

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

حسن بیگلری^۱
سعید جمالی*^۲
هومن حاجی‌کندی^۳
سعید شعبانلو^۴

چکیده

الگوریتم‌های بهینه‌سازی چندهدفه، ابزاری قدرتمند برای بهره‌برداری بهینه از منابع آب و تعیین منحنی فرمان بهینه سدها می‌باشد. 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 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، دانشکده آزاد اسلامی، کرمانشاه، ایران

علمی-پژوهشی

مقدمه

مسائل مختلف بهینه‌سازی است (واردلاو و شریف^۵، ۱۹۹۹؛ نیکلاو و همکاران^۶، ۲۰۱۰؛ کالیتا و همکاران^۷، ۲۰۱۴). چانگ و همکاران^۸ 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^۹ 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^{۱۰} در سال ۲۰۱۸، گورانی و همکاران^{۱۱} در سال ۲۰۲۱، جیان و همکاران^{۱۲} در سال ۲۰۲۰، زینعلی و همکاران^{۱۳} 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 مخزن، 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^{۱۴}، ۲۰۲۱). 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

بهره‌برداری اصولی از مخازن و سدهای مخزنی نقش بسیار مهمی را در تأمین آب ایفا می‌نماید و بدین جهت که مقاصد چندانگانه‌ای 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 پاسخ‌های محیط به سناریوها یا راه‌حل‌های پیشنهادی، همواره مورد توجه مدیران و محققان بخش آب بوده است (زینعلی و همکاران^۱، ۲۰۲۰a؛ رفیعی انزاب و همکاران^۲، 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^۳، ۲۰۰۳).

ساختار بهینه‌سازی معین^۴ 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

8- Chang et al.

9- Momtahan & Dariane

10 Azari et al

11 Goorani et al

12 Jian et al

13 Zeinali et al

14 Bayesteh and Azari

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

هیدروکلیماتولوژی مانند دما، بارندگی، جریان رودخانه ها و تغییرات تراز آب مخازن سطحی و آب زیرزمینی استفاده شده است (زین الدین و همکاران^{۱۳}، ۲۰۱۸؛ سلطانی و همکاران^{۱۴}، ۲۰۲۱؛ اسماعیلی و همکاران^{۱۵}، ۲۰۲۱). در سالهای اخیر، در کنار روشهای استوکاستیک (ابتهاج و همکاران^{۱۶}، ۲۰۲۰؛ زین الدین و همکاران^{۱۷}، ۲۰۲۰؛ آذری و همکاران^{۱۸}، ۲۰۲۱) بصورت گسترده از روش های مبتنی بر هوش مصنوعی مانند ماشین آموزش نیرومند با داده های پرت^{۱۹} (ORELM)، ماشین آموزش نیرومند^{۲۰} (ELM) و روش کنترل گروهی داده ها^{۲۱} (GMDH) و روشهای هیبرید^{۲۲} برای پیش بینی پارامترهای هیدروکلیماتولوژی مانند دما، بارندگی، جریان رودخانه ها و تغییرات تراز آب مخازن سطحی و آب زیرزمینی استفاده شده است (زین الدین و همکاران^{۲۳}، ۲۰۱۸؛ سلطانی و همکاران^{۲۴}، ۲۰۲۱؛ اسماعیلی و همکاران^{۲۵}، ۲۰۲۱؛ یوسفوند و شعبانلو^{۲۶}، ۲۰۲۰؛ پورسعید و همکاران^{۲۷}، ۲۰۲۰، ۲۰۲۱؛ عزیزپور و همکاران^{۲۸}، ۲۰۱۹ الف و ب؛ ملکزاده و همکاران^{۲۹}، ۲۰۱۹ الف و ب؛ محمد و همکاران^{۳۰}، ۲۰۲۳؛ امیری و همکاران^{۳۱}، ۲۰۲۳؛ فلاحی و همکاران^{۳۲}، ۲۰۲۳؛ گرامی مقدم و همکاران^{۳۳}، ۲۰۱۹؛ شعبانلو^{۳۴}، ۲۰۱۸، قریب و همکاران^{۳۵}، ۲۰۲۰؛ زارعی و همکاران^{۳۶}، ۲۰۲۰). ایده اصلی تحقیق حاضر، استفاده تلفیقی از الگوریتم بهینه سازی چندهدفه گرگ خاکستری^{۳۷} (MOGWO) و مدل های مبتنی بر هوش مصنوعی برای بهره برداری بهینه از سیستم های منابع آب در زمان واقعی است. بر

