



Extracting the Optimal Role Curve of Dams in Real Time based on the Integration of Meta-Exploration Algorithm and Machine Learning Technique

Ahmad Aman Jalili¹ | Mohsen Najarchi^{2✉} | Saeid Shabanlou³ | Reza Jafarinia⁴

1. Department of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran. E-mail: ahmad.jalili@gmail.com

2. Corresponding Author, Department of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran. E-mail: m-najarchi@iau-arak.ac.ir

3. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. E-mail: saeid.shabanlou@gmail.com

4. Department of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran. E-mail: r-jafarinia@iau-arak.ac

Article Info

Article type: Research Article

Article history:

Received: Oct. 21, 2022

Revised: March. 10, 2023

Accepted: Apr. 24, 2023

Published online: June. 22, 2023

Keywords:

Jamishan Dam,
NSGA-II,
Real Time,
Support Vector Machines,
WEAP.

ABSTRACT

The use of coupled simulation-optimization models to extract the optimal role curve of dams is one of the effective strategies for optimal management of reservoirs. In certain optimization techniques, historical data of the inflow to the reservoir is usually used to extract the optimal role curve of the dam. It is possible that in the coming years, with the change of the inflow to dams, the parameters based on which the optimal role curve was extracted may no longer work and the results may be unexpected. The objective of this research is to provide a solution for extracting the optimal role curve in real time so that by changing the inflow to the dam in the future without re-executing the optimization algorithm and using artificial intelligence techniques in the shortest time, the optimal role curve compatible with the new conditions can be obtained. In this research, the integration of the NSGA-II multi-objective algorithm and the WEAP simulation model is used to derive optimal policies based on historical data. Then, using the support vector machine method and the results obtained from the output of the optimization algorithm, a new structure is developed so that the optimal role curve can be obtained in real time and based on new inputs. The results indicate that the average error of the optimal role curve extracted from support vector machines is less than 2.5% compared to the role curve obtained from the NSGA-II algorithm in the calibration and validation stages. Therefore, the developed support vector machine model has the ability to quickly provide optimal operation policies in such a way that provides the possibility of optimal management of the system in real time, according to the new data of the inflow to the dam.

Cite this article: Aman Jalili, A., Najarchi, M., Shabanlou, S., & Jafarinia, R. (2023). Extracting the Optimal Role Curve of Dams in Real Time based on the Integration of Meta-Exploration Algorithm and Machine Learning Technique. *Iranian Journal of Soil and Water Research*, 54 (4), 695-712. <https://doi.org/10.22059/ijswr.2023.350224.669380>

© The Author(s).

Publisher: University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2023.350224.669380>



استخراج منحنی فرمان بهینه سد در زمان واقعی بر اساس ترکیب الگوریتم فراکاوشی و تکنیک یادگیری ماشین

احمد امان جلیلی^۱ | محسن نجارچی^۲ | سعید شعبانلو^۳ | رضا جعفری نیا^۴

۱. گروه مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران. رایانامه: ahmad.jalili@gmail.com

۲. نویسنده مسئول، گروه مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران. رایانامه: m-najarchi@iau-arak.ac.ir

۳. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران. رایانامه: saeid.shabanlou@gmail.com

۴. گروه مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران. رایانامه: r-jafarinia@iau-arak.ac

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	استفاده از مدل‌های کوپل شده شبیه‌سازی-بهینه‌سازی برای استخراج منحنی فرمان بهینه سدها یکی از راهکارهای موثر برای مدیریت بهینه مخازن است. در تکنیک بهینه‌سازی معین، معمولاً از داده‌های جریان تاریخی ورودی به مخزن برای استخراج منحنی فرمان بهینه سد استفاده می‌شود. ممکن است در سال‌های آینده با تغییر جریان ورودی به سدها پارامترهایی که بر اساس آن منحنی فرمان بهینه استخراج شده است ممکن است دیگر کارایی نداشته باشد و نتایج خارج از انتظار باشد. هدف از این تحقیق ارزیابی راهکاری برای استخراج منحنی فرمان بهینه در زمان واقعی است طوری که با تغییر جریان ورودی به سد در آینده بدون اجرای مجدد الگوریتم بهینه‌سازی و با استفاده از تکنیک هوش مصنوعی در کمترین زمان، منحنی فرمان بهینه سازگار با شرایط جدید را استخراج کرد. در این تحقیق از ترکیب الگوریتم چندهدفه NSGA-II و مدل شبیه‌ساز WEAP برای استخراج سیاست‌های بهینه بر اساس داده‌های تاریخی استفاده شد. سپس با استفاده از روش ماشین بردار پشتیبان و نتایج حاصل از خروجی الگوریتم بهینه‌سازی ساختار جدیدی توسعه داده شد تا بتوان منحنی فرمان بهینه را در زمان واقعی و بر اساس ورودی‌های جدید بدست آورد. نتایج نشان داد کمترین درصد تامین نیاز کشاورزی مربوط به ماه‌های تیر و مرداد به ترتیب به میزان ۷۷ و ۷۷ درصد و کمترین درصد تامین نیاز زیست‌محیطی مربوط به ماه شهریور و در حدود ۶۴ درصد بود. همچنین منحنی فرمان بهینه مستخرج از ماشین‌های بردار پشتیبان نسبت به منحنی فرمان حاصل از الگوریتم NSGA-II در مرحله واسنجی و صحت‌سنجی دارای میانگین خطای کمتر از ۲/۵ درصد و ضریب تبیین ۰/۹۹ می‌باشد. لذا مدل ماشین بردار پشتیبان توسعه داده شده این قابلیت را داشته که با توجه به داده‌های جدید جریان ورودی به سد، سریعاً سیاست‌های بهره‌برداری بهینه را به نحوی در اختیار قرار دهد که امکان مدیریت بهینه سیستم در زمان واقعی فراهم گردد.
تاریخ دریافت: ۱۴۰۱/۷/۲۹	
تاریخ بازنگری: ۱۴۰۱/۱۲/۱۹	
تاریخ پذیرش: ۱۴۰۱/۲/۴	
تاریخ انتشار: ۱۴۰۲/۴/۱	
واژه‌های کلیدی:	
NSGA-II	
WEAP	
زمان واقعی،	
سد جامیشان،	
ماشین‌های بردار پشتیبان،	

استناد: امان جلیلی؛ احمد، نجارچی؛ محسن، شعبانلو؛ سعید، جعفری نیا؛ رضا، (۱۴۰۲)، استخراج منحنی فرمان بهینه سد در زمان واقعی بر اساس ترکیب الگوریتم فراکاوشی

و تکنیک یادگیری ماشین، مجله تحقیقات آب و خاک ایران، ۵۴ (۴)، ۶۹۵-۱۷۲. <https://doi.org/10.22059/ijswr.2023.350224.669380>



© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2023.350224.669380>

مقدمه

بهره‌برداری اصولی از مخازن و سدهای مخزنی نقش بسیار مهمی را در تأمین آب ایفا می‌نماید و به دلیل این که مقاصد چندگانه‌ای را از لحاظ اقتصادی، اجتماعی و فرهنگی با خود به همراه دارد از اولویت‌های برنامه‌ریزی و مدیریت منابع آب است. در حال حاضر با توجه به کاهش حجم آب ورودی به مخازن در مقایسه با دوره‌های گذشته، به منظور افزایش کارایی استفاده از منابع آب موجود در تأمین اهداف مختلف، کاربرد سیاست‌های بهره‌برداری بهینه از سدهای مخزنی در قالب مدل‌سازی سیستم مخازن چند هدفه در سطح حوضه‌های آبریز، امری ضروری می‌باشد. از جمله ابزارهای مناسب در حوزه مدیریت منابع آب استفاده از روش‌های شبیه‌سازی، بهینه‌سازی و ترکیب شبیه‌سازی-بهینه‌سازی می‌باشد.

بسیاری از مسائل بهینه‌سازی در علوم مهندسی، طبیعتاً پیچیده‌تر و مشکل‌تر از آن هستند که با روش‌های مرسوم بهینه‌سازی، نظیر روش برنامه‌ریزی ریاضی و نظایر آن قابل حل باشند. در این راستا گروهی از الگوریتم‌های تکاملی توسط محققین مختلف توسعه یافته‌اند که اساساً سعی در ترکیب اصول اولیه روش‌های کاوشی و یافتن روش کاوش مؤثر و کارا در فضای جستجو را دارند. امروزه این روش‌ها به نام روش‌های کاوشی مشهورند (Blum & Roli, 2003).

پیشینه پژوهش

الگوریتم ژنتیک در بین الگوریتم‌های تکاملی، به عنوان شناخته‌شده‌ترین روش‌های مورد استفاده، مطرح بوده و در حیطه‌های متفاوت علمی از جمله علوم پایه، اقتصاد، بیولوژی و علوم مهندسی به عنوان ابزاری قدرتمند و مناسب در حل مسائل مختلف بهینه‌سازی است (Wardlaw & Sharif, 1999; Nicklow et al., 2010; Kalita et al., 2014). (Chang et al., 2005). الگوریتم ژنتیک را برای پیدا کردن منحنی فرمان ماهانه بهینه در یک سیستم تک سدی چندهدفه در تایوان به کار بردند. نتایج نشان داد که با استفاده از منحنی فرمان به دست آمده از الگوریتم ژنتیک، نتایج بهتری از لحاظ میزان کمبود در تأمین نیازهای کشاورزی و تولید انرژی برقایی نسبت به منحنی فرمان رایج و سنتی موجود، حاصل خواهد گردید. (Momtahan & Dariane, 2007) در یک سیستم تک مخزنی ساده برای جستجوی مستقیم پارامترهای مربوط به سیاست بهره‌برداری بهینه مخزن از الگوریتم ژنتیک استفاده کردند تا ارتباط بین متغیرهای حالت (حجم مخزن و جریان ورودی) و متغیرهای تصمیم‌گیری (خروجی مخزن) از طریق آن‌ها برقرار شود.

الگوریتم ژنتیک مبتنی بر جواب غیر پست (NSGA-II) که در واقع نوعی الگوریتم ژنتیک چندهدفه محسوب می‌شود در هر گام حل با جمعیتی از جواب‌های ممکن کار می‌کند. به دلیل ساختار مناسب این مدل و گزینش جواب‌های غیر پست در هر بار تکرار معادلات، این الگوریتم دارای سرعت همگرایی بهتری نسبت به مدل الگوریتم ژنتیک معمولی است (Deb et al., 2002; Azari et al., 2018; Zainali et al., 2020). به دلیل ساختار چندهدفه، همچنین به دلیل پیچیدگی مسئله و تعداد متغیرهای تصمیم، در فرآیند بهینه‌سازی در این تحقیق از این روش بهره گرفته شد. (Jian et al., 2005) از الگوریتم ژنتیک چندهدفه، جهت برنامه‌ریزی سیستم‌های چند مخزنه استفاده نمودند و دریافتند که با وجود افزایش تعداد متغیرها و نیز طولانی شدن زمان اجرای برنامه، الگوریتم ژنتیک در حل مسائل با ورودی‌های کم و شرایط پیچیده از پتانسیل بالایی برخوردار می‌باشد. (Goorani & Shabanlou, 2021) برای بهره‌برداری بهینه از سد مارون و استخراج منحنی فرمان بهینه برای تأمین اهداف کمی و کیفی از NSGA-II استفاده کردند. الگوریتم NSGA-II در بسیاری از مسائل چندهدفه سیستم‌های منابع آب مورد استفاده قرار گرفته و باعث بهبود بهره‌برداری از سیستم شده است (Karamian et al., 2023; Zarei et al., 2022; Jalilian et al., 2022).

