۷ در مرحله آزمون) نشان‌دهنده توانایی مدل در استخراج وابستگی‌های زمانی بین بارش، دما و جریان رودخانه بودند. قابل

در سیاست‌های تخصیص، ظرفیت‌سازی یا مدیریت تقاضا را مطرح کند.

مقایسه این چهار مؤلفه در دو دوره زمانی، تصویری روشن از تحول در عملکرد مخزن ارائه می‌دهد. اگر در دوره آتی شاهد کاهش کمبود و سرریز و افزایش ذخیره‌سازی باشیم، می‌توان گفت که سامانه به سمت پایداری و بهره‌وری بیش‌تر حرکت کرده است. اما اگر کمبود افزایش یافته و ذخیره کاهش یافته، باید به‌دنبال علل ساختاری یا اقلیمی آن بود. هم‌چنین نتایج شاخص تاب‌آوری عملکرد مخزن برای دو دوره پایه و آتی در شکل ۱۳ ارائه شده است.



شکل ۱۳- مقایسه شاخص تاب‌آوری سامانه

Fig 13. Comparison of system's resilience index

همان‌طور که از شکل ۱۳ نشان داده شده است، شاخص برگشت‌پذیری در دوره آتی نسبت به دوره پایه حدود ۱۷ درصد افزایش داشته است، یعنی تاب‌آوری سامانه مخزن در تأمین آب و شرایط کمبود آب در شرایط تغییر اقلیم، بیش‌تر شده است. قابل ذکر است که برای بررسی حساسیت HHOA، مقادیر مختلف اندازه جمعیت و نرخ‌های مختلف یادگیری تغییر داده شد. نتایج نشان دادند که اندازه جمعیت بالاتر موجب همگرایی پایدارتر، اما زمان محاسباتی بیش‌تر می‌شود. نرخ یادگیری بالاتر سرعت همگرایی را افزایش داد، اما خطر بیش‌برازش نیز بیش‌تر شد.

### محدودیت‌های تحقیق و پیشنهادهای آتی

از محدودیت‌های این پژوهش می‌توان به وابستگی به داده‌های تاریخی، فرضیات نرم‌افزار Cropwat، و حساسیت نتایج به انتخاب پارامترهای الگوریتم‌های بهینه‌سازی اشاره کرد. این موارد ممکن است بر

ناشی از مدیریت هوشمندانه رهاسازی و کاهش دفعات وقوع کمبودهای متوالی است.

یافته‌های پژوهش حاضر همسو با مطالعات پیشین (Akbarifard and Zounemat-Kermani, 2024; Yilmaz et al., 2025; Dabral et al., 2025) تأیید می‌کند که استفاده از الگوریتم‌های فراابتکاری می‌تواند به بهبود معنادار در مدیریت مخازن تحت شرایط تغییر اقلیم منجر شود. با وجود این، مزیت اصلی HHOA نسبت به الگوریتم‌های متداول مانند GP، در توانایی آن برای برقراری تعادل بین اکتشاف و استخراج و جلوگیری از گیر افتادن در نقاط بهینه محلی است. این ویژگی به‌ویژه در شرایطی که تقاضای کشاورزی و ورودی مخزن هم‌زمان دچار نوسان هستند، اهمیت بیشتری می‌یابد.

در مجموع، می‌توان نتیجه گرفت که ترکیب مدل‌های اقلیمی، مدل‌های پیش‌بینی رواناب مبتنی بر یادگیری عمیق، و الگوریتم‌های فراابتکاری جدید، چارچوبی قدرتمند برای برنامه‌ریزی پایدار منابع آب فراهم می‌آورد. در این میان، مدل HHOA به‌عنوان ابزاری نوین، قابلیت بالایی در کاهش کسری آب و ارتقای تاب‌آوری مخزن قرنقو نشان داده است. پیشنهاد می‌شود در تحقیقات آینده، نسخه‌های چندهدفه HHOA برای هم‌زمان در نظر گرفتن معیارهایی چون قابلیت اطمینان، آسیب‌پذیری و کارایی اقتصادی مورد استفاده قرار گیرند.

نتایج به‌طور کلی نشان دادند که ترکیب مدل LSTM و HHOA توانست نیاز آبیاری محصولات کشاورزی را با دقت بیشتری برآورد کرده و کسری آب را تا ۲۲ درصد کاهش دهد. همچنین، شاخص تاب‌آوری مخزن از ۶۷ به ۷۹ درصد افزایش یافت. این یافته‌ها، بیان‌گر کارایی رویکرد پیشنهادی در مدیریت پایدار منابع آب تحت شرایط تغییر اقلیم است.

#### منابع

Akbari-Alashti, H., Bozorg-Haddad, O., Fallah-Mehdipour, E., and Mariño, M. A. (2014). Multi-reservoir real-time operation rules: A new genetic programming approach.