خواهد شد. راهکار دیگر، استفاده از روش های هوشمند، مانند ماشین های بردار پشتیبان برای بکار بردن نتایج حاصل از بهینه سازی سیستم در زمان واقعی است. در بسیاری از تحقیقات، روش موسوم به ماشین های بردار رگرسیون که بر اساس ماشین بردار پشتیبان توسعه یافته است برای پیش بینی سری زمانی استفاده شده است. تیسن و همکاران^۱ در سال ۲۰۰۳ و لین و همکاران^۲ در سال ۲۰۰۶ دریافتند که ماشین های بردار پشتیبان نسبت به مدل های ARMA و شبکه های عصبی مصنوعی کارایی بهتری برای پیش بینی سری زمانی دارد و نتایج آن به واقعیت نزدیکتر است. دو و همکاران^۳ در سال ۲۰۱۷ از ترکیب ماشین بردار پشتیبان و الگوریتم ازدحام ذرات، برای پیش بینی بارندگی سه ساعته ایستگاه هواشناسی واقع در نانجینگ چین استفاده کردند. سو و همکاران^۴ در سال ۲۰۱۴ از GA-SVM برای پیش بینی حجم ذخیره ی ماهلنه مخزن Miyun در چین استفاده کردند. مدل ترکیبی GA-SVM، توسط برخی محققان برای افزایش دقت پیش بینی پارامترهای هیدرولوژیکی استفاده شده است (لی و همکاران^۵، ۲۰۲۱). در سالهای اخیر، در کنار روشهای استوکاستیک (ابتهاج و همکاران^۶، ۲۰۲۰؛ زین الدین و همکاران^۷، ۲۰۲۰؛ آذری و همکاران^۸، ۲۰۲۱) بصورت گسترده از روش های مبتنی بر هوش مصنوعی مانند ماشین آموزش نیرومند با داده های پرت^۹ (ORELM)، ماشین آموزش نیرومند^{۱۰} (ELM) و روش کنترل گروهی داده ها^{۱۱} (GMDH) و روشهای هیبرید^{۱۲} برای پیش بینی پارامترهای

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)

1 Thissen et al.
 2 Lin et al.
 3 Du et al.
 4 Su et al.
 5 Lei et al
 6 Ebtehaj et 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 Ebtehaj et al
 17 Zeynoddin et al
 18 Azari et al
 19 Outlier Robust Extreme Learning Machine (GMDH)
 20 Extreme Learning Machine (ELM)

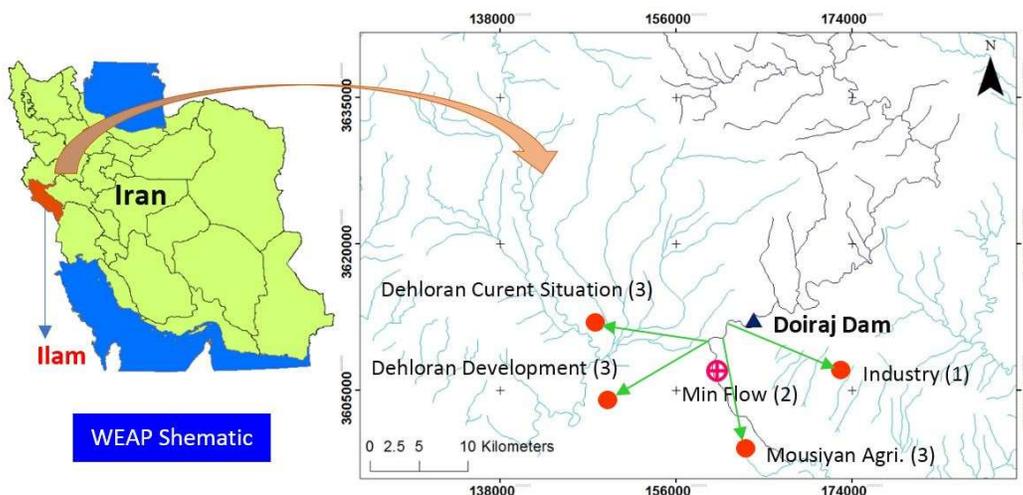
آتی با مشخص بودن چهار پارامتر اول در ابتدای هر ماه مقدار رهاسازی بهینه در زمان واقعی مشخص خواهد شد. در این ساختار، برخلاف ساختار رایج برنامه‌ریزی معین، در صورت تغییر جریان ورودی، نیازی به انجام بهینه‌سازی مجدد، برای تعیین ضرایب بهینه نیست، بلکه با استفاده از رابطه مستخرج از روش ماشین بردار پشتیبان می‌توان 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.