مطابق با آنچه گفته شد بسیاری از تحقیقات انجام شده بر روی روش‌های بهینه‌سازی بهره‌برداری از مخازن در قالب بهینه‌سازی معین انجام گرفته است. در این نوع از مطالعات یک سری معین از جریان ورودی به مخزن در طول دوره بهره‌برداری در نظر گرفته شده و رهاسازی از مخزن جهت تأمین مصارف پایین‌دست در این شرایط بهینه می‌گردد. اشکال چنین مدل‌هایی این است که جواب‌های بهینه قابل تعمیم برای سایر ورودی‌های محتمل به مخزن نیستند و در صورت تغییر جریان ورودی به مخزن به احتمال زیاد جواب‌های بهینه بدست آمده کارایی نداشته و باید بهره‌برداری از سیستم در قالب الگوریتم بهینه‌ساز مجدداً بهینه گردد. در چنین شرایطی یکی از راهکارها استفاده از ورودی‌های جریان تصادفی در قالب بهینه‌سازی استوکاستیک است (Bayesteh & Azari, 2021). اما در این روش نیز به دلیل تنوع سری‌های جریان ورودی برای جلوگیری از طولانی شدن زمان حل به ناچار باید از تعداد متغیرهای تصمیم به شدت کاسته شود که خود باعث خطاهایی در بهره‌برداری از سیستم در زمان واقعی خواهد شد. راهکار دیگر استفاده از روش‌های هوشمند مانند ماشین‌های بردار

پشتیبان برای بکار بردن نتایج حاصل از بهینه‌سازی سیستم در زمان واقعی است. در بسیاری از تحقیقات روش موسوم به ماشین‌های بردار گرسیون که بر اساس ماشین بردار پشتیبان توسعه یافته است برای پیش‌بینی سری زمانی استفاده شده است. (Thissen *et al.*, (2003) و (Lin *et al.*, (2006) دریافتند که ماشین‌های بردار پشتیبان نسبت به مدل‌های ARMA و شبکه عصبی مصنوعی کارایی بهتری برای پیش‌بینی سری زمانی دارد و نتایج آن به واقعیت نزدیکتر است. (Du *et al.*, (2017) از ترکیب ماشین بردار پشتیبان و الگوریتم ازدحام ذرات برای پیش‌بینی بارندگی سه ساعته ایستگاه هواشناسی واقع در نانجینگ چین استفاده کردند. (Su *et al.*, (2014) از GA-SVM برای پیش‌بینی حجم ذخیره ماهیانه مخزن Miyun در چین استفاده کردند. مدل ترکیبی GA-SVM توسط برخی محققان برای افزایش دقت پیش‌بینی پارامترهای هیدرولوژیکی و برنامه ریزی منابع آب استفاده شده است (Lei *et al.* 2021; Huang *et al.* 2021; Yadav *et al.* 2022). استفاده از مدل‌های مبتنی بر هوش مصنوعی همواره یکی از روش‌های پرکاربرد برای افزایش دقت پیش‌بینی پارامترهای مختلف هیدروکلیماتولوژی بوده است (Soltani and Azari, 2022; Azari *et al.*, 2021; Soltani *et al.*, 2021; Fatemi *et al.*, 2022).

نوآوری تحقیق حاضر، استفاده تلفیقی از الگوریتم چندهدفه NSGA-II و مدل SVM برای بهره‌برداری بهینه از سیستم‌های منابع آب در زمان واقعی است. بر اساس این نوآوری، قوانین بهره‌برداری از منحنی فرمان سد در زمان آینده بر اساس داده‌های جدید و بصورت آنی قابل استخراج خواهد بود و نیاز به اجرای مجدد الگوریتم بهینه‌ساز نیست. بر اساس بررسی‌های صورت گرفته نویسندگان این تحقیق ترجیح دادند برای بهینه‌سازی سیستم بجای داده‌های تصادفی و یا احتمالاتی، از داده‌های مشاهداتی ثبت شده در ایستگاه هیدرومتری واقع در نزدیکی ورودی به سد استفاده کنند. در این صورت پس از اتمام الگوریتم و استخراج متغیرهای بهینه، ارتباط معناداری بین جریان‌ات ماهیانه ورودی به مخزن، حجم ذخیره آب در مخزن، تغییرات حجم مخزن و نیازهای پایین دست (به عنوان متغیرهای مستقل) و متغیر میزان رهاسازی بهینه (به عنوان متغیر وابسته) وجود خواهد داشت. لذا هدف اصلی این تحقیق تلفیق مدل ماشین بردار پشتیبان با الگوریتم بهینه‌سازی NSGA-II برای بهره‌برداری بهینه از سیستم در زمان واقعی می‌باشد. به این معنا که در هر دوره شبیه‌سازی آبی با مشخص بودن چهار پارامتر اول در ابتدای هر ماه مقدار رهاسازی بهینه در زمان واقعی مشخص خواهد شد. در این ساختار برخلاف ساختار رایج برنامه ریزی معین، در صورت تغییر جریان ورودی نیازی به انجام بهینه‌سازی مجدد برای فهمیدن ضرایب بهینه نیست بلکه با استفاده از رابطه مستخرج از روش ماشین بردار پشتیبان می‌توان بر اساس جریان ورودی به مخزن (در ابتدای ماه)، حجم ذخیره آب در مخزن (در ابتدای ماه) و تغییرات ذخیره مخزن و نیازهای پایین دست در ماه حاضر، مقدار رهاسازی بهینه را در زمان واقعی بدست آورد.

روش شناسی پژوهش

منطقه مورد مطالعه

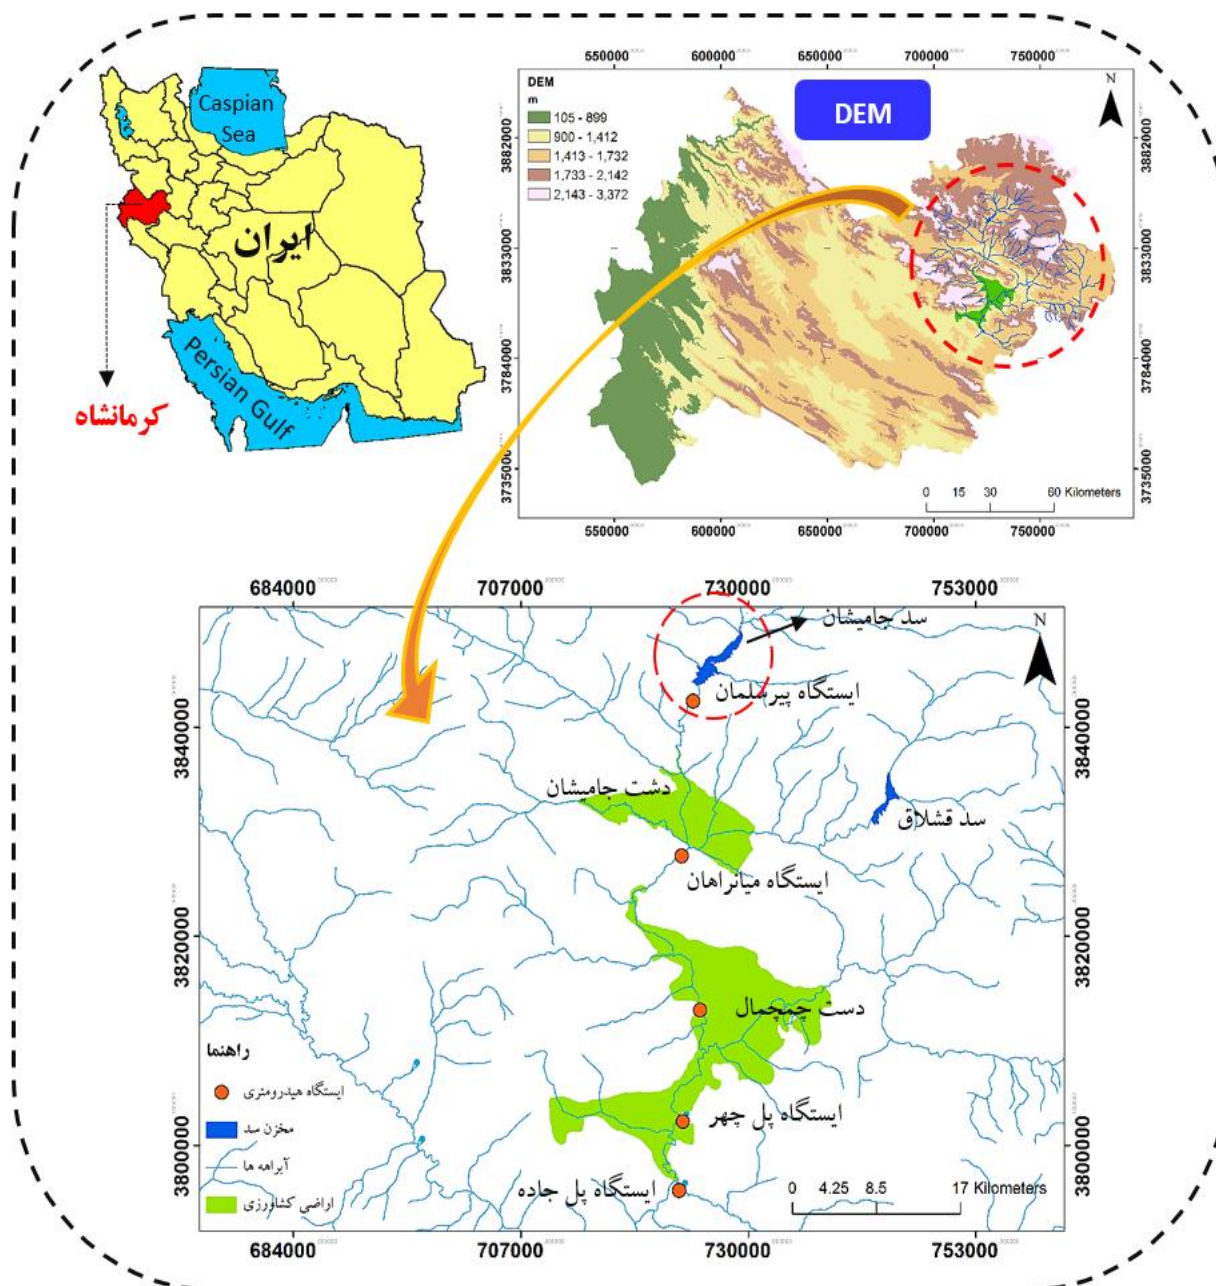
سد جامیشان بر روی رودخانه جامیشان واقع در غرب ایران است. سد جامیشان با مختصات جغرافیایی ۴۷ درجه و ۵۰ دقیقه شرقی و ۳۴ درجه و ۵۴ دقیقه شمالی در فاصله ۸/۵ کیلومتری شهر سنقر قرار دارد. این سد از نوع سنگریزه ای با هسته رسی با سرریز اوجی، ارتفاع ۵۸ متر و حجم مخزن ۶۲/۸ میلیون مترمکعب است که در سال ۱۳۹۴ مورد بهره‌برداری قرار گرفت. مهمترین اهداف سد مخزنی جامیشان، کنترل سیلاب‌های فصلی، تأمین آب بخشی از اراضی کشاورزی جامیشان و چمچمال واقع در پائین دست و همچنین حفظ شرایط زیست محیطی رودخانه جامیشان است. ایستگاه هیدرومتری پیرسلیمان در نزدیکی محل احداث سد جامیشان و بر روی این رودخانه قرار گرفته است که از داده‌های آن به عنوان جریان ورودی به مخزن سد استفاده شد. موقعیت منطقه مطالعاتی در شکل (۱) نشان داده شده است.