ذکر است که فرآیندهای مرتبط با رواناب و بارندگی به‌طور ذاتی ناپایستا هستند و تغییرات اقلیمی این ناپایداری را تشدید می‌کند. بنابراین دقت مدل در دوره‌های مختلف ممکن است متفاوت باشد (Kousali et al., 2022; Modabber-Azizi et al., 2023; Salarijazi et al., 2023). مقایسه رواناب پیش‌بینی‌شده در افق آینده نشان داد که علاوه بر کاهش میانگین جریان سالانه، توزیع زمانی رواناب نیز نامنظم‌تر خواهد شد. در نتیجه، احتمال کمبود آب در فصل‌های زراعی حساس افزایش خواهد یافت.

در گام بعدی نیاز آبی پایین‌دست با مدل Cropwat برآورد شد. نتایج حاصل از مدل Cropwat بیانگر آن است که نیاز خالص آبیاری محصولات زراعی در دوره آینده نسبت به دوره پایه حدود ۲۰ درصد افزایش خواهد یافت. افزایش دما و کاهش کارایی بارش مؤثر، عامل اصلی این روند است. بیش‌ترین افزایش نیاز آبی مربوط به محصولات با فصل رشد طولانی مانند ذرت و یونجه بوده است. در مقابل، محصولات زودرس مانند جو تغییرات کم‌تری را نشان دادند. این نتایج اهمیت استفاده از راهبردهای سازگاری در الگوی کشت و بهبود راندمان آبیاری را دوچندان می‌کند.

در ادامه عملکرد مدل‌های HHOA و GP برای توابع معیار و بهینه‌سازی تخصیص آب مقایسه شدند. اجرای توابع معیار نشان داد که مدل HHOA توانایی بالاتری در اجتناب از بهینه‌های محلی نسبت به GP دارد و در تابع راس‌تریجین با میانگین خطای کم‌تر به نقطه بهینه همگرا شد. در مسئله تخصیص بهینه منابع آب نیز، مدل HHOA موفق به کاهش میانگین کسری آب به میزان ۲۲ درصد نسبت به GP گردید. علاوه بر این، HHOA توزیع متعادل‌تری از رهاسازی آب بین ماه‌های مختلف ارائه کرد که با شرایط متغیر جریان ورودی و نیاز آبی هم‌خوانی بیشتری داشت.

محاسبه شاخص تاب‌آوری نشان داد که در دوره پایه، سامانه توانایی بازگشت به وضعیت پایدار تأمین آب را در ۶۷ درصد موارد داشت، در حالی که در سناریوی آینده این مقدار به ۷۹ درصد افزایش یافت. با این حال، استفاده از مدل HHOA توانست تاب‌آوری سامانه را در دوره آینده تا ۱۷ درصد ارتقا دهد. این بهبود

- <https://openknowledge.fao.org/handle/20.500.14283/f2430e>.
- Hashimoto, T., Stedinger, J. R., & Loucks, D. P. (1982). Reliability, resiliency, and vulnerability criteria for water resource system performance evaluation. *Water Resources Research*, 18(1), 14–20. <https://doi.org/10.1029/WR018i001p00014>.
- Helmi, M., Neyshabouri, S. Z., Amirabadizadeh, M. & Yaghoobzadeh, M. (2024). Evaluation of SDSM, LARS-WG, and ANN methods in downscaling of temperature and precipitation for two different climates. *Journal of Drought and Climate Change Research (JDCR)*, 1(4), 105–118. [In Persian]. <https://doi.org/10.22077/JDCR.2023.6996.1049>.
- Hınçal, O., Altan-Sakarya, A. B., and Ger, A. M. (2011). Optimization of multireservoir systems by genetic algorithm. *Water Resources Management*, 25 (5), 1465-1487. <https://doi.org/10.1007/s11269-010-9755-0>.
- IPCC, 2014, Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, Pachauri, R.K., and Meyer, L.A., (eds.)]. IPCC, Geneva, Switzerland; 151 pp.
- Karami, H. Ehteram, M. Mousavi, S.F. Farzin, S. Kisi, O., and El-Shafie, A. (2019). Optimization of energy management and conversion in the water systems based on evolutionary algorithms. *Neural Computing and Applications*, 31(10), 5951-5964. [https://doi.org/10.1680/wama.13.00021](https://doi.org/10.1007/Proceedings of the Institution of Civil Engineers: Water Management, 167 (10), 561-576. https://doi.org/10.1680/wama.13.00021).
- Akbarifard, M., & Zounemat-Kermani, M. (2024). New hybrid optimization approaches for the optimal management of surface water resources systems. *Water Resources Management*, 38(2), 341–359. <https://doi.org/10.1007/s11269-024-03941-6>.
- Akbarifard, S., Sharifi, M. R., & Qaderi, K. (2020). Data on optimization of the Karun-4 hydropower reservoir operation using evolutionary algorithms. *Data in brief*, 29, 105048.. <https://doi.org/10.1016/j.dib.2019.105048>.
- Behroozi, A.H., Nazem Al Sadat, S. M. J., & Pishvaei, M. (2023). Evaluating the trend of rainfall changes in the long-term time series of Shiraz. *Journal of Drought and Climate Change Research*, 1(1), 19-32. <https://doi.org/10.22077/JDCR.2023.5856.1001>.
- Bhavya, K., & Elango, L. (2023). Ant-inspired metaheuristic algorithms for combinatorial optimization problems in water resources management. *Water*, 15(9): 1762. <https://doi.org/10.3390/w15091762>.
- Dabral, R., Sharma, A., & Verma, S. (2025). Optimal operation of reservoir for sustainable water resource management using multi-objective algorithms and EMCP approach. *Journal of Hydroinformatics*, 27(5): 878–892. <https://doi.org/10.2166/hydro.2025.064>.
- Doorenbos, J., & Pruitt, W. O. (1977). Guidelines for predicting crop water requirements.