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 می‌باشد. به این معنا که در هر دوره شبیه‌سازی

مواد و روش‌ها

منطقه مورد مطالعه

حوضه‌ی آبخیز سد دوبرج در غرب ایران و جنوب شرقی استان ایلام قرار دارد. رودخانه اصلی این حوضه رودخانه دوبرج می‌باشد (شکل ۱). سد دوبرج 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 رودخانه‌ها، محل سد و مصارف مختلف رقمی 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

شبیه‌سازی سیستم

مقادیر آبدهی رودخانه 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.

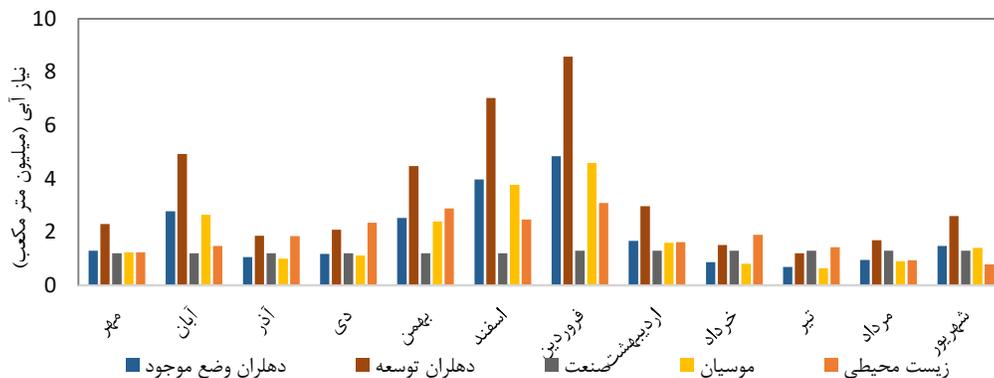
در مدل WEAP با استفاده از ابزارهای موجود و با توجه به نقشه‌های پایه GIS، مسیر رودخانه‌ها، محل ایستگاه‌های هیدرومتری، محل سد، محل‌های برداشت آب، گره‌ی مربوط به مصارف مختلف و نیازهای پایین دست رقومی شدند. گام‌های زمانی شبیه‌سازی، ماهانه در نظر گرفته شد. سری‌های زمانی داده‌های ثبت شده هیدرولوژیکی و اطلاعات 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 منطقه‌ای 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



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



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

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.

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 (1976) Tenant که از جمله روش‌های درجه‌بندی هیدرولوژیکی محسوب می‌شود، برای تخمین حداقل جریان زیست‌محیطی پایین دست بر اساس جریان طبیعی رودخانه

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

در سال ۲۰۱۴ ارائه شده است. بعدها الگوریتم چندهدفه MOGWO توسط میر جلالی و همکاران در سال ۲۰۱۶ ارائه شد. در بهینه‌ساز گرگ خاکستری (GWO)، مناسب‌ترین راه حل را به عنوان آلفا در نظر می‌گیریم، و راه‌حل‌های دوم و سوم مناسب، به ترتیب بتا و دلتا نامگذاری می‌شوند. بقیه راه‌حل‌ها، امگا در نظر گرفته می‌شوند. در الگوریتم GWO، شکار توسط α و β هدایت می‌شود. راه‌حل ω از این سه گرگ پیروی می‌کند. وقتی شکار توسط گرگ‌ها احاطه شده و از حرکت بایستد، حمله به رهبری گرگ α شروع می‌شود. مدل کردن این فرآیند با استفاده از کاهش بردار a انجام می‌شود. از آنجا که A برداری تصادفی در بازه $[-1, 1]$ است، $2a, 2a$ با کاهش a بردار ضرایب A هم کاهش می‌یابد.