شبیه‌سازی سیستم

برای شبیه‌سازی سیستم از مدل برنامه ریزی منابع آب WEAP استفاده شد. ساختار WEAP براساس معادلات پایه بیان آبی عمل کرده و آن را می‌توان در بهره‌برداری از سدها، سیستم‌های شهری و کشاورزی، حوضه‌های مستقل یا سیستم‌های رودخانه‌ای مرزی پیچیده به کار برد. علاوه بر این، WEAP می‌تواند طیف گسترده‌ای از اجزای طبیعی و مهندسی سیستم‌ها، از جمله بارش-رواناب، جریان پایه و تغذیه آب‌های زیرزمینی از بارش را شبیه‌سازی کند.

در مدل WEAP با استفاده از ابزارهای موجود و با توجه به نقشه‌های پایه GIS، مسیر رودخانه‌ها، محل ایستگاه‌های هیدرومتری،

محل سد، کانال‌های برداشت آب، گره مربوط به شهرها و مصارف و غیره رقومی شدند. گام‌های زمانی شبیه‌سازی، ماهیانه در نظر گرفته شد. سری‌های زمانی داده‌های ثبت شده هیدرولوژیکی و اطلاعات مربوط به نیاز ماهیانه مصارف، اطلاعات مخازن و محل‌های برداشت، ضرایب و پارامترهای مورد نیاز و غیره به صورت فایل‌های متنی با پسوند CSV به مدل معرفی شدند. سپس اطلاعات بهره‌برداری سد جامیشان مطابق با جدول (۱) در مدل وارد شد.

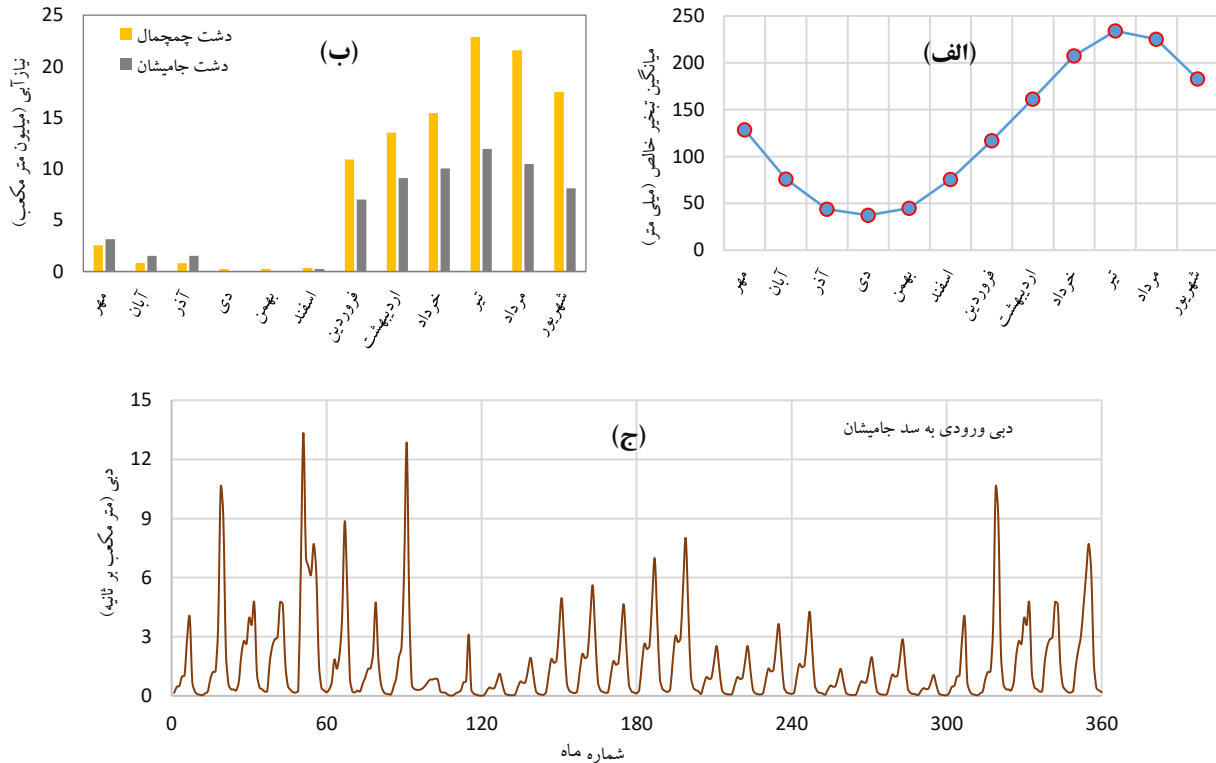


شکل ۱. موقعیت محدوده مطالعاتی، سد، رودخانه‌ها و مصارف کشاورزی

جدول ۱. مشخصات بهره‌برداری از سد جامیشان

سد جامیشان	پارامتر
۱۵۸۷	تراز حداکثر (متر)
۶۲/۸	حجم مخزن در تراز حداکثر (میلیون مترمکعب)
۹/۶۲	حجم غیر فعال (میلیون مترمکعب)
۵۳/۱۸	حجم فعال (میلیون مترمکعب)

با توجه به داده‌های تبخیر سطحی مخازن سد جامیشان و قشلاق و با در نظر گرفتن میزان بارندگی، تبخیر خالص از سطح آزاد مخازن محاسبه شد که در شکل ۲.الف نشان داده شده است. نیاز آبی اراضی دشت‌های چمچمال و جامیشان محاسبه شده و در مدل وارد شد. متوسط آب مورد نیاز این دشت‌ها در کل دوره در شکل ۲.ب نشان داده شده است. همچنین مقادیر آبدهی ورودی به مخزن سد در طول دوره شبیه‌سازی در مدل تعریف شد (شکل ۲.ج)



شکل ۲.الف) متوسط تبخیر خالص از مخزن سد جامیشان (میلی متر) (ب) نیاز آبی دشت (میلیون متر مکعب) (ج) جریان ماهیانه ورودی به سد جامیشان (متر مکعب بر ثانیه)

به منظور تعیین جریان زیست‌محیطی پایین‌دست رودخانه، نیاز مربوط به حداقل دبی زیست‌محیطی در پایین‌دست منطقه مورد مطالعه در مدل تعریف شد. جریان زیست‌محیطی بر اساس جریان رودخانه برآورد شد. روش تنانت برای تخمین حداقل جریان زیست‌محیطی پایین‌دست استفاده شد (Tennant, 1976). روش تنانت یا مونتاناز جمله روش‌های درجه‌بندی هیدرولوژیکی محسوب می‌شود که برای تخمین حداقل جریان زیست‌محیطی رودخانه‌ها مورد استفاده قرار می‌گیرد. این روش در نشریه ۵۵۷ وزارت نیرو که در سال ۱۳۹۰ منتشر گردیده، بیان شده است. مطابق با این روش، حداقل جریان زیست‌محیطی در ماه‌های مختلف به صورت جدول (۲) در نظر گرفته می‌شود. در این تحقیق شرایط عادلانه برای اعمال جریان زیست‌محیطی در نظر گرفته شد.

جدول ۲. حداقل جریان زیست‌محیطی در طول سال طبق روش تنانت


وضعیت رودخانه	پاییز -	بهار - تابستان
بسیار عالی	۴۰	۶۰
عالی	۳۰	۵۰
خوب	۲۰	۴۰
عادلانه	۱۰	۳۰
ضعیف	۱۰	۱۰
تخریب شدید	۱۰ >	۱۰ >

حداقل جریان زیست‌محیطی رودخانه که با استفاده از روش فوق در گره‌های مورد نظر به دست آمد، به ترتیب ۱۰ و ۳۰ درصد دبی

سالانه در نیمه اول و دوم سال (اکتبر تا سپتامبر) بود.

ساختار مدل بهره‌برداری چندهدفه پیشنهادی

در این تحقیق از مدل الگوریتم ژنتیک مبتنی بر جواب غیر پست (NSGA-II) استفاده گردید که به صورت چند هدفه تدوین شده است. به این ترتیب که در آن هدف اول، حداکثر نمودن اطمینان‌پذیری تأمین نیازهای طرح در طی دوره برنامه‌ریزی در مقابل هدف دوم، یعنی حداقل نمودن افت تراز آب زیرزمینی در پایان دوره بهره‌برداری قرار می‌گیرد. برای درک بهتر موضوع ساختار اصلی این مدل در شکل (۳) نشان داده شده است.



شکل ۳- ساختار اصلی مدل بهینه‌سازی چند هدفه (NSGA-II) (Deb et al. 2002)

توابع هدف و محدودیت‌های مطالعه بصورت زیر تعریف گردیدند.