- the long-term spatial-temporal pattern of dry and wet years over Iran. *Physics and Chemistry of the Earth, Parts A/B/C*, 131, 103426. [https://doi.org/10.1016/S1474-7065\(23\)00070-0](https://doi.org/10.1016/S1474-7065(23)00070-0).
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., et al. (2011). *Scikit-learn: Machine Learning in Python* — train\_test\_split documentation.
- Ramezani Etedali, H., & Koochi, S. (2024). Investigating the impact of climate change on the aridity in Iran with population exposure approach. *Journal of Drought and Climate Change Research (JDCR)*, In Press. [In Persian]. <https://doi.org/10.22077/jdcr.2024.8258.1079>.
- Salarijazi, M., Ghorbani, K., Mohammadi, M., Ahmadianfar, I., Mohammadrezapour, O., Naser, M. H., & Yaseen, Z. M. (2023). Spatial-temporal estimation of maximum temperature high returns periods for annual time series considering stationary/nonstationary approaches in Iran urban area. *Urban Climate*, 49, 101504. <https://doi.org/10.1016/j.uclim.2023.101504>.
- Salarijazi, M., Ahmadianfar, I., and Mundher Yaseen, Z. (2024). Prediction enhancement for surface water sodium adsorption ratio using limited inputs: Implementation of hybridized stacked ensemble model with feature selection algorithm. *Physics and Chemistry of the Earth, Parts A/B/C*, 134, 103561, <https://doi.org/10.1016/j.pce.2024.103561>.
- Yilmaz, A. O., Kose, E. I., & Demir, A. (2025). Defining the most appropriate water [s00521-018-3412-6](https://doi.org/10.1016/j.pce.2024.103561).
- Kousali, M., Salarijazi, M., & Ghorbani, K. (2022). Estimation of non-stationary behavior in annual and seasonal surface freshwater volume discharged into the Gorgan Bay, Iran. *Natural Resources Research*, 31, 835–847. <https://doi.org/10.1007/s11053-022-10010-5>.
- Koza, J. R. (1992). *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. MIT Press.
- Loucks, D. P., & van Beek, E. (2017). *Water resource systems planning and management: An introduction to methods, models, and applications*. Springer.
- McMahon, T. A., Adedoye, A. J., & Zhou, S. L. (2006). Assessment of storage requirements for water supply reservoirs. *Journal of Hydrology*, 324(1–4), 1–15. <https://doi.org/10.1016/j.jhydrol.2005.08.006>.
- MiarNaeimi, F., Azizyan, G., & Rashki, M. (2021). Horse herd optimization algorithm: A nature-inspired algorithm for high-dimensional optimization problems. *Knowledge-Based Systems*, 213, 106711. <https://doi.org/10.1016/j.knsys.2020.106711>.
- Ming, B., Chang, J.-X., Huang, Q., Wang, Y.-M., and Huang, Sh.-Z. (2015). Optimal operation of multi-reservoir system based-on cuckoo search algorithm. *Water Resources Management*, 29, 5671-5687, <https://doi.org/10.1007/s11269-015-1140-6>.
- Modabber-Azizi, S., Salarijazi, M., and Ghorbani, K. (2023). A novel approach to recognize

network management plan with different optimization algorithms. *Water Resources Management*, 39(1), 115–132. <https://doi.org/10.1007/s11269-025-04221-7>.

Zhou, X., Leng, Y., Salarijazi, M., Ahmadianfar, I., Ahsan Farooque, A. (2024). Development of forecasting of monthly SAR time series in river systems: A multivariate data decomposition-based hybrid approach. *Process Safety and Environmental Protection*, 188, 1355-1375, <https://doi.org/10.1016/j.psep.2024.06.050>.

