نشریه علمی سد و نیروگاه برق آبی ایران
سال دهم/ شماره سی و پنجم/ پاییز ۱۴۰۲

Journal of Iranian Dam and Hydroelectric Power Plant
10th Year/ No. 35/ December 2023

بهره‌برداری بهینه از مخزن سد در زمان واقعی بر اساس مدل هیبرید MOGWO-ORELM

حسن بیگلری[۱]
سعید جمالی*[۲]
هومن حاجی کندی[۳]
سعید شعبانلو[۴]

چکیده

الگوریتم‌های بهینه‌سازی چندهدفه، ابزاری قدرتمند برای بهره‌برداری بهینه از منابع آب و تعیین منحنی فرمان بهینه سدها می باشد. در این تحقیق از الگوریتم چندهدفه MOGWO برای استخراج الگوی بهینه رهاسازی جریان از مخزن سد دویرج استفاده شد. در این راستا، با استفاده از تکنیک بهینه‌سازی معین بر اساس یک دوره‌ی آماری ۷۲۰ ماهه (مهر ۱۳۴۰ تا شهریور ۱۴۰۰)، منحنی فرمان سد یا مقدار رهاسازی از مخزن جهت تأمین مصارف پایین دست، بهینه شد. در روش بهینه‌سازی معین، جواب‌های بهینه قابل تعمیم برای سایر ورودی‌های محتمل به مخزن نیستند و در صورتی که در سال‌های آتی، جریان ورودی به مخزن تغییر کند، جواب‌های بهینه‌ی بدست آمده، کارایی نداشته و باید بهره‌برداری از سیستم، در قالب الگوریتم بهینه‌ساز، مجدداً بهینه گردد. برای حل این مشکل، روش جدیدی بر اساس تلفیق مدل ORELM و الگوریتم MOGWO برای بهره‌برداری بهینه از سیستم در زمان واقعی توسعه داده شد. نتایج نشان داد، میزان میانگین خطای قوانین بهینه‌ی مستخرج از مدل ORELM نسبت به خروجی الگوریتم MOGWO در مرحله صحت‌سنجی کمتر از ۶ درصد است که نشان دهنده‌ی کارایی این روش در پیش‌بینی الگوی بهینه منحنی فرمان سد در زمان واقعی است. در این ساختار، مدل ترکیبی MOGWO- ORELM توسعه داده شده، این قابلیت را داشته که با توجه به داده‌های جدید جریان ورودی به سد، 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 و سریعاً سیاست‌های بهره‌برداری بهینه را به نحوی در اختیار قرار دهد که امکان مدیریت بهینه سیستم در زمان واقعی فراهم گردد.

واژه‌های کلیدی:
بهینه‌سازی چندهدفه، زمان واقعی، MOGWO ، ORELM ، سد دویرج

---

۱. دانشجوی دکتری، گروه مهندسی عمران، دانشکده مهندسی عمران و منابع زمین، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران
۲. گروه مهندسی عمران، دانشکده مهندسی عمران و منابع زمین، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران
* نویسنده مسئول: sae.jamali@iauctb.ac.ir
۳. گروه مهندسی عمران، دانشکده مهندسی عمران و منابع زمین، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران
۴. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

علمی-پژوهشی

تاریخ دریافت: ۱۴۰۱/۱۱/۲۶ تاریخ پذیرش: ۱۴۰۲/۰۷/۰۸

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

مقدمه

بهره‌برداری اصولی از مخازن و سدهای مخزنی نقش بسیار مهمی را در تأمین آب ایفا می‌نماید و بدین جهت که مقاصد چندگانه‌ای را از لحاظ اقتصادی، اجتماعی و گردشگری 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 و بهینه‌سازی می‌باشد. استفاده از مدل WEAP به عنوان یک مدل جامع برنامه‌ریزی منابع آب، برای شبیه‌سازی پاسخ های محیط به سناریوها یا راه حل‌های پیشنهادی، همواره مورد توجه مدیران و محققان بخش آب بوده است (زینعلی و همکاران[1]، ۲۰۲۰a؛ رفیعی انزاب و همکاران[2]، ۲۰۱۶).

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 (بلوم و رولی[3]،۲۰۰۳).

ساختار بهینه‌سازی معین[4] به عنوان شناخته‌شده‌ترین روش بهینه‌سازی 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 (واردلاو و شریف[5]، ۱۹۹۹؛ نیکلاو و همکاران[6]، ۲۰۱۰؛ کالیتا و همکاران[7]، ۲۰۱۴). چانگ و همکاران[8] در سال ۲۰۰۵ این روش را برای پیدا کردن منحنی فرمان ماهانه بهینه در یک سیستم تک سدی چندهدفه در تایوان به کار بردند. ممتحن و داریان[9] در سال ۲۰۰۷ در یک سیستم تک مخزنی ساده برای جستجوی مستقیم پارامترهای مربوط به سیاست بهره‌برداری بهینه مخزن، از بهینه‌سازی معین استفاده کردند تا ارتباط بین متغیرهای حالت (حجم مخزن و جریان ورودی) و متغیرهای تصمیم‌گیری (خروجی مخزن)، از طریق آن‌ها برقرار شود. در بسیاری از تحقیقات، مانند آذری و همکاران[10] در سال ۲۰۱۸، گورانی و همکاران[11] در سال ۲۰۲۱، جیان و همکاران[12] در سال ۲۰۲۰، زینعلی و همکاران[13] در سال ۲۰۲۰b از الگوریتم‌های بهینه‌سازی چندهدفه بر اساس تکنیک بهینه‌سازی معین و بر اساس ورودی‌های تاریخی ثبت شده برای بهینه‌سازی بهره‌برداری از سیستم‌های منابع آب استفاده می‌شود.

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 پایین دست 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 مخازن، به احتمال زیاد، جواب‌های بهینه‌ی 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 (بایسته و آذری[14]، ۲۰۲۱). اما در این روش نیز به دلیل تنوع سری های 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

[1] Zeinali et al
[2] Rafiee Aanzab et al
[3] Blum and Roli
[4] Deterministic Optimization
[5] Wardlaw and Sharif
[6] Nicklow et al
[7] Kalita et al
[8]- Chang et al.
[9]- Momtahen & Dariane
[10] Azari et al
[11] Goorani et al
[12] Jian et al
[13] Zeinali et al
[14] Bayesteh and Azari

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

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 رگرسیون که بر اساس ماشین بردار پشتیبان توسعه یافته است برای پیش‌بینی سری زمانی استفاده شده است. تیسن و همکاران[1] در سال ۲۰۰۳ و لین و همکاران[2] در سال ۲۰۰۶ دریافتند که ماشین‌های بردار پشتیبان نسبت به مدل‌های ARMA و شبکه‌ی عصبی مصنوعی کارایی بهتری برای پیش‌بینی سری زمانی دارد و نتایج آن به واقعیت نزدیکتر است. دو و همکاران[3] در سال ۲۰۱۷ از ترکیب ماشین بردار پشتیبان و الگوریتم ازدحام ذرات، برای پیش‌بینی بارندگی سه ساعته ایستگاه هواشناسی واقع در نانجینگ چین استفاده کردند. سو و همکاران[4] در سال ۲۰۱۴ از GA-SVM برای پیش‌بینی حجم ذخیره‌ی ماهانه مخزن Miyun در چین استفاده کردند. مدل ترکیبی GA-SVM، توسط برخی محققان برای افزایش دقت پیش‌بینی پارامترهای هیدرولوژیکی استفاده شده است (لی و همکاران[5]، ۲۰۲۱).

در سالهای اخیر، در کنار روشهای استوکاستیک (ابتهاج و همکاران[6]، ۲۰۲۰؛ زین الدین و همکاران[7]، ۲۰۲۰؛ آذری و همکاران[8]، ۲۰۲۱) بصورت گسترده از روش های مبتنی بر هوش مصنوعی مانند ماشین آموزش نیرومند با داده‌های پرت[9] (ORELM)، ماشین نیرومند[10] (ELM) و روش کنترل گروهی داده‌ها[11] (GMDH) و روشهای هیبرید[12] برای پیش‌بینی پارامترهای هیدروکلیماتولوژی مانند دما، بارندگی، جریان رودخانه ها و تغییرات تراز آب مخازن سطحی و آب زیرزمینی استفاده شده است (زین الدین و همکاران[13]، ۲۰۱۸؛ سلطانی و همکاران[14]،۲۰۲۱؛ اسماعیلی و همکاران[15]، ۲۰۲۱). در سالهای اخیر، در کنار روشهای استوکاستیک (ابتهاج و همکاران[16]، ۲۰۲۰؛ زین الدین و همکاران[17]، ۲۰۲۰؛ آذری و همکاران[18]، ۲۰۲۱) بصورت گسترده از روش های مبتنی بر هوش مصنوعی مانند ماشین آموزش نیرومند با داده‌های پرت[19] (ORELM)، ماشین آموزش نیرومند[20] (ELM) و روش کنترل گروهی داده‌ها[21] (GMDH) و روشهای هیبرید[22] برای پیش‌بینی پارامترهای هیدروکلیماتولوژی مانند دما، بارندگی، جریان رودخانه ها و تغییرات تراز آب مخازن سطحی و آب زیرزمینی استفاده شده است (زین الدین و همکاران[23]، ۲۰۱۸؛ سلطانی و همکاران[24]، ۲۰۲۱؛ اسماعیلی و همکاران[25]، ۲۰۲۱؛ یوسفوند و شعبانلو[26]، ۲۰۲۰؛ پورسعید و همکاران[27]، ۲۰۲۰، ۲۰۲۱؛ عزیزپور و همکاران[28]، ۲۰۱۹ الف و ب؛ ملکزاده و همکاران[29]، ۲۰۱۹ الف و ب؛ محمد و همکاران[30]، ۲۰۲۳؛ امیری و همکاران[31]، ۲۰۲۳؛ فلاحی و همکاران[32]، ۲۰۲۳؛ گرامی مقدم و همکاران[33]، ۲۰۱۹؛ شعبانلو[34]، ۲۰۱۸، قریب و همکاران[35]، ۲۰۲۰؛ زارعی و همکاران[36]، ۲۰۲۰). ایده اصلی تحقیق حاضر، استفاده تلفیقی از الگوریتم بهینه‌سازی چندهدفه گرگ خاکستری[37] (MOGWO) و مدل‌های مبتنی بر هوش مصنوعی برای بهره‌برداری بهینه از سیستم های منابع آب در زمان واقعی است. بر

[1] Thissen et al.
[2] Lin et al.
[3] Du et al.
[4] Su et al.
[5] Lei et al
[6] Ebtehajet al
[7] Zeynoddin et al
[8] Azari et al
[9] Outlier Robust Extreme Learning Machine (GMDH)
[10] Extreme Learning Machine (ELM)
[11] Group Method of Data Handling (GMDH)
[12] Hybrid Methods
[13] Zeynoddin et al
[14] Soltani et al
[15] Esmaeili et al
[16] Ebtehajet al
[17] Zeynoddin et al
[18] Azari et al
[19] Outlier Robust Extreme Learning Machine (GMDH)
[20] Extreme Learning Machine (ELM)
[21] Group Method of Data Handling (GMDH)
[22] Hybrid Methods
[23] Zeynoddin et al
[24] Soltani et al
[25] Esmaeili et al
[26] Yosefvand and Shabanlou
[27] Poursaeid et al.
[28] Azizpour et al.
[29] Malekzadeh et al.
[30] Mohammed et al.
[31] Amiri et al.
[32] Fallahi et al
[33] Gerami Moghadam et al.
[34] Shabanlou S.
[35] Gharib et al.
[36] Zarei et al.
[37] Multi-Objective Grey Wolf Optimization (MOGWO)