توابع هدف:

۱- حداکثر نمودن درصد تأمین نیاز مصارف در کل دوره t

$$F_1 = \text{Maximize (coverage)} = \text{Maximize} \left(\sum_{t=1}^n \sum_{z=1}^k \sum_{d=1}^{nd} \text{COV}_{tzd} \right) \text{ or } \text{Minimize} \left(\sum_{t=1}^n \sum_{z=1}^k \sum_{d=1}^{nd} \left(\frac{100 - \text{COV}_{tzd}}{100} \right) \right) \quad (\text{رابطه ۱})$$

$$\text{COV}_{tzd} = \left(\frac{\text{TAW}_{tzd}}{\text{DM}_{tzs}} \right) * 100 \quad \text{که در آن:}$$

COV_{tzd} : درصد تأمین نیاز نوع d در دوره t از منطقه z

DM_{tzs} : نیاز آبی بخش d در دوره t از منطقه z

TAW_{tzs} : میزان کل آب تخصیص داده شده به بخش d در دوره t از منطقه z

۲- حداقل نمودن افت تراز آب زیرزمینی در کل دشت در طول دوره بهره‌برداری

$$F_2 = \text{Minimize} \left(\sum_{t=1}^n \sum_{i=1}^r \sum_{j=1}^c \frac{\text{InitialHead}_{(i,j,t)} - \text{CellHead}_{(i,j,t)}}{\text{InitialHead}_{(i,j,t)} - \text{Bottom}_{(i,j)}} \right) \quad (\text{رابطه ۲})$$

که در آن:

$\text{InitialHead}_{(i,j,t)}$: تراز سطح آب زیرزمینی در سلول i, j در ابتدای دوره بهره‌برداری (t = 1)

$\text{CellHead}_{(i,j,t)}$: تراز سطح آب زیرزمینی در سلول i, j در انتهای دوره بهره‌برداری (t = n)

$\text{Bottom}_{(i,j)}$: تراز سنگ کف آبخوان در سلول i, j

محدودیت‌ها

$$\text{TAW}_{tzd} = \text{RS}_{tzd} + \text{RG}_{tzd} \quad , \quad t = 1, \dots, m \times y \quad , \quad z = 1, \dots, nz \quad , \quad d = 1, \dots, nd \quad (\text{رابطه ۳})$$

RS_{tzd} : حجم کل آب سطحی تخصیص داده شده به بخش d در دوره t از منطقه z

RG_{tzd} : حجم کل آب زیرزمینی تخصیص داده شده به بخش d در دوره t از منطقه z

n_z : تعداد مناطق نیاز

nd : تعداد بخش‌های مصرف کننده آب در هر منطقه نیاز

m : تعداد دوره‌های برنامه‌ریزی در هر سال

U : تعداد سال‌های دوره برنامه‌ریزی

$$TSR_t = R_p + R_L + R_{e-r} \quad \text{رابطه (۴)}$$

TSR_t : میزان کل آب سطحی تخصیص داده شده در دوره t

R_p : حجم آب برداشتی از سد جامیشان برای اراضی چمچمال در دوره t

R_L : حجم آب برداشتی از سد جامیشان برای اراضی جامیشان در دوره t

R_{e-r} : آب تخصیص داده شده برای مصارف زیست‌محیطی

$$ARS_{tzd} = \begin{cases} DM_{tzd} & \text{if } \left(TSR_t - \sum_{z=1}^{z-1} \sum_{d=1}^d DM_{tzd} - \sum_{z=1}^z \sum_{d=1}^{d-1} DM_{tzd} \right) \geq DM_{tzd} \\ \left(TSR_t - \sum_{z=1}^{z-1} \sum_{d=1}^d DM_{tzd} - \sum_{z=1}^z \sum_{d=1}^{d-1} DM_{tzd} \right) & \text{otherwise} \end{cases} \quad \text{رابطه (۵)}$$

$$Z = IZ(1), \dots, IZ(nz) \quad d = Id(1), \dots, Id(nd)$$

ARS_{tzd} : میزان کل آب سطحی تخصیص داده شده به بخش d در دوره t از منطقه z (با در نظر گرفتن اولویت‌های منابع تامین و اولویت نیاز مصارف)

$$TDF_{tzd} = DM_{tzd} - ARS_{tzd} \quad \text{رابطه (۶)}$$

$$ARG_{tzd} = \begin{cases} TDF_{tzd} & \text{if } \left(G_{t-\max} - \sum_{z=1}^z \sum_{d=1}^{d-1} TDF_{tzd} \right) \geq TDF_{tzd} \\ \left(G_{t-\max} - \sum_{z=1}^z \sum_{d=1}^{d-1} TDF_{tzd} \right) & \text{otherwise} \end{cases} \quad \text{رابطه (۷)}$$

$$Z = IZ(1), \dots, IZ(nz) \quad d = Id(1), \dots, Id(nd)$$

TDF_{tzd} : حجم کل کمبود آب بخش d در دوره t از منطقه z

$G_{t-\max}$: حد مجاز برداشت ماهانه از منبع آب زیرزمینی (این حد طوری در نظر گرفته شده که حداکثر برابر برداشت فعلی باشد و از این مقدار تجاوز نکند)

یکی دیگر از محدودیت‌های بهینه‌سازی اولویت تأمین می‌باشد که در طول دوره شبیه‌سازی ابتدا از آب سطحی و سپس از آب زیرزمینی تأمین می‌شود. با توجه به تعداد زیاد متغیرهای پیش رو، حجم بالای محاسبات در مدل تلفیقی آب سطحی و زیرزمینی در محدوده مطالعاتی، در بدنه مدل بهینه‌سازی NSGA-II، از ضرایب مدیریتی برداشت (α) استفاده شد. مقادیر α در اصل درصد برداشت از آب زیرزمینی در هر یک از ماه‌های سال است و برای ۱۲ ماه مختلف ۱۲ ضریب به عنوان متغیر تصمیم‌گیری در نظر گرفته شد. این ضرایب بصورت ماهیانه، در طول ۳۶۰ ماه دوره بهینه‌سازی بعنوان درصد تأمین نیاز از آب زیرزمینی معرفی شده و در طول دوره تکرار شدند. با بدست آمدن مقادیر بهینه درصد تأمین نیاز از آب زیرزمینی (α)، درصد تأمین نیاز از آب سطحی ($1 - \alpha$) نیز بدست می‌آید. پس از اجراهای متوالی مدل و بررسی نحوه همگرایی الگوریتم NSGAII در حل مسئله بهره‌برداری بهینه از سد جامیشان، پارامترهای بهینه تنظیم شده برای اجرای الگوریتم بصورت جدول (۳) در نظر گرفته شد.

جدول ۳. پارامترهای نهایی تنظیم شده در بدنه الگوریتم NSGAI

پارامتر	مقدار
تعداد تکرار	۱۰۰۰
جمعیت اولیه	۳۴
درصد تقاطع	۰/۹
درصد جهش	۰/۰۵
تعداد متغیرهای تصمیم	۱۲

هدف از اجرای مدل بهینه‌ساز نیز یافتن جواب‌های بهینه برای این متغیرها در طول دوره بهره‌برداری ۳۰ سال آبی می‌باشد طوری که بر اساس تابع چندهدفه تعریف شده در الگوریتم NSGA-II، علاوه بر بیشینه نمودن درصد تامین نیاز تمامی مصارف، میزان افت آب زیرزمینی در این دشت نیز حداقل گردد. در این صورت با معلوم شدن مقادیر بهینه درصد تامین نیاز از آب سطحی، درصد تامین از آب زیرزمینی نیز مشخص خواهد شد و بر این اساس میزان جریان رهاسازی بهینه از سد جامیشان در ماه‌های مختلف بدست می‌آید.

ماشین‌های بردار پشتیبان

نتایج بهینه‌سازی منجر به استخراج میزان رهاسازی بهینه سد یا منحنی فرمان بهینه بر اساس جریان‌ات ورودی ثبت شده می‌گردد. در بهره‌برداری واقعی از سیستم مخازن، بهره‌برداران معمولاً از منحنی‌های فرمان پیروی می‌کنند که با استفاده از آن می‌توانند در شرایط مختلف، تصمیم نسبتاً صحیحی را برای بهره‌برداری از مخازن اتخاذ نمایند. منحنی فرمان بیانگر مقدار تخلیه مورد نظر از مخزن یا حجم ذخیره مخزن در یک بازه مشخص از سال (معمولاً ماه) است. همچنین منحنی‌های فرمان بهره‌برداری یک سری قواعد مشخص و ثابت را در اختیار بهره‌بردار قرار می‌دهد تا بتواند با توجه به آن و پیش‌بینی جریان‌های آبی، تصمیم‌گیری مناسبی را در مورد رهاسازی‌های در زمان واقعی اتخاذ نماید. لذا برای استفاده از نتایج بهینه‌سازی در زمان واقعی از روش ماشین‌های بردار پشتیبان در این تحقیق استفاده شد. ماشین‌های بردار پشتیبان یک روش یادگیری است که در اصل بر اساس یک مدل آماری برای دسته‌بندی داده‌ها توسعه یافت (Vapnic and Cortes, 1995). بعدها این مدل تحت عنوان ماشین‌های بردار رگرسیون برای حل مسائل رگرسیونی، تشخیص الگوی سری‌های زمانی و پیش‌بینی داده بکار گرفته شد (Smola and Schölkopf, 2004).

در حالت کلی یادگیری به دو شکل نظارت شده و نظارت نشده انجام می‌شود. در بسیاری از روش‌های یادگیری نظارت شده مجموعه‌ای از بردارهای ورودی مانند $X = \{x_n\}$ و بردارهای خروجی متناظر با آن‌ها $Y = \{y_n\}$ داده می‌شود. هدف این است که ماشین قادر باشد با استفاده از این داده‌های آموزشی برای ورودی x جدید، خروجی y را پیش‌بینی نماید (کاندلا و هانسن، ۲۰۰۲). در فرآیند یادگیری ابتدا سیستم تعلیم یافته و سپس به ازای مقادیر ورودی جدید آزمایش می‌شود. به شکل ریاضی مسئله یادگیری ماشین بردار رگرسیون را می‌توان به شکل یک نگاهت در فضای پیوسته در نظر گرفت که طی آن بردار n بعدی x به عنوان ورودی منجر به ایجاد یک بردار y به عنوان خروجی یا هدف می‌شود که هر دو عضو مجموعه اعداد حقیقی هستند در حالی که در مدل SVM بردار خروجی عضو مجموعه باینری است. ابتدا طبق رابطه (۸) تابع Φ تعریف می‌شود (زی و همکاران، ۲۰۰۷):

$$\Phi: X \rightarrow H \quad ; \quad x \rightarrow z = \Phi(x) \quad \text{رابطه (۸)}$$

در این تابع X مجموعه ورودی‌هاست که شامل بردارهای ورودی x_i است. H فضای مشخصه است که شامل مجموعه بردارهای z می‌باشد. در فضای مشخصه یک تابع خطی بصورت رابطه (۹) بر داده‌ها برازش داده می‌شود.

$$f(z) = w \cdot z + b \quad \text{رابطه (۹)}$$

در صورتی که داده‌ها در فضای ورودی اولیه به شکل خطی جداپذیر نباشند ماشین بردار پشتیبان فضای اولیه را به فضای مشخصه با ابعاد بالاتر تبدیل می‌کند. این تبدیل توسط تابع تصویر کننده (کرنل) غیرخطی k انجام می‌شود تابع غیرخطی k بصورت زیر تعریف می‌شود و حاصل ضرب داخلی توابع Φ است.

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) = z_i \cdot z_j \quad \text{رابطه (۱۰)}$$

یکی از توابع کرنل پرکاربرد که در این تحقیق از آن استفاده شده تحت عنوان تابع گوسی بصورت رابطه (۱۱) تعریف می‌شود.

$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}} \quad \text{رابطه (۱۱)}$$

پس از مرحله تبدیل غیرخطی، ماشین‌های بردار پشتیبان در این فضای مشخصه جدید یک ابر صفحه جداساز بهینه با حداکثر حاشیه اطمینان را جستجو می‌کنند. در پیش‌بینی سری زمانی در ماشین بردار پشتیبان رابطه (۱۲) باید کمینه گردد:

$$\min \frac{1}{2} \|w\|^2 + \frac{C}{m} \sum_{i=1}^m l(y_i, f(z)) \quad \text{رابطه ۱۲}$$

که $l(y_i, f(z))$ تابع هزینه بر اساس مقدار تخطی از خطای مجاز ε است که از رابطه (۱۳) بدست می‌آید.

$$l(y_i, f(z)) = |y - f(z)|_\varepsilon = \max\{0, |y - f(z)| - \varepsilon\} \quad \text{رابطه ۱۳}$$

ترم $\frac{1}{2} \|w\|^2$ در اصل با کمینه کردن وزن‌های لایه‌ها که اعداد حقیقی می‌باشند سعی می‌کند مدل را تا حد امکان ساده‌سازی کند. M تعداد داده‌های مورد استفاده در مرحله آموزش است و C یک پارامتر تنظیمی تحت عنوان ضریب تابع هزینه است.