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 اسکریپت، متغیرهای تصمیم‌گیری تولید شده توسط MOGWO در مسیر منطقه‌ی فعال WEAP قرار می‌گیرد. پس از آن سناریو فعال WEAP که همان سناریوی بهینه‌سازی بر اساس قواعد جیره‌بندی است به طور خودکار اجرا می‌شود. الگوریتم GWO، بر اساس جستجو، رفتار شکار و سلسله‌مراتب اجتماعی گرگ‌های خاکستری توسط میر جلالی^۱

¹ Mirjalili et al.

توابع هدف:

۱- حداکثر نمودن درصد تأمین نیازها

$$F_1 = \text{Maximize} \left(\sum_{z=1}^m \sum_{d=1}^k \sum_{t=1}^n (COV_{zdt}) \right) \quad (1)$$

$$= \text{Maximize} \left(\sum_{z=1}^m \sum_{d=1}^k \sum_{t=1}^n \left(\frac{TDW_{zdt}}{MD_{zdt}} \times 100 \right) \right)$$

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

$$F_1 = \text{Minimize} \left(\sum_{z=1}^m \sum_{d=1}^k \sum_{t=1}^n (100 - COV_{zdt}) \right) \quad (2)$$

$$= \text{Minimize} \left(\sum_{z=1}^m \sum_{d=1}^k \sum_{t=1}^n \left(100 - \frac{TDW_{zdt}}{MD_{zdt}} \times 100 \right) \right)$$

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:

$$F_2 = \text{Minimize} \left(\sum_{R=1}^k \sum_{t=1}^n \text{Max} \left(\left(1 - \frac{S_t}{S_{min}} \right), 0 \right) \right) \quad (3)$$

که در آن:

S_t : حجم ذخیره مخزن سد در زمان t

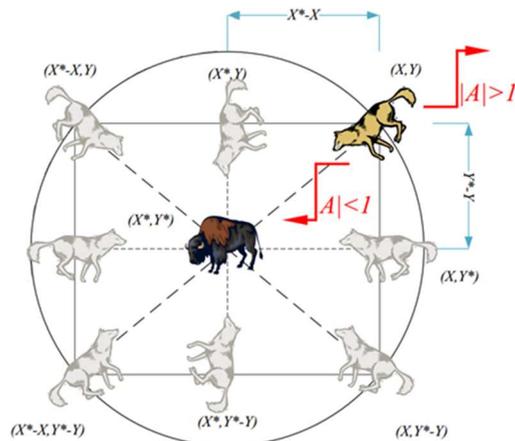
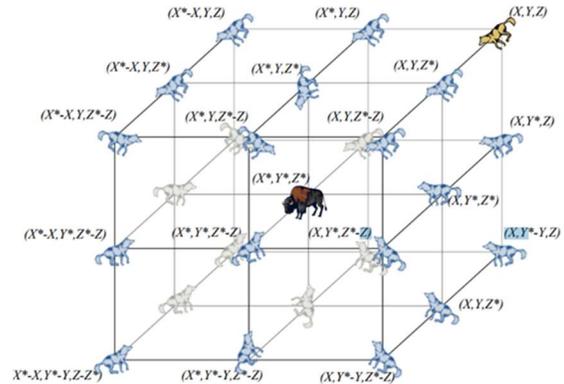
S_{min} : حجم مخزن سد R در تراز حداقل بهره‌برداری در دوره‌ی t

محدودیت‌ها:

$$TAW_{tzs} = RS_{tzs} \quad , \quad t = 1, \dots, m \times y, \quad (4)$$

$$z = 1, \dots, nz \quad s = 1, \dots, ns$$

اگر $|A| < 1$ باشد، گرگ α 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 α , β , δ 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.