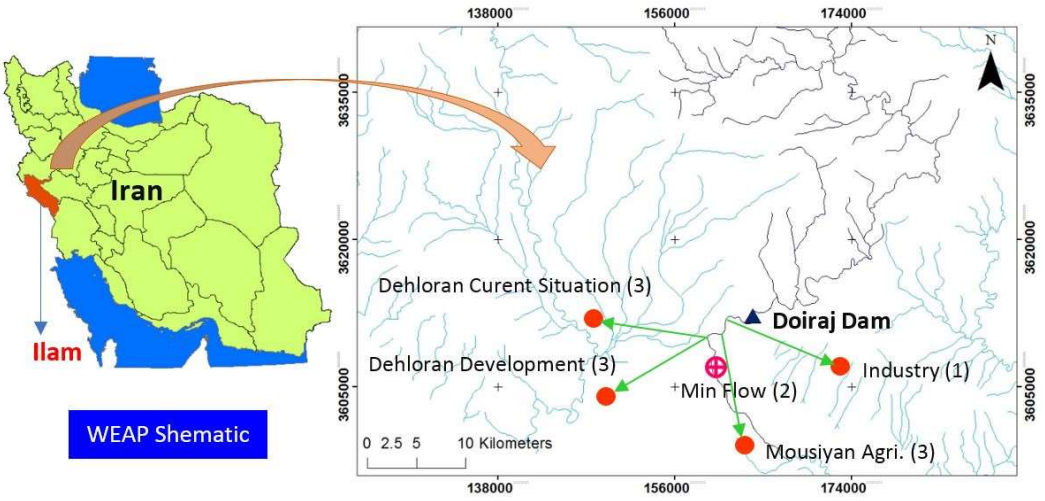
[Downloaded from journal.hydropower.org.ir on 2026-11-19]

اساس بررسی‌های صورت گرفته، نویسندگان این تحقیق، ترجیح دادند برای بهینه‌سازی سیستم، بجای داده‌های تصادفی، از داده‌های واقعی ثبت شده استفاده کنند. در این صورت، پس از اتمام الگوریتم و استخراج متغیرهای بهینه، ارتباط معناداری بین جریانات ماهانه 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 MOGWO برای بهره‌برداری بهینه از سیستم در زمان واقعی می باشد. به این معنا که در هر دوره شبیه‌سازی آتی 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 برنامه‌ریزی معین، در صورت تغییر جریان ورودی، نیازی به انجام بهینه‌سازی مجدد، برای تعیین 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.

مواد و روش‌ها

منطقه مورد مطالعه

حوضه‌ی آبخیز سد دویرج در غرب ایران و جنوب شرقی استان ایلام قرار دارد. رودخانه اصلی این حوضه رودخانه دویرج می‌باشد (شکل ۱). سد دویرج منبع اصلی تأمین آب مصارف صنعتی پایین دست و اراضی کشاورزی دهلران و موسیان است. در مدل WEAP با استفاده از ابزارهای موجود و با توجه به نقشه‌های پایه GIS، مسیر رودخانه ها، محل سد و مصارف مختلف رقومی شدند. شماتیک و چارچوب مدل تهیه شده در WEAP در شکل (۱) نشان داده شده است.



شکل (۱): موقعیت محدوده مطالعاتی و منابع و مصارف موجود

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

شبیه‌سازی سیستم

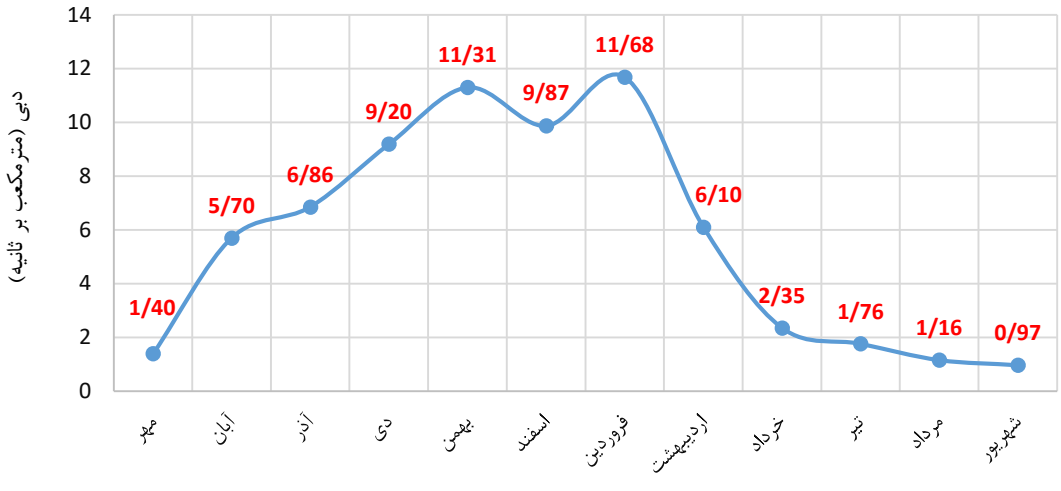
در مدل WEAP با استفاده از ابزارهای موجود و با توجه به نقشه‌های پایه GIS، مسیر رودخانه‌ها، محل ایستگاه‌های هیدرومتری، محل سد، محل های برداشت آب، گره‌ی مربوط به مصارف مختلف و نیازهای پایین دست رقومی شدند. گام-های زمانی شبیه‌سازی، ماهانه در نظر گرفته شد. سری‌های زمانی داده‌های ثبت شده هیدرولوژیکی و اطلاعات مربوط به نیاز ماهانه 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 دویرج اخذ شده، از شرکت آب منطقه ای ایلام مطابق با جدول (۱) در مدل وارد شد.

جدول (۱): مشخصات بهره‌برداری از سد دویرج

پارامتر	سد دویرج
بیشترین تراز بهره‌برداری	۲۲۶/۵ متر
کمترین تراز بهره‌برداری	۲۰۱ متر
ظرفیت ذخیره در بیشترین تراز بهره‌برداری	۲۰۵ میلیون مترمکعب
حجم غیرفعال	۳۲/۳ میلیون مترمکعب
حجم فعال	۱۷۲/۷ میلیون مترمکعب
حجم ذخیره اولیه (اکتبر ۱۹۹۰)	۱۲۰ میلیون متر مکعب

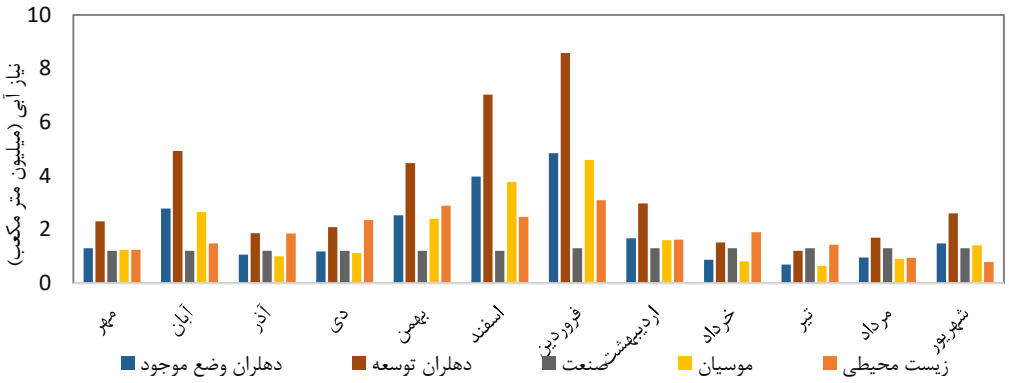
مقادیر آبدهی رودخلنه در محل ورودی به سد بر اساس آبدهی رودخانه در محل ایستگاه پل دویرج، واقع در نزدیکی سد و بر اساس اطلاعات اخذ شده از شرکت آب منطقه‌ای ایلام محاسبه شده و در مدل تعریف گردید. میانگین آبدهی ماهانه ورودی به سد، در طول دوره شبیه‌سازی در شکل (۲) ارائه شده است.

نیاز آبی اراضی دشت‌های تحت پوشش سد دویرج (دهلران و موسیان) و همچنین مصارف صنعتی و نیاز زیست‌محیطی پایین دست سد، به عنوان مصارف سیستم بر اساس اطلاعات اخذ شده از شرکت آب منطقه‌ای ایلام در مدل تعریف شدند. اولویت‌های تخصیص در مدل به ترتیب برای مصارف صنعتی، زیست‌محیطی و کشاورزی در نظر گرفته شد. مقادیر ماهانه این مصارف در شکل (۳) ارائه شده است.



شکل (۲): میانگین آبدهی ماهانه در محل ایستگاه هیدرومتری واقع در بالادست سد

[Downloaded from journal.hydropower.org.ir on 2026-11-19]



شکل (۳): میزان نیاز آبی کشاورزی، شرب و زیست محیطی منطقه در ماههای مختلف (MCM)

در این تحقیق، برای تعیین جریان زیست‌محیطی، گره‌ی مربوط به حداقل جریان زیست‌محیطی در پایین دست سد مورد مطالعه و بر روی رودخانه‌ی اصلی در مدل ایجاد شد. از روش Tenant (1976) که از جمله روش‌های درجه‌بندی هیدرولوژیکی محسوب می‌شود، برای تخمین حداقل جریان زیست‌محیطی پایین دست بر اساس جریان طبیعی رودخانه استفاده شد. با توجه به اطلاعات تبخیر از سطح آزاد مخزن سد دویرج اخذ شده از شرکت آب منطقه‌ای ایلام و در نظر گرفتن میزان بارندگی روی سطح مخزن، تبخیر خالص از سطح آزاد مخزن محاسبه شد که در جدول (۲) نشان داده شده است.