رابطه (۱۲) می‌تواند به شکل رابطه (۱۴) بیان شود که باید با توجه به محدودیت‌های رابطه (۱۵) بهینه گردد:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \quad \text{رابطه ۱۴}$$

$$\text{Subject to } \begin{cases} y_i - wx_i - b \leq \varepsilon + \xi_i \\ wx_i + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad \text{رابطه ۱۵}$$

که ξ_i و ξ_i^* متغیرهای کمبود، y_i مقدار سری زمانی مشاهداتی و $w x_i + b$ مقدار سری زمانی پیش‌بینی شده است. در نهایت پس از تعیین ضرایب و تابع کرنل مناسب پیش‌بینی سری زمانی توسط رابطه (۱۶) صورت می‌گیرد.

$$y = \sum_{i=1}^n (\alpha_i^+ - \alpha_i^-) K(x_i, x) + b \quad \text{رابطه ۱۶}$$

که b مقدار عرض از مبدا یا مقدار اریب مدل و α_i ضرایب لاگرانژ و $\alpha_i^+ - \alpha_i^-$ وزن تابع کرنل در هر لایه i در کل فضای مشخصه می‌باشد.

مرحله آخر این تحقیق، تلفیق مدل ماشین بردار پشتیبان با الگوریتم بهینه‌سازی NSGA-II برای دستیابی به قواعد بهره‌برداری از سیستم در زمان واقعی می‌باشد. به این معنا که پس از استخراج مقادیر رهاسازی بهینه از سد توسط الگوریتم NSGA-II، در هر دوره شبیه‌سازی آتی به کمک ماشین بردار پشتیبان و استفاده از نتایج الگوریتم بهینه‌سازی، با مشخص بودن چهار پارامتر جریان‌ات ماهیانه ورودی به مخزن، حجم ذخیره آب در مخزن، تغییرات حجم مخزن و نیازهای پایین دست در ابتدای هر ماه به عنوان لایه‌های ورودی، مقادیر رهاسازی بهینه در زمان واقعی به عنوان لایه خروجی پیش‌بینی خواهد شد. در بدنه مدل هوش مصنوعی (SVM) ابتدا داده‌های مورد استفاده با استفاده از توابع نرمال‌سازی به اعدادی بین صفر و یک تبدیل شد. پس از اجرای مدل مقادیر پیش‌بینی شده با استفاده از تابع معکوس نرمال‌سازی به مقادیر واقعی تبدیل شد. برای مقایسه مقادیر شبیه‌سازی شده توسط مدل SVM و مقادیر مشاهداتی (خرنجی الگوریتم بهینه‌سازی) از شاخص‌های RMSE، NRMSE، NASH و R استفاده شد که در روابط (۱۷) تا (۲۰) نشان داده شده‌اند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i^{obs} - X_i^{sim})^2} \quad \text{رابطه ۱۷}$$

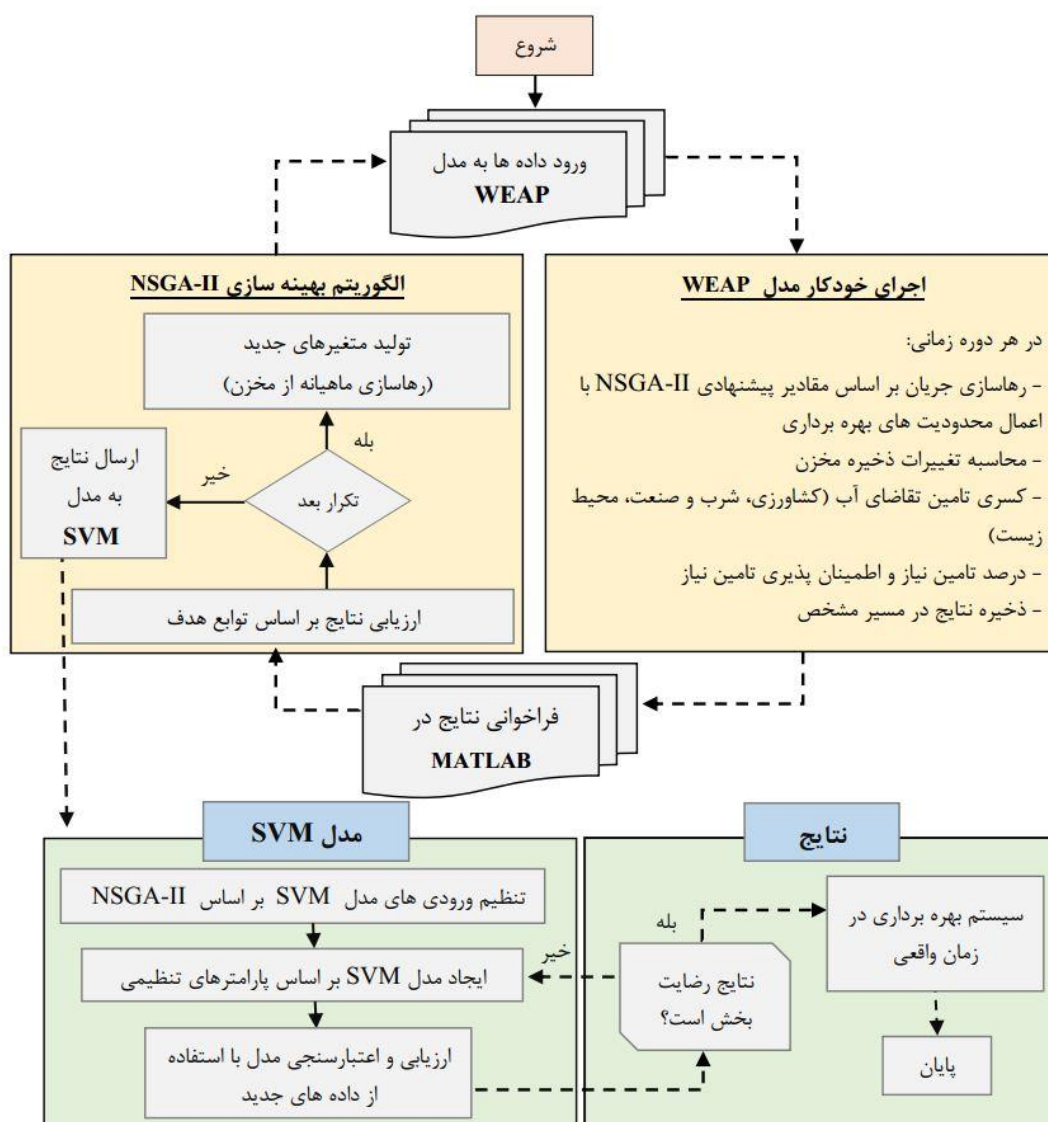
$$NRMSE = \frac{RMSE}{(X_{Max}^{obs} - X_{Min}^{obs})} \quad \text{رابطه ۱۸}$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^n (X_i^{obs} - X_i^{sim})^2}{\sum_{i=1}^n (X_i^{obs} - X_{Mean}^{obs})^2} \right] \quad \text{رابطه ۱۹}$$

$$R = \left(\frac{\sum_{i=1}^n (X_i^{obs} - X_{Mean}^{obs})(X_i^{sim} - X_{Mean}^{sim})}{\sqrt{\sum_{i=1}^n (X_i^{obs} - X_{Mean}^{obs})^2 \sum_{i=1}^n (X_i^{sim} - X_{Mean}^{sim})^2}} \right) \quad \text{رابطه ۲۰}$$

که X_i^{obs} داده‌های مشاهداتی (خروجی الگوریتم بهینه‌سازی)، X_i^{sim} داده‌های شبیه‌سازی شده توسط مدل SVM، X_{Mean}^{sim} و

X_{Mean}^{sim} میانگین داده‌های مشاهداتی و شبیه‌سازی شده و n تعداد داده‌های مشاهداتی است. فلوجارت مراحل انجام کار در شکل (۴) نشان داده شده است.

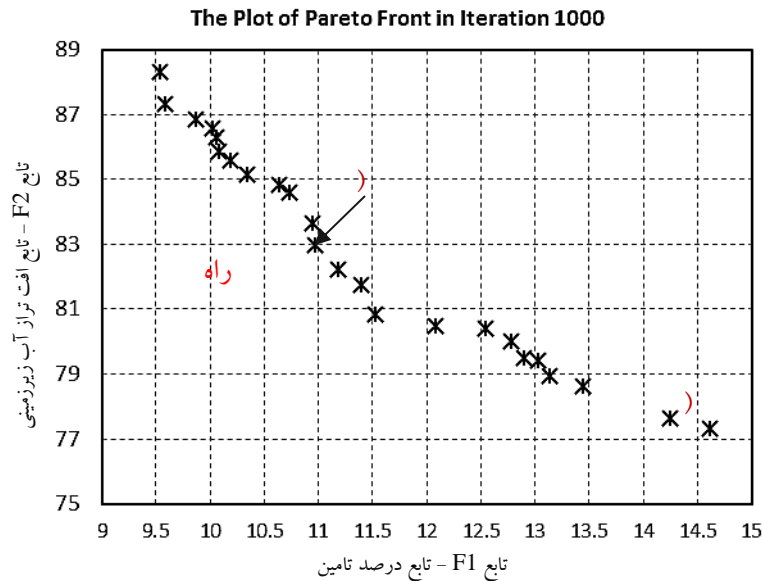


شکل ۴. فلوجارت مراحل ترکیب نتایج الگوریتم NSGA-II با ماشین‌های بردار پشتیبان

یافته‌های پژوهشی


نتایج حاصل از روش بهینه‌سازی

در سناریوی بهینه، اجراهای مکرر مدل نشان داد برای رسیدن به نتایج بهتر، جمعیت اولیه کروموزوم‌ها باید حداقل دو برابر تعداد متغیرهای تصمیم باشد که در این تحقیق تعداد جمعیت اولیه در مدل در حدود ۲۴ انتخاب شد. نتایج نشان داد که در تکرارهای پایین‌تر میزان تابع درصد تامین نیاز (فرمول (۱)) و تابع افت آب زیرزمینی (فرمول (۲))، هر دو تغییرات محسوس دارند. اما در تکرارهای بالاتر، مدل بر روی کاهش افت آب زیرزمینی متمرکز شده است. با توجه به پیچیدگی مسأله و تعداد متغیرهای زیاد، تعداد تکرار الگوریتم برای رسیدن به همگرایی در حدود ۱۰۰۰ در نظر گرفته شد. در نهایت پس از انجام بهینه‌سازی منحنی تبادل بهینه بین اهداف بهینه‌سازی به دست آمد. مطابق با روش الگوریتم ژنتیک مبتنی بر جواب غیر پست، در هر تکرار بهترین جواب‌ها بر اساس ارزش‌گذاری توابع هدف و فرآیند نخبه‌گرایی انتخاب می‌شوند و تحت عنوان مجموعه بهینه F_1 برای انتقال به نسل بعد ذخیره می‌گردند. نقاط ترسیم شده در گراف پارتو همان جواب‌های بهینه مدل بوده و محورهای این گراف توابع هدف مورد نظر می‌باشند. این منحنی بر اساس مجموعه ۲۴ جواب بهینه بر اساس توابع هدف F_1 و F_2 در آخرین تکرار در شکل (۵) نشان داده شده است.