جدول (۲): متوسط ماهانه تبخیر خالص از سطح آزاد مخزن سد دویرج (میلیمتر)

ماه	مهر	آبان	آذر	دی	بهمن	اسفند	فروردین	اردیبهشت	خرداد	تیر	مرداد	شهریور	جمع
تبخیر خالص (mm)	۲۱۲/۲	۱۳۹	۷۷/۹	۵۲/۲	۶۰/۸	۹۱/۶	۱۳۴/۴	۱۸۵/۵	۲۷۳/۷	۳۰۵/۱	۳۱۸/۵	۲۲۶/۲	۲۰۷۷/۱

ساختار مدل بهره‌برداری چندهدفه پیشنهادی

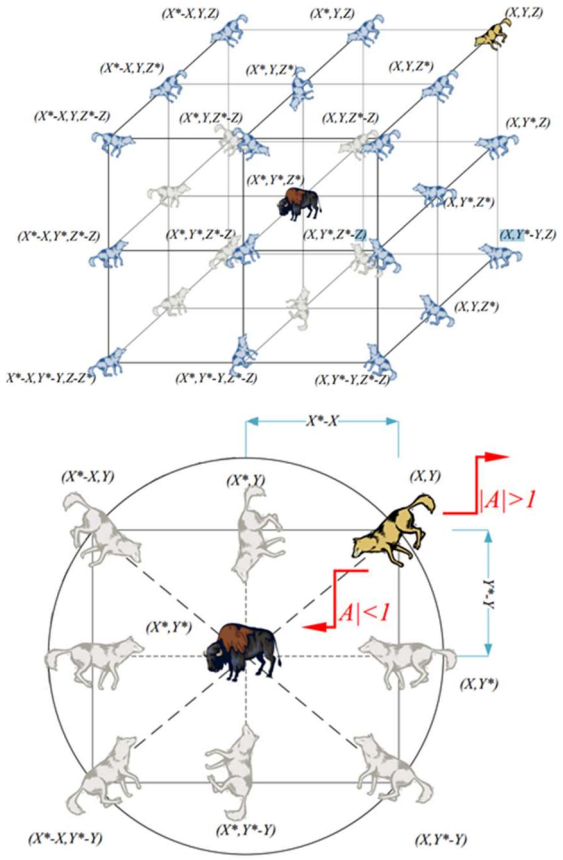
در این تحقیق، برای بهینه‌سازی سیستم، از الگوریتم چندهدفه‌ی بهینه‌سازی گرگ خاکستری (MOGWO) استفاده شد. برای بهینه‌سازی سیستم، این الگوریتم با استفاده از یک VBScript که توسط نویسندگان توسعه داده شده با مدل WEAP کوپل شد. با اجرای این اسکریپ، متغیرهای تصمیم‌گیری تولید شده توسط MOGWO در مسیر منطقه‌ی فعال WEAP قرار می گیرد. پس از آن سناریو فعال WEAP که همان سناریوی بهینه‌سازی بر اساس قواعد جیره‌بندی است به طور خودکار اجرا می شود.

الگوریتم GWO، بر اساس جستجو ، رفتار شکار و سلسله‌مراتب اجتماعی گرگ‌های خاکستری توسط میرجلالی[1] در سال ۲۰۱۴ ارائه‌شده است. بعدها الگوریتم چندهدفه MOGWO توسط میر جلالی و همکاران در سال ۲۰۱۶ ارائه شد. در بهینه‌ساز گرگ خاکستریGWO، مناسب‌ترین راه حل را به عنوان آلفا در نظر می گیریم ، و راه‌حل‌های دوم و سوم مناسب، به ترتیب بتا و دلتا نامگذاری می شوند. بقیه راه‌حل‌ها، امگا در نظر گرفته می شوند. در الگوریتم GWO، شکار توسط α β و δ هدایت می‌شود. راه‌حل ω از این سه گرگ پیروی می‌کند. وقتی شکار توسط گرگ‌ها احاطه شده و از حرکت بایستند، حمله به رهبری گرگ alpha شروع می‌شود. مدل کردن این فرآیند با استفاده از کاهش بردار a انجام می‌شود. از آنجا که A برداری تصادفی در بازه‌ی [-2a,2a] است، با کاهش a، بردار ضرایب A هم کاهش می‌یابد.

[1] Mirjalili et al.

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

اگر |A|<1 باشد، گرگ alpha به شکار (و بقیه گرگ‌ها) نزدیک می‌شود و اگر |A|>1 باشد،گرگ از شکار (و بقیه‌ی گرگ‌ها) دور خواهد شد. الگوریتم گرگ خاکستری الزام دارد که تمام گرگ‌ها موقعیت خود را برحسب موقعیت گرگ‌های alpha, beta, delta آپدیت کنند (شکل (۴)).



شکل (۴): مکانیسم به‌روزرسانی موقعیت دو بعدی و سه بعدی عوامل جستجو و تأثیرات A بر روی آن در الگوریتم گرگ خاکستری (Mirjalili et al. (2014, 2016))

در این تحقیق، با توجه به اهداف پیش رو از الگوریتم رقابت استعماری چندهدفه جهت بهره‌برداری بهینه، از سد دویرج و پیدا کردن راه حل‌های بهینه استفاده شد. برای ارزیابی عملکرد سیستم در صورت اجرای راه‌حل‌های پیشنهاد شده در هر تکرار الگوریتم، از یک تابع چندهدفه استفاده شد طوری که هدف اول، حداکثر نمودن درصد تأمین نیازهای طرح در طی دوره‌ی برنامه‌ریزی در مقابل هدف دوم، یعنی حداقل نمودن میزان تخطی از ظرفیت بهره‌برداری مخزن (تابع خسارت) در طول دوره بهره‌برداری قرار گرفت.
توابع هدف و قیود در این تحقیق به صورت زیر تعریف شدند.

توابع هدف:

۱- حداکثر نمودن درصد تأمین نیازها

$$F_1 = Maximize(\sum_{z=1}^{m}\sum_{d=1}^{k}\sum_{t=1}^{n}(COV_{zdt})) = Maximize(\sum_{z=1}^{m}\sum_{d=1}^{k}\sum_{t=1}^{n}(\frac{TDW_{zdt}}{MD_{zdt}} \times 100)) \quad (۱)$$

به دلیل اینکه الگوریتم بهینه‌سازی چندهدفه MOGWO به دنبال یافتن کمینه توابع هدف است، می‌توان معادله‌ی (۱) را به صورت معادله‌ی (۲) تعریف کرد:

$$F_1 = Minimize(\sum_{z=1}^{m}\sum_{d=1}^{k}\sum_{t=1}^{n}(100 - COV_{zdt})) = Minimize(\sum_{z=1}^{m}\sum_{d=1}^{k}\sum_{t=1}^{n}(100 - \frac{TDW_{zdt}}{MD_{zdt}} \times 100) \quad (۲)$$

که در این فرمول :

COV_{zdt}: درصد تأمین نیاز d در دوره‌ی t در منطقه‌ی z

TDW_{zdt}: حجم کل آب تحویلی به نیاز d در دوره‌ی t در منطقه‌ی z

MD_{zdt}: حجم کل آب مورد نیاز، نیاز d در دوره‌ی t در منطقه‌ی z

۲- تابع هدف دوم : حداقل نمودن میزان تخطی از ظرفیت مجاز بهره‌برداری مخزن:

$$F_2 = Minimize(\sum_{R=1}^{k}\sum_{t=1}^{n} Max((1 - \frac{S_t}{S_{min}}),0)) \quad (۳)$$

که در آن:

S_t : حجم ذخیره مخزن سد در زمان t

S_{min} : حجم مخزن سد R در تراز حداقل بهره‌برداری در دوره‌ی t

محدودیت‌ها:

$$TAW_{tzs} = RS_{tzs} \quad , \quad t = 1, \dots, m \times y, \quad z = 1, \dots, nz \quad s = 1, \dots, ns \quad (۴)$$

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

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

nz: تعداد مناطق نیاز

ns: تعداد بخش‌های مصرف‌کننده‌ی آب در هر منطقه‌ی نیاز

m: تعداد دوره‌های برنامه‌ریزی در هر سال

y: تعداد سال‌های دوره‌ی برنامه‌ریزی

$$\mathrm{ARS}_{tzs}=\begin{cases}\mathrm{DM}_{tzs} & \text{if } \left(\mathrm{TSR}_t-\sum_{z=1}^{z-1}\sum_{s=1}^{s}\mathrm{DM}_{tzs}-\sum_{z=1}^{z}\sum_{s=1}^{s-1}\mathrm{DM}_{tzs}\right)\geq \mathrm{DM}_{tzs}\\ \left(\mathrm{TSR}_t-\sum_{z=1}^{z-1}\sum_{s=1}^{s}\mathrm{DM}_{tzs}-\sum_{z=1}^{z}\sum_{s=1}^{s-1}\mathrm{DM}_{tzs}\right) & \text{otherwise}\end{cases} \quad (۵$$

$$Z=IZ(1),...,IZ(nz) \qquad S=IS(1),...,IS(ns)$$

ARS_{tzs}: میزان کل آب سطحی تخصیص داده شده به بخش s در دوره‌ی t از منطقه z (با در نظر گرفتن اولویت نیاز مصارف)

$$TDF_{tzs}=DM_{tzs}-ARS_{tzs} \quad (۶$$

TDF_{tzs}: حجم کل کمبود آب بخش s در دوره t از منطقه‌ی z

$$\mathrm{M1}<\mathrm{Tb1}<\mathrm{N1} \quad (۷$$

Tb1: تراز جیره‌بندی سد دویرج (متر)

M1: تراز غیرفعال سد دویرج (متر)

N1: تراز حداکثر سد دویرج (متر)

$$TDW_{zdt}\leq MD_{zdt} \quad (۸$$

در بدنه‌ی مدل بهینه‌سازی MOGWO، برای ناحیه‌بندی مخزن ۱۲ متغیر تراز جیره‌بندی در مخزن و ۱۲ متغیر ضریب جیره‌بندی به صورت ماهانه تعریف شد. این ضرایب به عنوان متغیرهای تصمیم‌گیری (۲۴ متغیر) به مدل معرفی گردید.

ماشین آموزش نیرومند با داده‌های پرت

ماشین آموزش نیرومند (ELM) یک شبکه‌ی عصبی پیشخور[1] تک لایه بوده و توسط هولنگ[2] و همکاران (۲۰۰۴، ۲۰۰۶) ارائه شده است. ELM وزن‌های ورودی را به صورت تصادفی وزن‌های خروجی را به صورت تحلیلی[3] تعیین می‌کند. ساختار کلی این الگوریتم در شکل (2.a) ارائه شده است. تنها تفاوت ELM با شبکه عصبی پیشخور تک لایه[4] (SLFFNN)، عدم استفاده از بایاس[5] برای نرون خروجی است. نرون‌های لایه‌ی ورودی با همه نرون‌های لایه مخفی در ارتباط است. تابع فعال‌سازی نرون‌های مخفی می‌تواند به صورت تابع پیوسته تکه‌ای[6] باشد در حالی که برای نرون لایه خروجی به صورت خطی است. مدل ELM از الگوریتم‌های مختلفی جهت محاسبه وزن‌ها و بایاس‌ها استفاده می‌کند که در نتیجه کاهش قابل توجه زمان آموزش شبکه را به همراه دارد. توصیف ریاضی شبکه‌عصبی پیشخور تک لایه با تعداد n گره مخفی، به صورت زیر بیان می‌شود:

$$f_n(x)=\sum_{i=1}^{n}\beta_i G(a_i,b_i,x) \quad (۹$$

که β_i وزن بین گره مخفی i ام و گره خروجی، a_i ($a_i\in R^n$) و b_i فاکتورهای آموزش گره‌های مخفی و $G(a_i, b_i, x)$ خروجی گره i ام برای ورودی x است. تابع فعالسازی g(x) (که دارای انواع مختلفی می‌باشند) برای گره مخفی افزاینده[7] $G(a_i, b_i, x)$ را می‌توان به شکل زیر بازنویسی کرد:

$$G(a_i,b_i,x)=g(a_i.x+b_i) \quad (۱۰$$

از توابع فعال‌سازی به‌منظور محاسبه خروجی پاسخ نرون ها استفاده می شود. زمانی که مجموعه‌ای از سیگنال ورودی وزن-

[1] feed-forward
[2] Huang
[3] Analytical
[4] single layer feed forward neural network
[5] bias
[6] piecewise continuous function
[7] additive

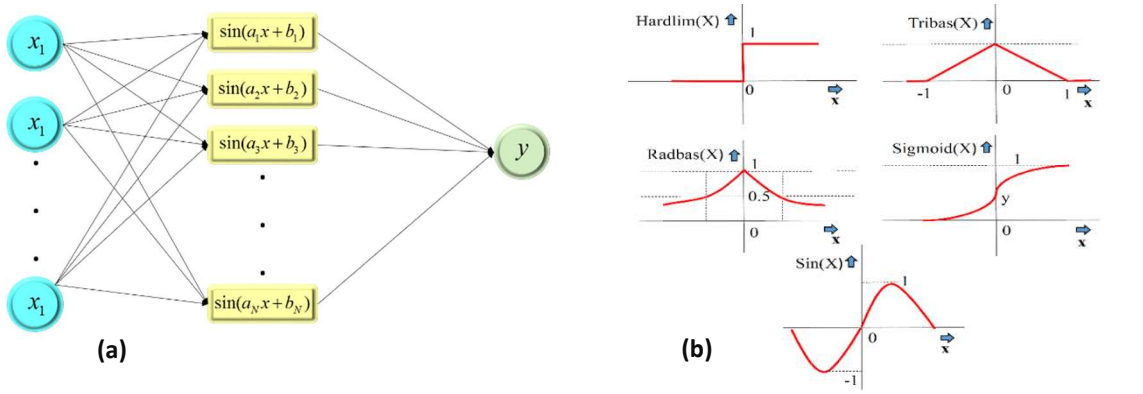
[Downloaded from journal.hydropower.org.ir on 2026-11-19]

دار اعمال می‌شود، برای بدست آوردن پاسخ از توابع فعال‌سازی استفاده می شود (پندی[1] و گووِیند[2] ۲۰۱۶). توابع فعال‌سازی غیرخطی ELM که در این مطالعه مورد بررسی قرار گرفته است شامل تابع پله‌ای (hardlim)، سیگموید[3] (sig)، سینوسی (sin)، بایاس مثلثی (tribas) و بایاس شعاعی (radbas) است که به صورت شکل ۵ تعریف می‌شوند.

فعالسازی نرون‌های لایه‌ی مخفی برای هر نمونه آموزشی در یک شبکه‌ی ELM با تعداد"j" نرون درلایه مخفی، "i" نرون ورودی و تعداد "k" نمونه‌ی آموزشی ، از رابطه‌ی زیر محاسبه می‌شود:

$$H_{jk} = g(\sum(W_{ji}X_{ik}) + B_j \qquad (۱۱$$

که g(.) می‌تواند هر تابع فعالسازی غیرخطی پیوسته باشد، W_{ji} وزن نرون ورودی iام و نرون لایه‌ی مخفی jام، B_j ، بایاس نرون لایه‌ی مخفی jام، X_{ik} ورودی نرون ورودی برای k امین نمونه آموزشی و H_{ik} ماتریس فعالسازی j امین نرون لایه‌ی مخفی برای k امین نمونه‌ی آموزشی است بطوریکه فعالسازی همه‌ی نرون‌های لایه‌ی مخفی برای نمونه‌های مورد استفاده در آموزش توسط این ماتریس ارائه می‌شود. در این ماتریس j ستون و k ردیف است. ماتریس H به عنوان ماتریس لایه‌ی مخفی خروجی شبکه عصبی بیان می‌شود. وزن‌های بین نرون‌های لایه مخفی و خروجی با استفاده از برازش حداقل مربعات برای مقادیر هدف در حالت آموزش در برابر خروجی‌های نرون-های لایه مخفی برای هر نمونه‌ی آموزشی، بکار برده می‌شود که معادل ریاضی آن را می‌توان به شکل زیر بیان کرد:



شکل (۵): الف-ساختار شبکه ELM ب-توابع فعال‌سازی مختلف در مدل ELM

$$H\beta = T \qquad (۱۲$$

$$\beta = (\beta_1,...,\beta_j)_{j\times 1} \qquad (۱۳$$

که β نشان دهنده‌ی وزن بین نرون لایه‌ی خورجی و نرون‌های لایه‌ی مخفی است و T بردار نشان دهنده‌ی مقادیر هدف برای نمونه‌های آموزش است که به صورت معادله (۱۳) بیان می-شود:

$$T = (T_1,...,T_k)_{k\times 1} \qquad (۱۴$$

نهایتاً وزن‌ها را می‌توان از رابطه‌ی (۱۴) محاسبه کرد:

$$\beta = H'T \qquad (۱۵$$

که در آن:

$$H(\tilde{a},\tilde{b},\tilde{x}) = \begin{bmatrix} G(a_1,b_1,x_1) & \dots & G(a_L,b_L,x_L) \\ G(a_1,b_1,x_N) & \dots & G(a_L,b_L,x_N) \end{bmatrix}_{N\times L} \qquad (۱۶$$

$$\beta = \begin{bmatrix} \beta_1^T \\ : \\ \beta_L^T \end{bmatrix}_{L\times m} \quad \text{and} \quad T = \begin{bmatrix} T_1^T \\ : \\ T_L^T \end{bmatrix}_{L\times m} \qquad (۱۷$$

[1] Pandey
[2] Govind
[3] sigmoid

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

که در آن $\tilde{a} = a_1, \dots, a_L, \tilde{b} = b_1, \dots, b_L;\ \tilde{x} = x_1, \dots, x_L$ و β بردار وزن بین نرون‌های لایه‌های مخفی و لایه پنهان و H′ شبه معکوس Moore-Penrose ماتریس H است. T بردار بین وزن‌های نمونه‌های آموزشی است. با توجه به توضیحات ارائه شده، می‌توان گفت که آموزش ELM، شامل دو مرحله است: مرحله اول، اختصاص تصادفی وزن‌ها و بایاس‌ها به نرون‌های لایه‌ی پنهان و محاسبه‌ی خروجی لایه پنهان ماتریس H و مرحله‌ی دوم، محاسبه‌ی وزن‌های خروجی با استفاده از شبه معکوس Moore-Penrose ماتریس H و مقادیر هدف برای نمونه‌های آموزشی مختلف است. روند آموزش، جهت پیدا کردن ماتریس لایه‌ی پنهان (H)، سریع است بطوریکه از سرعت بالاتری نسبت به الگوریتم‌های مبتنی بر تکرار رایج مانند لونبرگ-مارکوآردت[1] که در آن هیچ نوع روالی از بهینه‌سازی غیر خطی را در بر نمی‌گیرد، برخوردار است. بنابراین زمان آموزش شبکه به طور قابل توجهی کاهش می‌یابد (هوآنگ[2]، ۲۰۰۶).

به منظور مدلسازی با استفاده از مدل‌های مبتنی بر هوش مصنوعی همیشه داده‌های به صورت *outlier* وجود دارند و به دلیل اینکه عموماً وجود چنین نمونه‌هایی در بسیاری از موارد به طبیعت موجود در مسأله برمیگردد، امکان حذف آنها وجود ندارد. بنابراین، درصدی از کل خطای آموزش *(e)* را شامل می‌شود. به منظور برخورد با چنین داده‌هایی، وجود *outliers* با *sparsity* تعریف می شود. ژانگ[3] و لو[4] (۲۰۱۵) با دانش اینکه استفاده از *l_0-norm*، *sparsity* را نسبت به *l_2-norm* بهتر منعکس می کند، جهت محاسبه‌ی ماتریس وزن خروجی *(β)*، به جای استفاده از *l_2-norm*، خطای آموزش *(e)* را به گونه‌ای در نظر می گیرند که *sparse* باشد.

$$\min_{\beta} C\|\mathbf{e}\|_0 + \|\beta\|_2^2 \quad \text{subjectto } \mathbf{y} - \mathbf{H}\beta = \mathbf{e} \qquad (۱۸$$

$$\beta = [\beta_1, \dots, \beta_N]^T$$

(β)، ماتریس وزنهای خروجی است (w_o یا همان w_{output} است).

(یا در برخی منابع به این شکل نوشته می شود (w_o) ماتریس وزن‌های خروجی است):

$$(min_{w0} C\|e\|_0 + \|w_0\|_2^2 \quad subject\ to\ T - Hw_0$$

رابطه‌ی فوق یک مأله‌ی برنامه‌نویسی غیرمحدب[5] است. یکی از ساده‌ترین راه‌ها جهت حل این مسأله، نوشتن آن به صورت یک مسأله‌ی محدب قابل کنترل بدون از بین رفتن ویژگی پراکندگی[6] است. ترم پراکنده یا *sparse* با استفاده از *l_1-norm* بدست می آید. جایگذاری l_{0-norm} با l_{1-norm}، نه تنها منجر به حداقل سازی تحدب[7] (کم شدن تابع خطا) می شود بلکه وجود مشخصات پراکندگی یا وجود وقایع حدی (داده‌های نادر) را نیز تضمین می کند.

$$\min_{\beta} \|\mathbf{e}\|_1 + \frac{1}{C}\|\beta\|_2^2 \quad \text{subject to } \mathbf{y} - \mathbf{H}\beta = \mathbf{e} \qquad (۱۹$$

رابطه‌ی فوق یک مسأله‌ی بهنیه‌سازی محدب مقید[8] است به طوری که به طور کامل دامنه‌ی مناسب رویکرد تکمیل شده ضریب لاگرانژی[9] را تطبیق می کند.

$$\begin{aligned} L_\mu(e, \beta, \lambda) = \|e\|_1 &+ \frac{1}{C}\|\beta\|_2^2 \\ &+ \lambda^2(y - H\beta - e) \\ &+ \frac{\mu}{2}\|y - H\beta - e\|_2^2 \end{aligned} \qquad (۲۰$$

که $\mu = 2N/\|y\|_1$ (یانگ[10] و ژانگ[11]، ۲۰۱۱) بر پارامتر جریمه[12] دلالت دارد و $\lambda \in R^n$ بردار ضرب لاگرانژی است. جواب بهینه *(e,β)* و بردار ضرب لاگرانژی *(λ)* با استفاده از حداقل سازی تابع زیر طی فرایند تکراری، بدست می آید.

$$\begin{cases} (\mathbf{e}_{k+1}, \beta_{k+1}) = \arg\min_{\mathbf{e},\beta} L_\mu(\mathbf{e}, \beta, \lambda) & \text{(a)} \\ \lambda_{k+1} = \lambda_k + \mu(\mathbf{y} - \mathbf{H}\beta_{k+1} - \mathbf{e}_{k+1}) & \text{(b)} \end{cases}$$

مرحله‌ی آخر این تحقیق، تلفیق مدل ORELM با الگوریتم بهینه‌سازی MOGWO برای دستیابی به قواعد بهره‌برداری از سیستم در زمان واقعی در محیط MATLAB می‌باشد. با توجه به اینکه جعبه‌ی ابزار آماده‌ای برای این کار در محیط

[1] Levenberg-Marquardt
[2] Howang
[3] Zhang
[4] Luo
[5] non-convex programming
[6] tractable convex relaxation form without loss of the sparsity characteristic
[7] minimization convex
[8] constrained convex
[9] Augmented Lagrangian (AL) multiplier
[10] Yang
[11] Zhang
[12] penalty

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

MATLAB وجود ندارد، نسخه‌ی اولیه الگوریتم MOGWO که بصورت منبع باز[1] برای حل مسایل ریاضی ساده وجود دارد توسط نویسندگان این تحقیق برای حل مسئله‌ی بهینه‌سازی بهره‌برداری از مخزن با تعریف توابع هدف و قیود مورد اشاره در بخش‌های قبل توسعه داده شده و به مدل ORELM متصل شد. به این معنا که پس از استخراج مقدار رهاسازی بهینه از سد توسط الگوریتم MOGWO، در هر دوره‌ی شبیه‌سازی آتی به کمک ORELM و استفاده از نتایج الگوریتم بهینه‌ساز، 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، مقدار رهاسازی بهینه در زمان واقعی مشخص خواهد شد. فلوچارت مراحل انجام کار در شکل (۶) نشان داده شده است.