شکل ۵. منحنی تبادل بهینه بین اهداف بهینه‌سازی (منحنی پارتو) در تکرار ۱۰۰۰

در آخرین تکرار مدل، ۲۴ راه حل بهینه ارائه شد که پس از اجرای تمامی این راه حل‌ها و مقایسه آنها، از بین آن‌ها با توجه به ارزش گذاری توابع هدف، راه حلی که هم زمان دارای کم‌ترین میزان تابع افت آب زیرزمینی و بیش‌ترین میزان درصد تامین نیازها بود (پاسخ شماره ۱۲) به عنوان جواب برتر انتخاب شد. متغیرهای بهینه حاصل از راه حل شماره ۱۲ در مدل آب سطحی WEAP وارد شده و نتایج حاصل از آن بررسی شد. نتایج مربوط به درصد‌های تامین و اطمینان‌پذیری نیازها در صورت استفاده از این راه حل بهینه در شکل (۶) نشان داده شده است.

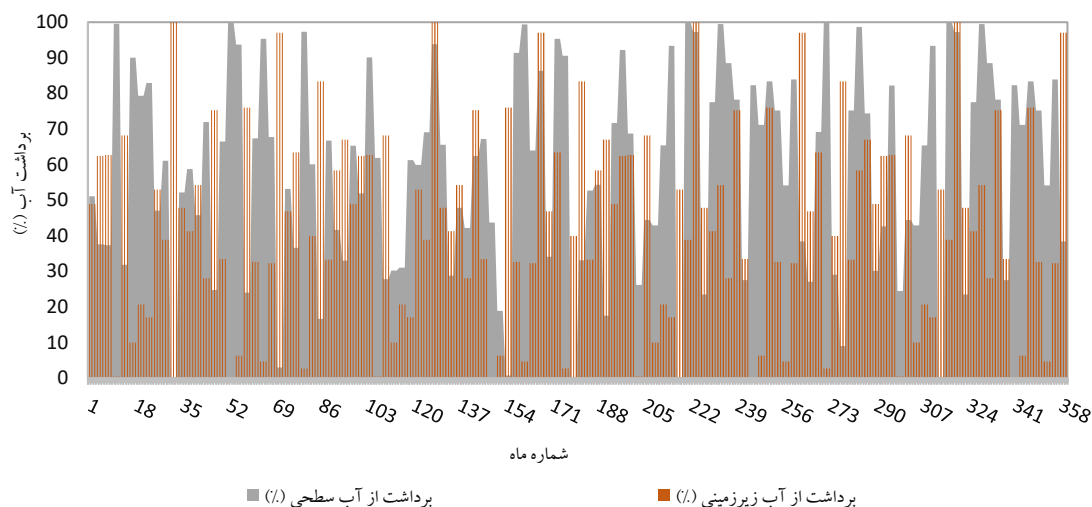


شکل ۶- میانگین شاخص‌های درصد تامین و اطمینان‌پذیری نیازها (راه حل بهینه)

شکل (۶) درصد تامین نیاز و اطمینان‌پذیری نیازهای کشاورزی و زیست‌محیطی را بعد از استفاده از متغیرهای تصمیم بهینه حاصل از الگوریتم بهینه‌سازی NSGA-II در بدنه مدل شبیه‌ساز WEAP نشان می‌دهد. این شکل نشان می‌دهد تامین نیاز اراضی دشت‌های مورد مطالعه در بیشتر ماه‌ها به طور کامل و در حد مطلوب می‌باشد.

با توجه به تعداد بیشتر چاه‌ها در دشت چمچمال، درصد برداشت بهینه از منابع آب سطحی و زیرزمینی در دشت چمچمال در طول دوره بهره‌برداری (۳۰ سال) در شکل (۷) نشان داده شده است. همانطور که در شکل ۷ نشان داده شده است، با توجه به اولویت برداشت از منابع تعریف شده در مدل بهره‌برداری که ابتدا از آب سطحی و سپس از آب زیرزمینی است در دوره‌های تر سالی بیشتر درصد برداشت از آب سطحی بوده و در دوره‌های کم آب بیشتر درصد برداشت از آب زیرزمینی می‌باشد. لازم به ذکر است با در نظر گرفتن کل دوره ۳۶۰ ماهه برنامه ریزی درصد برداشت از منابع آب سطحی و زیرزمینی در دشت چمچمال به ترتیب ۵۷ و ۴۳ درصد و در دشت جامیشان به

ترتیب ۸۰ و ۲۰ درصد است.



شکل ۷. مقادیر بهینه درصد برداشت از هر کدام از منابع آب سطحی و زیرزمینی در طول دوره بهره‌برداری در دشت چمچمال

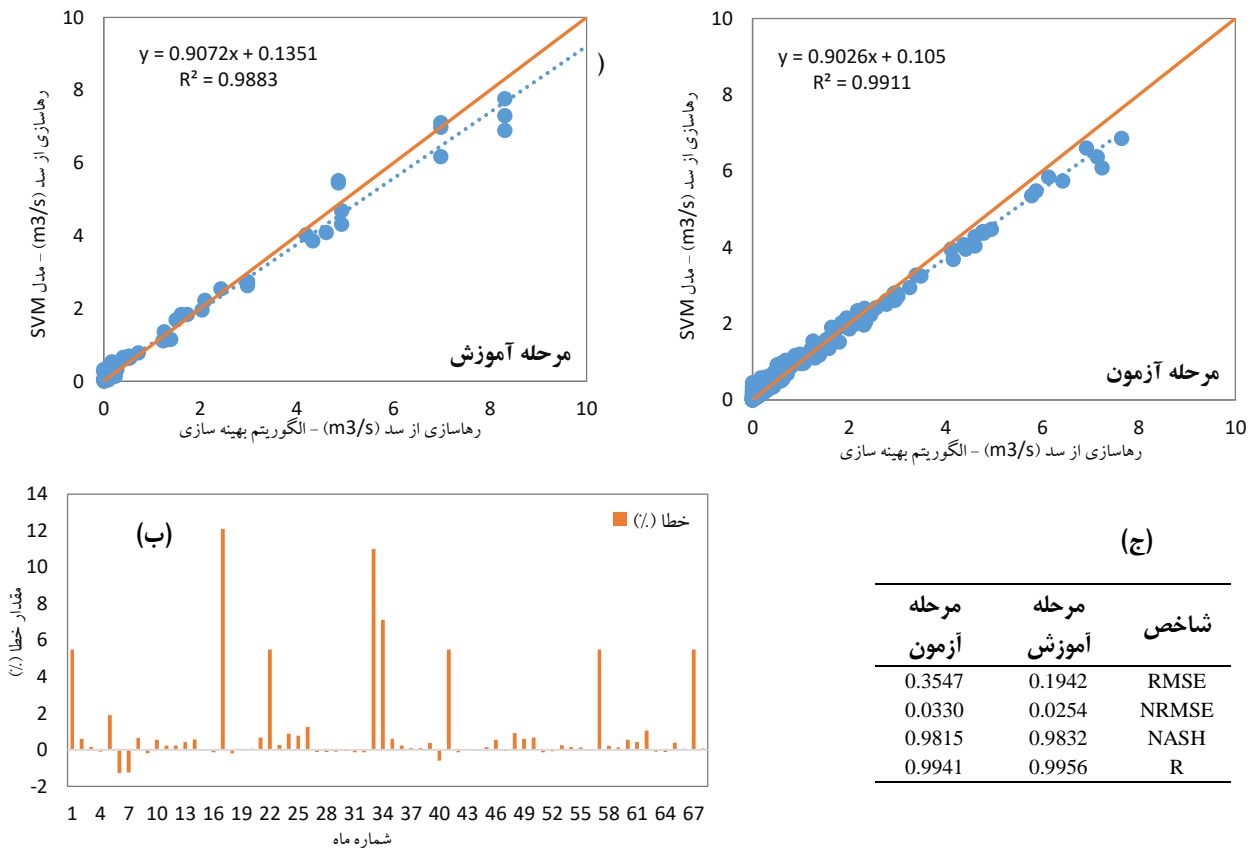
نتایج حاصل از روش ماشین‌های بردار پشتیبان

در این تحقیق برای استفاده از نتایج بهینه‌سازی در زمان واقعی از روش هوشمند ماشین‌های بردار پشتیبان استفاده شد. ابتدا ماشین‌های بردار پشتیبان بر اساس خروجی الگوریتم بهینه‌سازی و برای یک دوره ۲۸۸ ماهه آموزش داده شد. سپس برای یک دوره ۷۲ ماهه از داده‌ها که در مرحله آموزش از آنها استفاده نشده بود صحت‌سنجی صورت گرفت. بدین ترتیب که در این دوره بر اساس مقادیر جریان ورودی به مخزن (در ابتدای ماه)، حجم ذخیره آب در مخزن (در ابتدای ماه) و تغییرات ذخیره مخزن و نیازهای پایین دست در ماه حاضر، مقدار رهاسازی بهینه بر اساس ماشین‌های بردار پشتیبان بدست آمد و نتایج حاصل با خروجی حاصل از الگوریتم بهینه‌سازی در این دوره ۷۲ ماهه مقایسه شد. بر اساس صحت‌سنجی، بهترین ماشین بردار پشتیبان باید قادر باشد مقادیر رهاسازی بهینه از سد را با توجه به ورودی‌های ذکر شده پیش‌بینی نماید و نتایج حاصل از آن کمترین اختلاف را با نتایج حاصل از الگوریتم بهینه‌سازی داشته باشد. این امر در تحقیقات *Thissen et al., (2003)* و *Lin et al., (2006)* نیز برای اثبات برتری ماشین بردار پشتیبان مورد توجه قرار گرفته است. نتایج نشان داد بهترین تابع کرنل قابل استفاده در مدل ماشین بردار پشتیبان در این تحقیق تابع گوسی (تابع کرنل RBF) می باشد. دو و همکاران (۲۰۱۷) در تحقیقات خود همین تابع کرنل را پیشنهاد دادند. مقادیر بهینه پارامترهای C ، ϵ و γ در بدنه ماشین بردار پشتیبان با استفاده از روش جستجوی شبکه برابر با 0.033 ، 2000 و 18 بدست آمد. در شکل (۸) مقادیر سری زمانی رهاسازی پیش‌بینی شده از سد توسط ماشین بردار پشتیبان در مقایسه با خروجی الگوریتم بهینه‌سازی در دو مرحله آموزش و آزمون آورده شده است که نشان دهنده تطابق بالای مقادیر پیش‌بینی شده توسط ماشین بردار پشتیبان با الگوریتم بهینه‌سازی NSGAI می باشد.