نتایج

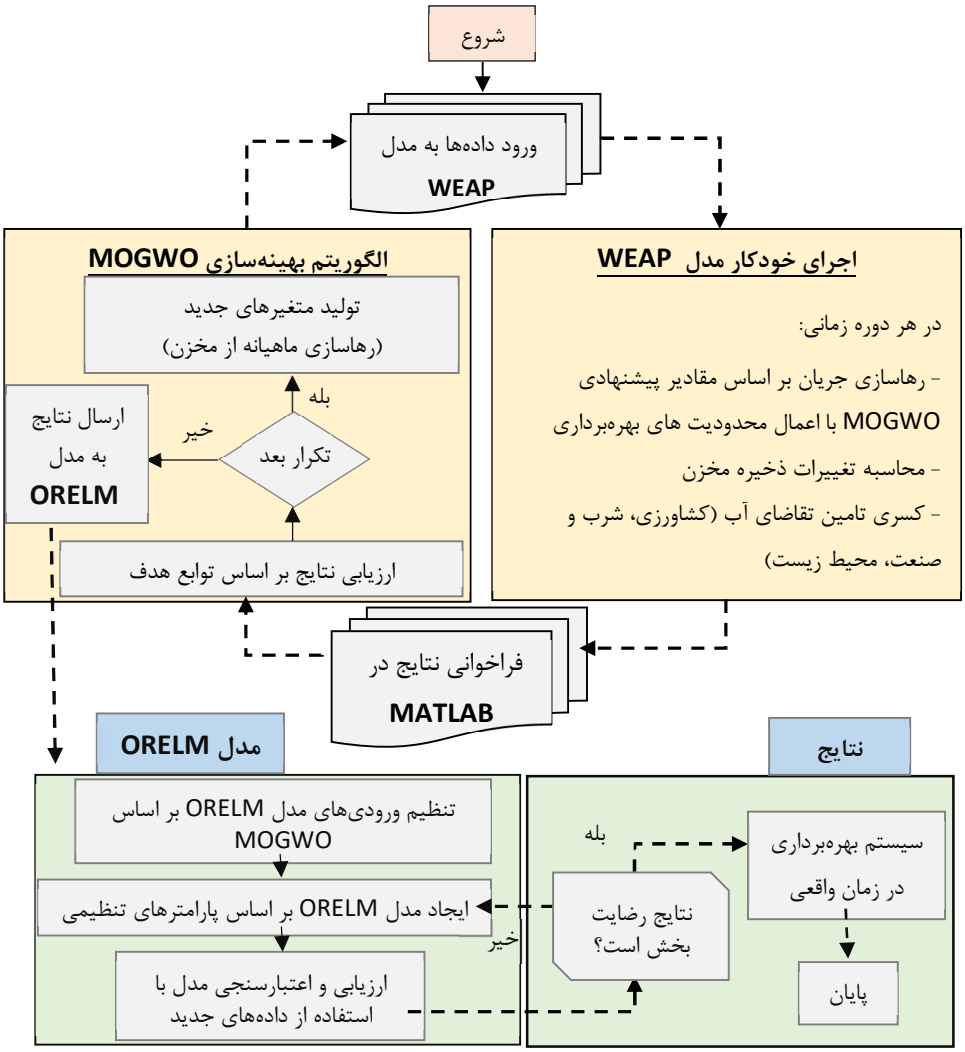
نتایج حاصل از روش بهینه‌سازی

در سناریوی بهینه، اجراهای مکرر مدل نشان داد برای رسیدن به نتایج بهتر، جمعیت اولیه (تعداد گرگ‌ها) باید حداقل دو برابر تعداد متغیرهای تصمیم باشد که در این تحقیق تعداد جمعیت اولیه در مدل در حدود ۴۸ انتخاب شد. نتایج نشان داد که در تکرارهای پایین‌تر میزان تابع Coverage و تابع خسارت (جریمه)، هر دو تغییرات محسوس دارند. اما در تکرارهای بالاتر دامنه تغییرات تابع Coverage ثابت شد و مدل بر روی کاهش جریمه متمرکز شد. با توجه به پیچیدگی مسأله و تعداد متغیرهای زیاد، تعداد تکرار الگوریتم جهت رسیدن به همگرایی در حدود ۱۰۰۰ در نظر گرفته شد. در نهایت پس از انجام بهینه‌سازی، با توجه به اندازه‌ی جمعیت ۴۸ و اجرای مدل MOGWO برای ۱۰۰۰ تکرار، جوابهای بهینه حاصل شد و منحنی تبادل بهینه (گراف پارتو[2]) بین اهداف بهینه‌سازی (حداکثرسازی درصد تأمین نیاز و حداقل‌سازی جریمه‌ی ناشی از تخطی سیستم از ظرفیت‌های مجاز مخزن) به دست آمد. مطابق با روش الگوریتم MOGWO، در هر تکرار بهترین جواب‌ها بر اساس ارزش‌گذاری توابع هدف انتخاب می‌شوند و تحت عنوان مجموعه بهینه F_1 جهت 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 مجموعه‌ی ۲۴ جواب بهینه بر اساس توابع هدف F_1 و F_2 در آخرین تکرار در شکل (۷) نشان داده شده است.

[1] Open Source

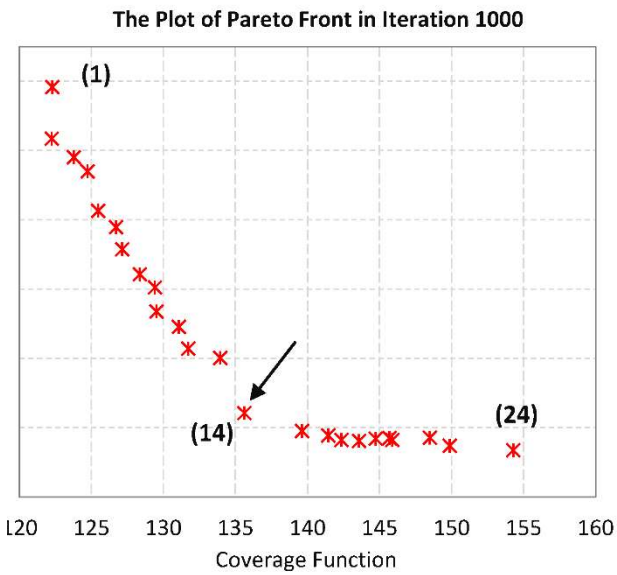
[2] Pareto-optimal Front

[Downloaded from journal.hydropower.org.ir on 2026-11-19]



شکل (۶): فلوچارت مراحل ترکیب نتایج الگوریتم MOGWO با مدل ORELM

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

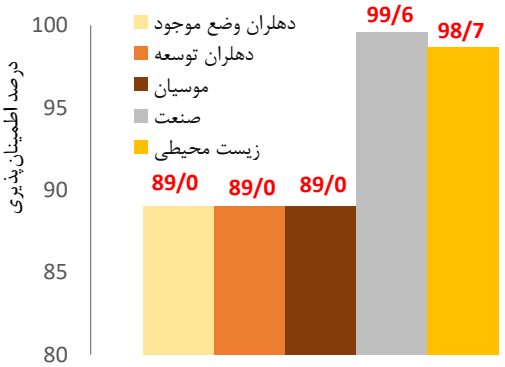


شکل (۷): منحنی تبادل بهینه بین اهداف بهینه‌سازی (منحنی پارتو) در تکرار ۱۰۰۰

از بین ۲۴ جواب ارائه شده در منحنی پارتو در آخرین تکرار الگوریتم، با انتخاب جواب شماره ۱، مقدار Coverage Function دارای کمترین مقدار خواهد بود که مناسب است اما مقدار Penalty Function دارای بیشترین مقدار خواهد بود که به هیچ وجه مطلوب نیست. با انتخاب جواب شماره ۲۴، مقدار مطلوبیت این دو تابع برعکس خواهد بود و این بار مقدار Coverage Function دارای بیشترین مقدار خواهد شد که از این نظر نامطلوب می باشد. لذا بر اساس ارزش‌گذاری توابع هدف، راه‌حلی که بطور نسبی در مقایسه با سایر راه حلها دارای مناسب ترین مقدار برای هر دو تابع هدف بود به عنوان جواب برتر انتخاب شد (راه حل شماره ۱۴). متغیرهای تصمیم بهینه‌ی پیشنهادی توسط این راه‌حل در مدل آب سطحی ویپ وارد شده و نتایج حاصل از آن ذخیره شد.

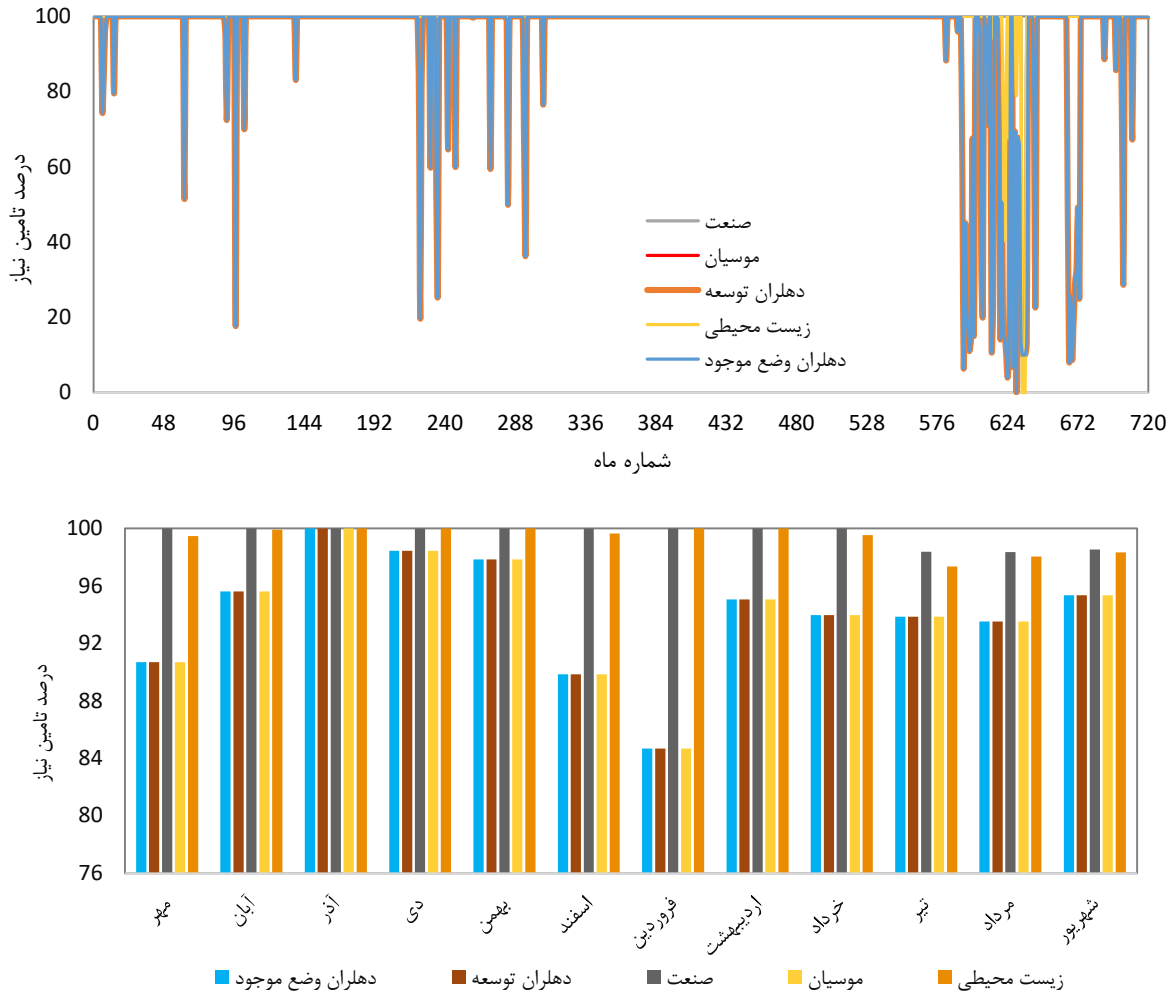
شکل (۸) مقدار اطمینان‌پذیری و شکل (۹) درصد تأمین نیاز هر کدام از مصارف پس از بهینه‌سازی سیستم را نشان می‌دهد.

شکل ۹ نشان می دهد درصد تامین نیاز مصارف مختلف با اعمال جواب بهینه حاصل از الگوریتم MOGWO (راه‌حل شماره ۱۴)، با در نظر گرفتن کل دوره‌ی بهره‌برداری قابل قبول بوده و میانگین درصد تأمین نیاز حتی در ماههای کم آب بیش از ۸۴ درصد است. لذا در کل دوره‌ی بهره‌برداری، الگوریتم بهینه‌سازی مبتنی بر قواعد جیره‌بندی، بیشترین کارایی خود را در تأمین نیاز مصارف بخصوص در ماههای کم آب داشته تا از شکست کامل در این ماهها جلوگیری کند. نتایج نشان می‌دهد مدل کوپل شده شبیه‌ساز-بهینه‌ساز تنها به دنبال افزایش درصد تأمین نیاز نبوده و علاوه بر در نظر داشتن حداکثرسازی تأمین نیاز در کل دوره بهره‌برداری، هدف حداقل سازی جریمه‌ی ناشی از تخطی از ظرفیت‌های مجاز مخزن را نیز در نظر داشته است. طوری که سیستم پس از افزایش درصد تأمین نیاز ها تا حد امکان کمترین میزان تخطی از تراز حداقل بهره‌برداری را داشته باشد. شکل (۱۰) عملکرد مخزن را در طول دوره بهره‌برداری (۷۲۰ ماه) نشان می‌دهد.

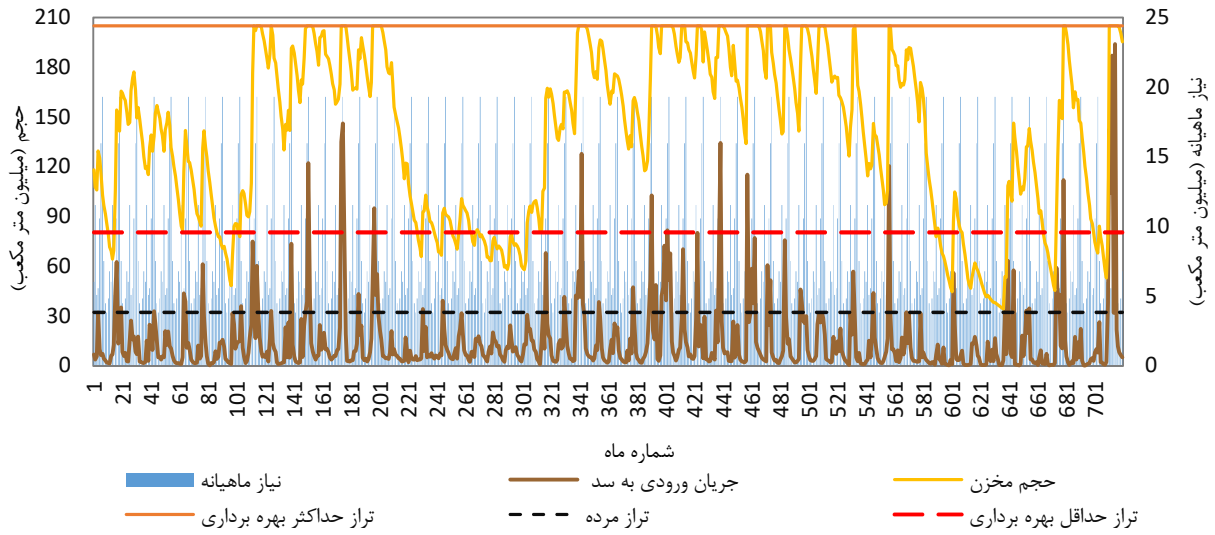


شکل (۸): مقادیر اطمینان‌پذیری تأمین نیاز هر کدام از مصارف مختلف پس از بهینه‌سازی سیستم توسط MOGWO

[Downloaded from journal.hydropower.org.ir on 2026-11-19]



شکل (۹): درصد تامین نیاز مصارف مختلف پس از بهینه‌سازی سیستم با MOGWO



شکل (۱۰): میزان تغییرات ذخیره مخزن سد دویرج در طول دوره‌ی بهره‌برداری پس از بهینه‌سازی سیستم توسط MOGWO

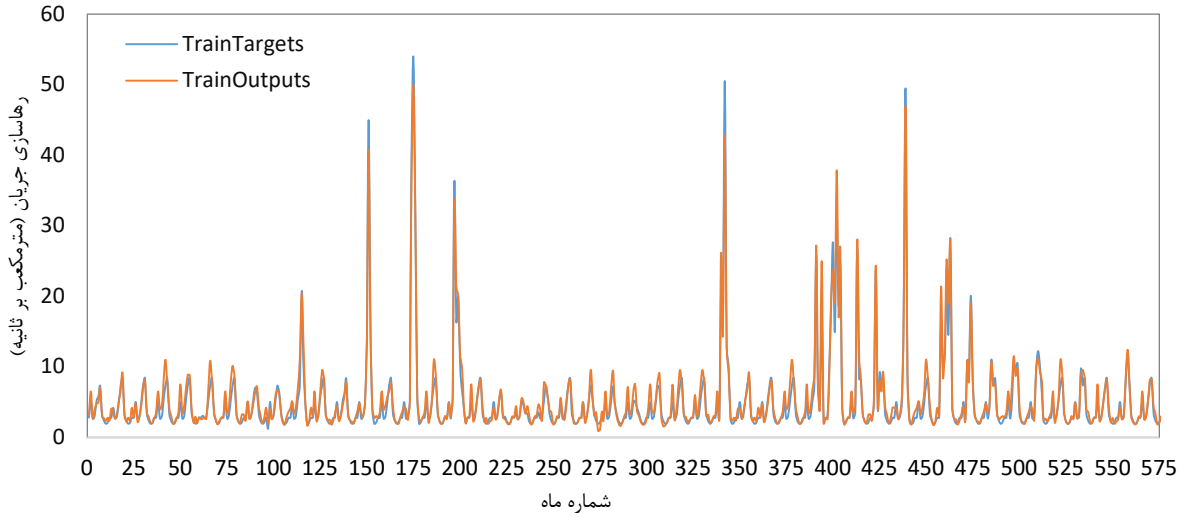
[Downloaded from journal.hydropower.org.ir on 2026-11-19]

مطابق با شکل (۱۰)، پس از بهینه‌سازی سیستم، به دلیل اعمال ضریب جیره‌بندی و اجرای تابع جریمه در طول دوره‌ی برنامه‌ریزی، تا حد امکان به جز چند ماه، میزان ذخیره مخزن از میزان ذخیره در حداقل تراز بهره‌برداری سد پایین‌تر نیامده است. این امر کمک می‌کند تا در شرایط خشکسالی شدید، با اعمال جیره‌بندی آب، حجم ذخیره مخزن به خوبی مدیریت شود تا علاوه بر تأمین نیازها با اطمینان‌پذیری مطلوب، شدت شکست ها در ماه‌هایی که با کمبود آب شدید مواجه هستیم کاهش یابد. بر این اساس، می‌توان اذعان کرد که اجرای سیاست جیره‌بندی در مخازن واقعی با استفاده از دو پارامتر تراز جیره‌بندی و ضریب جیره‌بندی نتایج رضایت‌بخشی به همراه خواهد داشت. طوری که در طول دوره بهره‌برداری منجر به کاهش تعداد ماههای شکست و شدت شکست در تأمین نیازها خواهد شد. این امر در مخزن سد دویرج با تعیین مقدار بهینه‌ی این پارامترها با استفاده از ترکیب الگوریتم بهینه‌سازی MOGWO با مدل شبیه‌ساز WEAP به خوبی اثبات شد.