شکل (۹ الف) توانایی ساختار آموزش دیده در پیش‌بینی رهاسازی بهینه از سد در ماه‌های مختلف با استفاده از داده‌های ورودی به مخزن، میزان ذخیره مخزن و تغییرات آن در ابتدای ماه و نیاز آبی مصارف در ماه حاضر را نشان می دهد. این شکل نشان دهنده مقدار بالای ضریب همبستگی بین مقادیر مستخرج از الگوریتم بهینه‌سازی و شبیه‌سازی شده توسط مدل SVM در دو مرحله آموزش و آزمون است. هم چنین میزان خطای نسبی مدل توسعه داده شده در تخمین مقدار رهاسازی بهینه از سد بر اساس داده‌های جدید در شکل (۹ ب) نشان داده شده است. همچنین مقادیر شاخص‌های آماری مختلف نشان داده شده در شکل (۹ ج) حاکی از دقت بالای مدل SVM در استخراج مقادیر بهینه رهاسازی از سد در زمان واقعی است.



شکل ۸. پیش‌بینی میزان رهاسازی بهینه از سد جامیشان توسط مدل ماشین بردار پشتیبان در مراحل آموزش و آزمون



شاخص	مرحله آموزش	مرحله آزمون
RMSE	0.1942	0.3547
NRMSE	0.0254	0.0330
NASH	0.9832	0.9815
R	0.9956	0.9941

شکل ۹. الف- پراکنش نقاط X (مقادیر رهاسازی از سد طبق الگوریتم بهینه‌سازی) و Y (مقادیر رهاسازی از سد طبق مدل SVM) اطراف خط ۴۵ درجه در مراحل آموزش و آزمون ب- درصد خطای نسبی مدل ماشین بردار پشتیبان برای تخمین میزان رهاسازی بهینه از سد جامیشان در مرحله آزمون ج- مقادیر شاخص‌های آماری در دو مرحله آموزش و آزمون

بحث

مطابق شکل (۶) کمترین درصد تامین نیاز اراضی چمچمال و جامیشان در ماه مهر و به ترتیب ۷۲ و ۸۱/۵ درصد است. کمترین درصد تامین نیاز زیست‌محیطی مربوط به ماه شهریور و در حدود ۶۴ درصد است. با در نظر گرفتن تمامی ماه‌های دوره برنامه ریزی ۳۰ ساله (۳۶۰ ماه) درصد اطمینان‌پذیری این مصارف بین ۷۴ تا ۷۹/۷ درصد است که رقمی قابل قبول است. علت پایین تر بودن اطمینان‌پذیری تامین نیاز اراضی جامیشان نسبت به چمچمال این است که این دشت تعداد چاه‌های بسیار کمتری نسبت به دشت چمچمال دارد و به همین خاطر میزان برداشت از منابع آب زیرزمینی به عنوان منبع جایگزین آب سطحی، برای جبران کمبود آب در ماه‌های خشک محدودتر است. شکل (۹ الف) مقدار ضریب همبستگی بین داده‌های مشاهداتی و پیش‌بینی شده و پراکنش این نقاط در اطراف خط ۴۵ درجه را در دو مرحله آموزش و آزمون نشان می‌دهد. مقدار R بالا در این شکل نشان دهنده کارایی مدل ماشین بردار پشتیبان برای تخمین خروجی بهینه سد در زمان واقعی است. شکل (۹ ب) مقدار خطای پیش‌بینی در حالت استفاده از سری داده‌های جدیدی که در آموزش استفاده نشده را نشان می‌دهد. بر اساس این شکل میانگین درصد خطا برای ۷۲ ماه حدود ۲/۱ درصد و بیشترین میزان خطا حدود ۱۲/۱ درصد بوده است. ساختار هیبرید GA-SVM توسط بسیاری از محققان مانند Yadav et al., 2022, Zhang et al., 2022 و Su et al., 2014 برای پیش‌بینی دبی رودخانه و ذخیره مخزن استفاده شده که در اکثر این مطالعات دارای دقت مناسبی با ضریب همبستگی بیش از ۰/۹۵ در مراحل آموزش و آزمون بوده است. در تحقیقات این محققان از الگوریتم ژنتیک تک هدفه (GA) استفاده شده است اما در تحقیق حاضر بدلیل مدل بهره‌برداری از منابع آب منطقه که شامل آب سطحی و آب زیرزمینی بوده و بدلیل تنوع مصارف مختلف از الگوریتم ژنتیک چندهدفه (NSGAI) استفاده شده است. در تحقیق دیگری توسط Azari and Arman, 2020 از مدل هیبرید SVM و NSGAI برای استخراج منحنی فرمان بهینه در زمان واقعی استفاده شده است. تفاوت تحقیق حاضر با تحقیق Azari and Arman, 2020 در فرمول بندی توابع هدف است. توابع هدف ارایه شده در تحقیق آنها مناسب مناطق بهره‌برداری تلفیقی آب سطحی و زیرزمینی نیست. از طرفی تابع هدف اطمینان‌پذیری مورد استفاده در تحقیق آنها مقدار اطمینان‌پذیری در کل دوره را بالا می‌برد و توجهی به ماه‌های کم آب یا خشک ندارد که باعث می‌شود شدت شکست در این ماه‌ها افزایش یابد. اما در تحقیق حاضر تابع هدف درصد تامین نیاز سعی در بالا بردن درصد تامین نیاز در کل ماه‌ها بخصوص ماه‌های کم آب دارد.

شکل (۹ ج) مقادیر شاخص‌های آماری در دو مرحله آموزش و آزمون را نشان می‌دهد. مقدار NRMSE در این دو مرحله به ترتیب ۰/۰۲۵ و ۰/۰۳۳ و مقدار شاخص NASH به ترتیب ۰/۹۸۳ و ۰/۹۸۱ می‌باشد که حاکی از دقت بسیار بالای مدل SVM در پیش‌بینی مقادیر رهاسازی از سد در زمان واقعی دارد. این امر به مدیران و برنامه ریزان کمک می‌کند در سال‌های آتی برنامه ریزی فقط با داشتن چهار پارامتر جریان ورودی به مخزن (در ابتدای ماه)، حجم ذخیره آب در مخزن (در ابتدای ماه) و تغییرات ذخیره مخزن و نیازهای پایین‌دست در ماه حاضر، مقدار رهاسازی بهینه را بصورت آبی و در زمان واقعی محاسبه نمایند و به شبیه سازی مجدد سیستم و انجام مجدد فرآیند بهینه‌سازی که فرآیندی وقت گیر و پیچیده است نیازی نیست. لذا منحنی فرمان سد در هر زمانی و با در نظر گرفتن داده‌های جدید در زمان واقعی قابل استخراج بوده و در سال‌های آتی منحنی فرمان سد براحتی بروزرسانی می‌شود.

نتیجه‌گیری و پیشنهادها

نتایج نشان داد با ترکیب الگوریتم چند هدفه NSGA-II و مدل شبیه‌سازی WEAP و استخراج سیاست‌های بهینه (منحنی فرمان بهینه سد) درصد تامین نیاز و اطمینان‌پذیری تامین نیازها به طور مناسب و قابل قبولی است. سیاست‌های بهینه استخراج شده توسط الگوریتم بهینه‌سازی بر اساس یک سری معین داده‌های تاریخی جریان ورودی به مخزن است. اشکال چنین مدل‌هایی این است که جواب‌های بهینه قابل تعمیم برای سایر ورودی‌های محتمل به مخزن در سال‌های آینده نیستند و در صورت تغییر جریان ورودی به مخزن به احتمال زیاد جواب‌های بهینه بدست آمده کارایی نداشته و باید بهره‌برداری از سیستم در قالب الگوریتم بهینه‌ساز مجدداً بهینه گردد. لذا برای استفاده از نتایج بهینه‌سازی در زمان واقعی از روش هوشمند ماشین‌های بردار پشتیبان استفاده شد. نتایج نشان داد میزان میانگین خطای قوانین بهینه مستخرج از ماشین‌های بردار پشتیبان نسبت به خروجی الگوریتم بهینه‌سازی NSGA-II در مرحله صحت‌سنجی کمتر از ۲/۵ درصد است که نشان دهنده کارایی این روش در پیش‌بینی الگوی بهینه منحنی فرمان سد در زمان واقعی است. دستاوردهای این تحقیق را می‌توان در چند مورد بیان کرد.

۱- کد توسعه داده شده در این تحقیق اتصال پویا بین مدل WEAP و الگوریتم بهینه‌ساز NSGAI در محیط MATLAB ایجاد

کرده است. این بدان معنی است می توان سناریوهای مدیریتی مختلفی در قالب بررسی اثرات تغییر اقلیم، تغییر الگوی مصرف (تغییر الگوی کشت اراضی کشاورزی) و یا حتی تغییر الگوی برداشت از منابع آب زیرزمینی در کنار آب سطحی بر منحنی فرمان بهینه سد در آینده مورد بررسی قرار داد.

۲- در صورت تغییر جریانات ورودی به سیستم در هر سناریوی مدیریتی در آینده، بدون نیاز به شبیه سازی و بهینه سازی مجدد سیستم، بر اساس قوانین استخراج شده توسط ترکیب نتایج الگوریتم بهینه ساز و مدل ماشین بردار، می توان منحنی فرمان بهینه سد را بصورت آنی بروزرسانی کرد. در این ساختار می توان بر اساس جریان ورودی به مخزن (در ابتدای ماه)، حجم ذخیره آب در مخزن (در ابتدای ماه) و تغییرات ذخیره مخزن و نیازهای پایین دست در ماه حاضر، مقدار رهاسازی بهینه را در زمان واقعی بدست آورد. یعنی مدل ماشین بردار پشتیبان توسعه داده شده این قابلیت را داشته که با توجه به ورودی های جدید جریان به سد، سریعاً سیاست های بهره برداری بهینه را به نحوی در اختیار قرار دهد که امکان مدیریت بهینه سیستم در زمان واقعی فراهم گردد.

لذا پیشنهاد می شود از مدل توسعه داده شده در این تحقیق برای برنامه ریزی و مدیریت بهره برداری از سیستم های سد و آبخوان برای سال های آینده استفاده شود. پیشنهاد می شود در سیستم های چند سدی که هر سد دارای منحنی فرمان جداگانه است اما رهاسازی هر کدام از این سدها متاثر از یکدیگر است از مدل های هوش مصنوعی که دارای چند لایه خروجی هستند استفاده شود. این مدل ها را می توان در محیط MATLAB برای شرایط جدید توسعه داد. همچنین بخشی از اطلاعات مورد نیاز چنین مدل هایی را می توان از پایگاه های اطلاعاتی برخط که از ماهواره های مختلف دریافت می شوند تهیه کرد. این امر بخصوص در مناطق فاقد آمار از اهمیت ویژه ای برخوردار است.