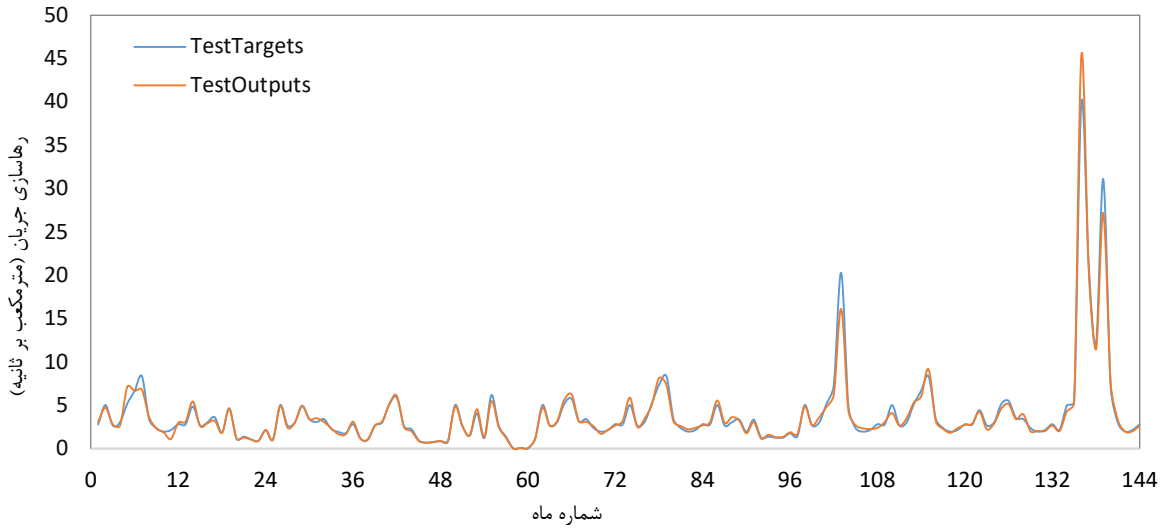
نتایج حاصل از ترکیب ORELM و MOGWO

در این تحقیق برای استفاده از نتایج بهینه‌سازی با الگوریتم MOGWO در زمان واقعی از مدل ORELM استفاده شد. ابتدا این مدل بر اساس خروجی الگوریتم MOGWO و برای یک دوره‌ی ۵۷۶ ماهه آموزش داده شدند. سپس برای یک دوره‌ی ۱۴۴ 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 ذخیره‌ی آب در مخزن (در ابتدای ماه) و تغییرات ذخیره‌ی مخزن و نیازهای پایین دست در ماه حاضر، مقدار رهاسازی بهینه، بر اساس مدل ORELM بدست آمد و نتایج حاصل با خروجی حاصل از الگوریتم بهینه‌سازی در این دوره‌ی ۱۴۴ ماهه مقایسه شد. بر اساس صحت‌سنجی، مدل ORELM 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.

در شکل (۱۱) نتایج صحت‌سنجی پیش‌بینی مدل ORELM بر اساس خروجی الگوریتم بهینه‌سازی آورده شده است.

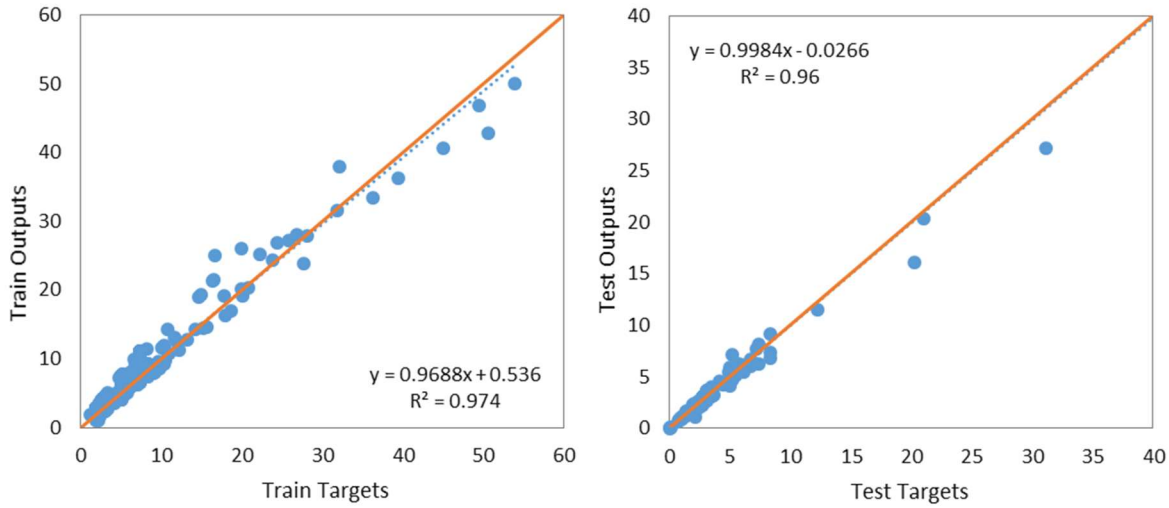


[Downloaded from journal.hydropower.org.ir on 2026-11-19]

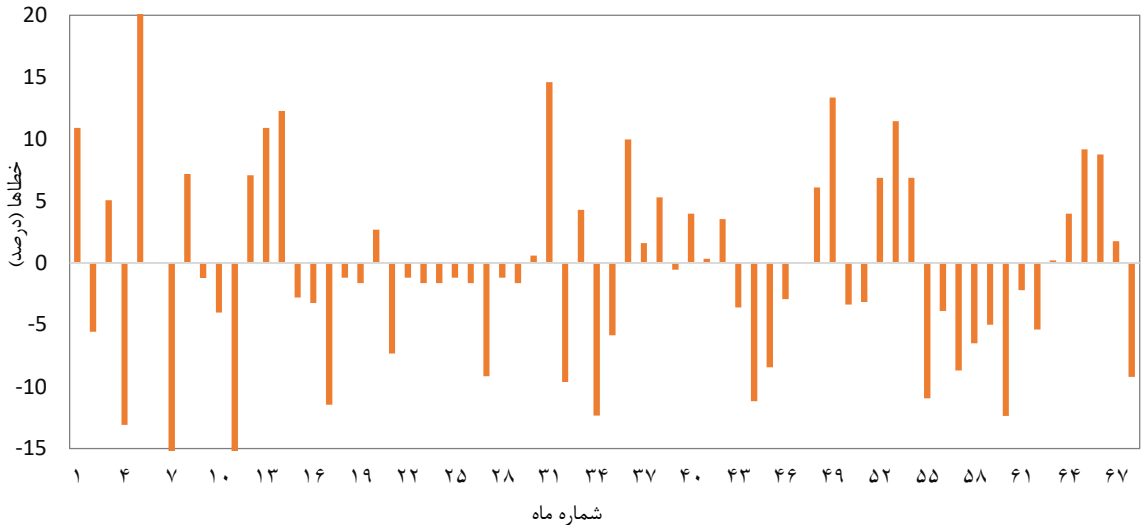


شکل (۱۱): پیش‌بینی میزان رهاسازی بهینه از سد دویرج توسط مدل ORELM در مراحل train و test

شکل (۱۱) 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 می‌دهد. همچنین میزان خطای نسبی مدل توسعه داده شده در تخمین مقدار رهاسازی بهینه از سد بر اساس داده‌های جدید در شکل (8.b) نشان داده شده است.



[Downloaded from journal.hydropower.org.ir on 2026-11-19]



شکل (۱۲): الف- پراکنش نقاط مشاهداتی و پیش‌بینی شده اطراف خط y=x در مراحل train و test در مدل ORELM ب- درصد خطای نسبی مدل ORELM برای تخمین میزان رهاسازی بهینه از سد دویرج در مرحله test

شکل (۱۲-الف) مقدار ضریب همبستگی بین داده‌های مشاهداتی و پیش‌بینی شده و پراکنش این نقاط در اطراف خط y=x را در دو مرحله train و test نشان می دهد. مقدار R بالا در این شکل نشان دهنده کارایی مدل ORELM برای تخمین خروجی بهینه سد در زمان واقعی است. شکل (۱۲-ب) مقدار خطای پیش‌بینی در حالت استفاده از سری داده‌های جدیدی که در آموزش استفاده نشده را نشان می دهد. بر اساس این شکل میانگین درصد خطا برای ۱۴۴ ماه کمتر از ۸ درصد و بیشترین میزان خطا حدود ۲۰ درصد بوده است.

نتیجه‌گیری

به طور کلی نتایج نشان داد مدل توسعه داده شده بر اساس ترکیب الگوریتم چند هدفه MOGWO و مدل شبیه‌سازی WEAP قابلیت و کارایی مناسبی در حل مسائل پیچیده و کاملا غیرخطی و ارائه جواب‌های بهینه دارد. طوری که الگوریتم در آخرین تکرار، منحنی تبادل اهداف بر اساس ۲۴ جواب در جبهه بهینه پارتو تشکیل شد. از بین این راهحل‌ها، با توجه به ارزش‌گذاری توابع هدف، راه حلی که هم زمان دارای کم‌ترین میزان تابع جریمه ناشی از تخطی از ظرفیت مجاز مخزن و بیشترین میزان درصد تأمین نیاز مصارف بود به عنوان جواب برتر انتخاب شد. نتایج کاربرد مقادیر رهاسازی بهینه از سد (منحنی فرمان بهینه سد) نشان داد با در نظر گرفتن سیاست بهینه، درصد تأمین و اطمینان‌پذیری تأمین اکثر نیازها به طور مناسب و قابل قبولی است. مقادیر رهاسازی بهینه یا منحنی فرمان بهینه حاصل از ترکیب الگوریتم MOGWO و شبیه‌ساز WEAP بر اساس یک سری معین از جریان ورودی به مخزن در طول دوره‌ی بهره‌برداری است و رهاسازی از مخزن جهت تأمین مصارف پایین دست در این شرایط بهینه گردید. 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 مخازن، به احتمال زیاد جواب‌های بهینه‌ی بدست آمده، کارایی نداشته و باید بهره‌برداری از سیستم در قالب الگوریتم بهینه‌ساز مجددا بهینه گردد. لذا برای استفاده از نتایج بهینه‌سازی در زمان واقعی از مدل ORELM استفاده شد. نتایج نشان داد میزان میانگین خطای قوانین بهینه مستخرج از ORELM نسبت به خروجی الگوریتم بهینه‌سازی MOGWO در مرحله صحت‌سنجی کمتر از ۶ درصد است که نشان دهنده‌ی دقت بالاتر این روش در پیش‌بینی الگوی بهینه منحنی فرمان سد در زمان واقعی نسبت به مدل‌های دیگر است. لذا در این ساختار می‌توان بر اساس جریان ورودی به مخزن (در ابتدای ماه)، حجم ذخیره‌ی آب در مخزن (در ابتدای ماه) و تغییرات ذخیره مخزن و

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

نیازهای پایین دست در ماه حاضر، مقدار رهاسازی بهینه را در زمان واقعی بدست آورد. یعنی مدل ترکیبی MOGWO-ORELM توسعه داده شده این قابلیت را داشته که با توجه به ورودی‌های جدید جریان به سد، سریعاً سیاست‌های بهره‌برداری بهینه را به نحوی در اختیار قرار دهد که امکان مدیریت بهینه سیستم در زمان واقعی فراهم گردد.

مراجع

Amiri S, Rajabi A, Shabanlou S, Yosefvand F, izadbakhsh MA. Prediction of groundwater level variations using deep learning methods and GMS numerical model. Earth Science Informatic, (2023). https://doi.org/10.1007/s12145-023-01052-1

Azari A, Zeynoddin M, Ebtehaj I, Sattar AMA, Gharabaghi B, Bonakdari H. Integrated preprocessing techniques with linear stochastic approaches in groundwater level forecasting. Acta Geophysica, (2021); 69, 1395–1411.

Azari A, Hamzeh S, Naderi S. Multi-objective optimization of the reservoir system operation by using the hedging policy. Water Resources. Management, (2018); 32 (6), 2061–2078.

Azizi E, Yosefvand F, Yaghoubi B, Izadbakhsh MA, Shabanlou S. Modelling and prediction of groundwater level using wavelet transform and machine learning methods: A case study for the Sahneh Plain, Iran. Irrigation and Drainage, (2023); 72(3), 747–762.

Azizpour A, Izadbakhsh MA, Shabanlou S, Yosefvand F, Rajabi A. Estimation of water level fluctuations in groundwater through a hybrid learning machine, Groundwater for Sustainable Development, (2021); 15, 100687.

Azizpour A, Izadbakhsh MA, Shabanlou S, Yosefvand F, Rajabi A. Simulation of time-series groundwater parameters using a hybrid metaheuristic neuro-fuzzy model. Environment Science Pollution Research, (2022); 29, 28414–28430.

Bayesteh M, Azari A. Stochastic Optimization of Reservoir Operation by Applying Hedging Rules. Journal of Water Resources Planning and Management, (2021); 147(2), 04020099.

Blum C, Roli A. Metaheuristics in combinational optimization: Overview and conceptual comparision. ACM Computing Surveys, (2003); 35(3), 268-308.

Candela JQ, Hansen LK. Time series prediction based on the Relevance Vector Machine with adaptive kernels, Acoustics, Speech, and Signal Processing (ICASSP), 2002 IEEE International Conference, vol.1, no., pp. 985-988, 13-17 May 2002.

Chang JF, Chen L, Chang CL. Optimizing reservoir operating rule curves by genetic algorithms. Hydrological Processes, (2005); 19, 2277-2289.

Du J, Liu Y, Yu Y, Yan W. A Prediction of Precipitation Data Based on Support Vector Machine and Particle Swarm Optimization (PSO-SVM) Algorithms. Algorithms, (2017); 10(57), 1-15.

Ebtehaj I, Bonakdari H, Zeynoddin M, Gharabaghi B, Azari A. Evaluation of preprocessing techniques for improving the accuracy of stochastic rainfall forecast models. International Journal of Environmental Science and Technology, (2020); 17, 505–524.

Esmaeili F, Shabanlou S, Saadat MA. Wavelet-outlier robust extreme learning machine for rainfall forecasting in Ardabil City. Iran. Earth Sci Inform, (2021); 14, 2087–2100.

Fallahi MM, Shabanlou S, Rajabi A, Yosefvand F, izadbakhsh MA. Effects of climate change on groundwater level variations affected by uncertainty (case study: Razan aquifer). Applied Water Science, (2023); 13, 143.

Moghadam RG, Izadbakhsh MA, Yosefvand F, Shabanlou S. Optimization of ANFIS network using firefly algorithm for simulating discharge coefficient of side orifices. Applied Water Science, (2019); 9, 84.

Gharib R, Heydari M, Kardar S, Shabanlou S. Simulation of discharge coefficient of side weirs placed on convergent canals using modern self-adaptive extreme learning machine. Applied Water Science, (2020); 10, 50.

Goorani Z, Shabanlou S. Multi-objective optimization of quantitative-qualitative operation of water resources systems with approach of supplying environmental demands of Shadegan Wetland, Journal of Environmental Management, (2021); 292(6), 112769.

Jian C, Qiang H, Min W. Genetic algorithm for optimal dispatchin. Water Resource Planning and Management, (2005); 19, 321-331.

Kalita HM, Sarma AK, Bhattacharjya PK. Evaluation of Optimal River Training Work Using GA Based Linked Simulation-Optimization Approach, Water Resources Management, (2007); 28, 2077–2092.

Lei J, Quan Q, Li P, Yan D. Research on Monthly Precipitation Prediction Based on the Least Square Support Vector Machine with Multi-Factor Integration, Atmosphere, (2021); 12(8), 1076.

Lin JY, Cheng CT, Chau KW. Using support vector machines for long-term discharge prediction. Hydrological Sciences–Journal–des Sciences Hydrologiques, (2006), 51(4), 599-612.

Malekzadeh M, Kardar S, Saeb K, Shabanlou S, Taghavi L. A novel approach for prediction of monthly ground water level using a hybrid wavelet and non-tuned self-adaptive machine learning model. Water resources management, (2019a); 33: 1609-1628.

Malekzadeh M, Kardar S, Shabanlou S. Simulation of groundwater level using MODFLOW, extreme learning machine and Wavelet-Extreme Learning Machine models, Groundwater for Sustainable Development, (2019b); 9, 100279.

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

Tennant DL. Instream flow regimens for fish, wildlife, recreation and related environmental resources. Fisheries, (1976b); 1(4), 6-10.

Thissen U, van Brakel R, de Weijer AP, Melssen WJ, Buydens LMC. Using support vector machines for time series prediction. Chemometrics and Intelligent Laboratory Systems, (2003); 69, 35–49.

Wardlaw R, Sharif M. Evaluation of genetic algorithms for optimal reservoir system operation. Water Resource Planning and Management, (1999); 125(1), 25-33.

Xi XC, Poo AN, Cho SK. Support vector regression model predictive control on a HVAC plant. Control Engineering Practice, (2007), 15, 897–908.

Yosefvand F, Shabanlou S. Forecasting of Groundwater Level Using Ensemble Hybrid Wavelet–Self-adaptive Extreme Learning Machine-Based Models. Natural Resource Research, (2020); 29, 3215–3232.

Zarei S, Yosefvand F, Shabanlou S. Discharge coefficient of side weirs on converging channels using extreme learning machine modeling method. Measurement, (2020); 152, 107321.

Zeinali M, Azari A, Heidari M. Simulating Unsaturated Zone of Soil for Estimating the Recharge Rate and Flow Exchange Between a River and an Aquifer. Water Resources Management, (2020a); 34, 425–443.

Zeinali M, Azari A, Heidari M. Multi objective Optimization for Water Resource Management in Low-Flow Areas Based on a Coupled Surface Water–Groundwater Model. Journal of Water Resource Planning and Management (ASCE), (2020b);146(5), 04020020.

Zeynoddin M, Bonakdari H, Azari A, Ebtehaj I, Gharabaghi B, Madavar HR. Novel hybrid linear stochastic with non-linear extreme learning machine methods for forecasting monthly rainfall a tropical climate. Journal of environmental management, (2018); 222, 190-206.

Zeynoddin M, Bonakdari H, Ebtehaj I, Azari A, Gharabaghi B. A generalized linear stochastic model for lake level prediction. Science of The Total Environment, (2020), 723, 138015.

Mazraeh A, Bagherifar M, Shabanlou S, Ekhlasmand R. A Hybrid Machine Learning Model for Modeling Nitrate Concentration in Water Sources. Water, Air, & Soil Pollution, (2023); 234(11), 1-22.

Mohammed KS, Shabanlou S, Rajabi A. Yosefvand F, izadbakhsh MA. Prediction of groundwater level fluctuations using artificial intelligence-based models and GMS. Applied Water Science, (2023); 13, 54.

Momtahen Sh, Dariane AB. Direct search approaches using genetic algorithms for optimization of water reservoir operating policies. Water Resource Planning and Management, (2007); 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. State of the Art for Genetic Algorithms and Beyond in Water Resources Planning and Management. Journal of Water Resources Planning and Management, (2010); 136, 412-432.

Poursaeid M, Mastouri R, Shabanlou S, Najarchi M. Estimation of total dissolved solids, electrical conductivity, Salinity and groundwater levels using novel learning machines. Environment Earth Science, (2020); 79:1–25.

Poursaeid M, Mastouri R, Shabanlou S, Najarchi M. Modelling qualitative and quantitative parameters of groundwater using a new wavelet conjunction heuristic method: wavelet extreme learning machine versus wavelet neural networks. Water and Environment Journal, (2021); 35, 67–83.

Rafiee Anzab N, Mousavi SJ, Rousta BA, Kim JH, Simulation Optimization for Optimal Sizing of Water Transfer Systems. Springer-Verlag Berlin Heidelberg, (2016); 365-375

Shabanlou S. Improvement of extreme learning machine using self-adaptive evolutionary algorithm for estimating discharge capacity of sharp-crested weirs located on the end of circular channels. Flow Measurement and Instrumentation, (2018); 59, 63-71. (2018)

Su J, Wang X, Liang Y Chen B. GA-Based Support Vector Machine Model for the Prediction of Monthly Reservoir Storage, Journal of Hydrologic Engineering, (2014); 19(7), 1430-1437.

[Downloaded from journal.hydropower.org.ir on 2026-11-19]

نشریه علمی سد و نیروگاه برق آبی ایران
سال دهم/ شماره سی و پنجم/ پاییز ۱۴۰۲

Journal of Iranian Dam and Hydroelectric Power Plant
10th Year/ No. 35/ December 2023

Optimization of Water Resources Systems in Real Time based on the Integration of Multi-objective Grey Wolf Algorithm and Artificial intelligence

Hasan Biglari[1]
Saeed Jamali*[2]
Hooman Hajikandi[3]
Saeid Shabanlou[4]

Abstract
One of the ways to manage water resource systems is to use optimization algorithms to implement optimal reservoir operation policies in a deterministic optimization format. In this paper, the multi-objective gray wolf optimization algorithm is utilized for the optimal operation of the Doiraj dam reservoir in such a way that the first objective is to maximize the percentage of supplying demands is placed against the second objective, i.e., minimizing the violation of the allowed capacity of the reservoir during the operation period. In this regard, the reservoir operation modeling is done based on the current situation of the region and for a 720-month period (October 1960 to September 2019) and the rule curve of the dam or the amount of release from the reservoir to provide downstream demands is optimized in these conditions. However, in the deterministic optimization, optimal solutions are not generalizable to other possible inputs to the reservoir and in the case where the inflow to the reservoir is altered, optimal solutions are no longer valid and the operation of the system should be repeated in the form of an optimizer algorithm. Thus, to solve this issue, a new method based on the integration of artificial intelligence and the MOGWO algorithm is developed for the optimal operation of the system in real time. The findings indicate that the average error value of optimal rules extracted from the ORELM model is less than 6% in the verification stage showing the efficiency of this method in predicting the optimal pattern of the dam rule curve in real time. In this structure, the developed hybrid MOGWO-ANN model has this ability to provide optimal operation policies regarding new data of inflow to the dam to allow us to manage the system optimally in real time.
Keywords:
Deterministic optimization, real time, MOGWO, artificial intelligence, Doiraj dam

[1] Ph.D. Candidate, Department of Civil Engineering, Faculty of Civil and Earth Resources Engineering, Islamic Azad University-Tehran Central Branch, Tehran, Iran.
[2] Department of Civil Engineering, Faculty of Civil and Earth Resources Engineering, Islamic Azad University-Tehran Central Branch, Tehran, Iran. E-mail: sae.jamali@iauctb.ac.ir
[3] Department of Civil Engineering, Faculty of Civil and Earth Resources Engineering, Islamic Azad University-Tehran Central Branch, Tehran, Iran.
[4] Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

Received: 2023/02/15 Accepted: 2023/09/30

[Downloaded from journal.hydropower.org.ir on 2026-11-19]