"هیچ گونه تعارض منافع بین نویسندگان وجود ندارد"

REFERENCES

- Azari, A., Arman, A. (2020). Optimal Utilization of Water Resources in Real Time Based on NSGA-II Algorithms and Support Vector Machines (Case Study: Gavoshan Dam). *Irrigation Sciences and Engineering (JISE)*, 43(1), 189-204.
- Azari, A., Hamzeh, S., & Naderi, S. (2018). Multi-objective optimization of the reservoir system operation by using the hedging policy. *Water Resources. Management*, 32(6), 2061-2078.
- Azari, A., Zeynoddin, M., Ebtehaj, I., Sattar, A. M. A., Gharabaghi, B. and Bonakdari, H. 2021. Integrated preprocessing techniques with linear stochastic approaches in groundwater level forecasting. *Acta Geophysica*, 69, 1395-1411. <https://doi.org/10.1007/s11600-021-00617-2>.
- Bayesteh, M., & Azari, A. (2021). Stochastic Optimization of Reservoir Operation by Applying Hedging Rules. *Journal of Water Resources Planning and Management*, 147(2), 04020099.
- Blum, C., & Roli, A. (2003). Metaheuristics in combinational optimization: Overview and conceptual comparison. *ACM Computing Surveys*, 35(3), 268-308.
- Candela, J. Q., & Hansen, L. K. (2002). Time series prediction based on the Relevance Vector Machine with adaptive kernels," *Acoustics, Speech, and Signal Processing (ICASSP)*, 2002 IEEE International Conference, 985-988.
- Chang, J. F., Chen, L., & Chang, C. L. (2005). Optimizing reservoir operating rule curves by genetic algorithms. *Hydrological Processes*, 19, 2277-2289.
- Deb, k., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multi-objective genetic algorithm: NSGA-II. *IEEE Trans Evolutionary Computing, Indian*, 6(2), 182-197.
- Du, J., Liu, Y., Yu, Y., & Yan, W. (2017). A Prediction of Precipitation Data Based on Support Vector Machine and Particle Swarm Optimization (PSO-SVM) Algorithms, *Algorithms*, 10(57), 1-15.
- Fatemi, S. E., Parvini, H. 2022. The impact assessments of the ACF shape on time series forecasting by the ANFIS model, *Neural Computing and Applications*. 34 (15): 12723-12736. <https://doi.org/10.1007/s00521-022-07140-5>.
- Goorani, Z., & Shabanlou, S. (2021). Multi-objective optimization of quantitative-qualitative operation of water resources systems with approach of supplying environmental demands of Shadegan Wetland, *Journal of Environmental Management*, 292(6), 112769.
- Huang, W., Liu, H., Zhang, Y., Mi, R., Tong, C., Xiao, W., Shuai, B. 2021. Railway dangerous goods transportation system risk identification: Comparisons among SVM, PSO-SVM, GA-SVM and GS-SVM, *Applied Soft Computing*. 109: 107541. <https://doi.org/10.1016/j.asoc.2021.107541>.
- Jalilian, A., Heydari, M., Azari, A. and Shabanlou, S. (2022). Extracting Optimal Rule Curve of Dam Reservoir

- Base on Stochastic Inflow. *Water Resources Management*, 36 (6): 1763–1782. <https://doi.org/10.1007/s11269-022-03087-3>.
- Jian, C., Qiang, H., & Min, W. (2005). Genetic algorithm for optimal dispatchin. *Water Resource Planning and Management*, 19, 321-331.
- Kalita, H. M., Sarma, A. K., & Bhattacharjya, P. K. (2007). Evaluation of Optimal River Training Work Using GA Based Linked Simulation-Optimization Approach. *Water Resources Management*, 28, 2077–2092.
- Karamian, F., Mirakzadeh, A. A., Azari, A. 2023. Application of multi-objective genetic algorithm for optimal combination of resources to achieve sustainable agriculture based on the water-energy-food nexus framework. *Science of The Total Environment*. 860: 160419. <https://doi.org/10.1016/j.scitotenv.2022.160419>.
- Lei, J., Quan, Q., Li, P., & Yan, D. (2021). Research on Monthly Precipitation Prediction Based on the Least Square Support Vector Machine with Multi-Factor Integration. *Atmosphere*, 12(8), 1076.
- Lin, J. Y., Cheng, C. T., & Chau, K. W. (2006). Using support vector machines for long-term discharge prediction. *Hydrological Sciences Journal*, 51(4), 599-612.
- Momtahan, Sh., & Dariane, A. B. (2007). Direct search approaches using genetic algorithms for optimization of water reservoir operating policies. *Water Resource Planning and Management*, 133(3), 202–209.
- Nicklow, J., Reed, P., Savic, D., Dessalegne, T., Harrell, L., Chan-Hilton, A., Karamouz, M., Minsker, B., Ostfeld, A., Singh, A., & Zechman, E. (2010). State of the Art for Genetic Algorithms and Beyond in Water Resources Planning and Management, *Journal of Water Resources Planning and Management*, 136, 412-432.
- Smola, A. J., Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*. 14 (3): 199–222. <https://doi.org/10.1023/B%3ASTCO.0000035301.49549.88>.
- Soltani., K., and Azari, A. (2022). Forecasting groundwater anomaly in the future using satellite information and machine learning. *Journal of Hydrology*, 612 (2): 128052. <https://doi.org/10.1016/j.jhydrol.2022.128052>.
- Soltani, K., Ebtehaj, I., Amiri, A., Azari, A., Gharabaghi, B. and Bonakdari, H. 2021. Mapping the spatial and temporal variability of flood susceptibility using remotely sensed normalized difference vegetation index and the forecasted changes in the future. *Science of The Total Environment*, 770, 145288. <https://doi.org/10.1016/j.scitotenv.2021.145288>.
- Su, J., Wang, X., Liang, Y., & Chen, B. (2014). GA-Based Support Vector Machine Model for the Prediction of Monthly Reservoir Storage. *Journal of Hydrologic Engineering*, 19(7), 1430-1437.
- Tennant, D. L. (1976). Instream flow regimens for fish, wildlife, recreation and related environmental resources. *Fisheries*, 1(4), 6-10.
- Thissen, U., van Brakel, R., de Weijer, A. P., Melssen, W.J., & Buydens, L. M. C. (2003). Using support vector machines for time series prediction. *Chemometrics and Intelligent Laboratory Systems*, 69, 35–49.
- Vapnik, V. N., and Cortes, C. 1995. Support vector networks. *Machine Learning*, 20, 273-297.
- Wardlaw, R., & Sharif, M. (1999). Evaluation of genetic algorithms for optimal reservoir system operation. *Water Resource Planning and Management*, 125(1), 25-33.
- Xi, X. C., Poo, A. N., & S. K. Cho. (2007). Support vector regression model predictive control on a HVAC plant. *Control Engineering Practice*, 15, 897–908.
- Yadav, A., Joshi, D., Melingi, S. B., Revanth, J., Aashrith, P., Chithaluru, P. (2022). Integration of genetic algorithm and support vector machine for water discharge prediction in river basin system. *NeuroQuantology*, 20 (10), 11811-11821. <https://doi.org/10.14704/NQ.2022.20.10.NQ551145>.
- Zarei, N., Azari, A., & Heidari, M. M. (2022). Improvement of the performance of NSGA-II and MOPSO algorithms in multi-objective optimization of urban water distribution networks based on modification of decision space. *Applied Water Science*, 12(6), 133. <https://doi.org/10.1007/s13201-022-01610-w>.
- Zeinali, M., Azari, A., & Heidari, M. (2020b). Multiobjective Optimization for Water Resource Management in Low-Flow Areas Based on a Coupled Surface Water–Groundwater Model. *Journal of Water Resource Planning and Management*, 146(5), 04020020.
- Zhang, W., Hou, S., Yin, H., Li, L., Wu, K. (2022). Evaluation of Regional Water-Saving Level Based on Support Vector Machine Optimized by Genetic Algorithm. *Water*, 14 (17), 2615. <https://doi.org/10.3390/w14172615>.



Extracting the Optimal Role Curve of Dams in Real Time based on the Integration of Meta-Exploration Algorithm and Machine Learning Technique

EXTENDED ABSTRACT

Introduction

In the deterministic optimization method, a historical series of inflow to the reservoir through the operation time is considered and the release volume from the reservoir is optimized to provide downstream consumption in these conditions. The disadvantage of such models is that the optimal solutions cannot be generalized to other possible inflows to the reservoir and if the inflow to the reservoirs changes, the optimal solutions will no longer work and the system must be operated in the form of an optimizer algorithm. Thus, the main objective of this research is to integrate the support vector machine model with the NSGA-II optimization algorithm for optimal real-time operation from the system.

Materials and methods

This study utilizes an integration of the NSGA-II multi-objective algorithm and WEAP simulator model so that the first objective is to maximize the reliability of providing the needs in front of the second goal, i.e., to minimize water table drawdown at the end of the operation time. The dam role curve or the amount of released volume from the reservoir is optimized to supply downstream uses in these conditions. However, in certain optimizations, the optimal solutions cannot be generalized to other possible inputs to the reservoir, and if the inflow to the reservoirs changes, the obtained optimal solutions are no longer efficient and the system must be re-optimized in the form of an optimizer algorithm. Therefore, to solve this problem, a new method is extended on the basis of the combination of the support vector machine and NSGA-II algorithm for optimal real-time operation of the system. In this case, after completing the algorithm and extracting the optimal variables, there will be a relationship between the monthly inflows to the reservoir, water storage volume in the reservoir, reservoir volume changes and downstream needs (as independent parameters) and the optimal release rate variable (as a dependent parameter). This means that in each future simulation period, by determining the first four parameters at the beginning of each month, the optimal real-time release volume will be determined.

Result and discussion

The results demonstrate that the average error rate of optimal rules derived from support vector machines is less than 2.5% compared to the output of the NSGA-II algorithm in the verification step, which indicates the efficiency of this method in predicting the optimal pattern of the dam role curve in real-time. In this structure, based on the inflow to the reservoir, the volume of water storage in the reservoir and changes in the reservoir storage (at the beginning of the month) and the downstream demands of the current month, the optimal release amount can be achieved in real-time. Therefore, the developed support vector machine has the ability to update the rule curve of the dam based on the new data if the input flow to the dam changes and provide the possibility of operating the system in real time. In this structure, unlike the common structure of deterministic optimization, if the inflow changes, it is no need to re-optimize to understand the optimal coefficients, however by utilizing the relationship obtained from the support machine method it is possible to predict the release volume in real-time on the basis of the inflow to the reservoir (measured at the first day of the month), the volume of water storage in the reservoir (measured at the first day of the month) and changes in the reservoir storage and downstream needs in the current month.

Conclusion

In general, the results showed that the SVM-NSGA-II developed model has good capability and efficiency in solving complex and completely nonlinear problems and providing optimal solutions based on 24 answers on the Pareto optimal front. Among these solutions, according to the valuation of the objective functions, the solution that had the lowest groundwater drop function and the highest percentage of supplying the demands was selected as the superior answer. The results of applying the optimal release values from the dam (optimal role curve of the dam) showed that considering the optimal policy, the percentage of providing and reliability of supplying the most demands is appropriate and acceptable. The developed SVM-NSGA-II model has the ability to provide optimal operation policies based on new data of the inflow to the dam in a way that allows us to optimally manage the system in real-time.

Keywords: Jamishan Dam, NSGA-II, Real Time, Support Vector Machines, WEAP.