RS_{tzs} : حجم کل آب سطحی تخصیص داده شده به بخش s
 در دوره t از منطقه z
 ns : تعداد بخش‌های مصرف‌کننده آب در هر منطقه‌ی نیاز
 m : تعداد دوره‌های برنامه‌ریزی در هر سال
 nz : تعداد مناطق نیاز
 y : تعداد سال‌های دوره‌ی برنامه‌ریزی

$$ARS_{tzs} = \begin{cases} DM_{tzs} & \text{if } \left(TSR_t - \sum_{z=1}^{z-1} \sum_{s=1}^s DM_{tzs} - \sum_{z=1}^z \sum_{s=1}^{s-1} DM_{tzs} \right) \geq DM_{tzs} \\ \left(TSR_t - \sum_{z=1}^{z-1} \sum_{s=1}^s DM_{tzs} - \sum_{z=1}^z \sum_{s=1}^{s-1} DM_{tzs} \right) & \text{otherwise} \end{cases} \quad (5)$$

$$Z = IZ(1), \dots, IZ(nz) \quad S = IS(1), \dots, IS(ns)$$

وزن‌های خروجی را به صورت تحلیلی^۳ تعیین می‌کند. ساختار کلی این الگوریتم در شکل (2.a) ارائه شده است. تنها تفاوت ELM با شبکه عصبی پیشخور تک لایه^۴ (SLFFNN)، عدم استفاده از بایاس^۵ 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^۶ 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 شبکه عصبی پیشخور تک لایه با تعداد n گره مخفی، به صورت زیر بیان می‌شود:

$$f_n(x) = \sum_{i=1}^n \beta_i G(a_i, b_i, x) \quad (9)$$

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 افزایشده^۷ $G(a_i, b_i, x)$ را می‌توان به شکل زیر بازنویسی کرد:

$$G(a_i, b_i, x) = g(a_i \cdot x + b_i) \quad (10)$$

از توابع فعال‌سازی به منظور محاسبه خروجی پاسخ نرون‌ها استفاده می‌شود. زمانی که مجموعه‌ای از سیگنال ورودی وزن-

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)

$$TDF_{tzs} = DM_{tzs} - ARS_{tzs} \quad (6)$$

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

$$M1 < Tb1 < N1 \quad (7)$$

$Tb1$: تراز جیره‌بندی سد دویرج (متر)

$M1$: تراز غیرفعال سد دویرج (متر)

$N1$: تراز حداکثر سد دویرج (متر)

$$TDW_{zdt} \leq MD_{zdt} \quad (8)$$

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^۱ تک لایه بوده و توسط هولنگ^۲ و همکاران (۲۰۰۴، ۲۰۰۶) ارائه شده است. ELM وزن‌های ورودی را به صورت تصادفی

⁵ bias

⁶ piecewise continuous function

⁷ additive

¹ feed-forward

² Huang

³ Analytical

⁴ single layer feed forward neural network

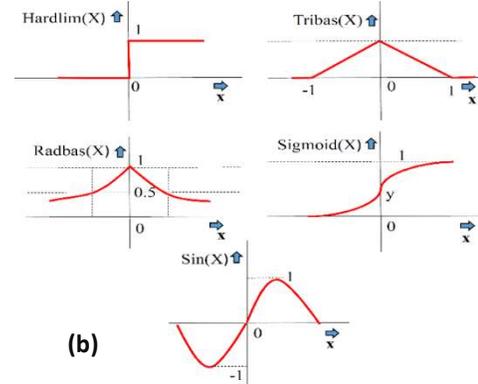
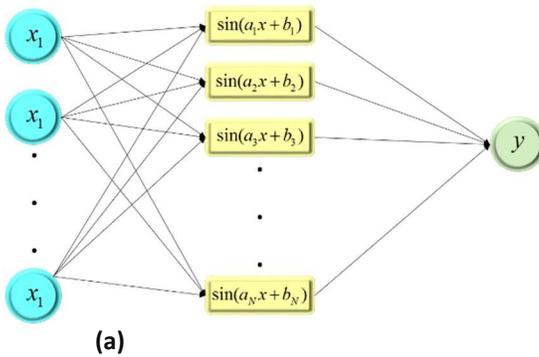
نرون لایه‌ی مخفی k ام، X_{ik} ورودی نرون ورودی برای k امین نمونه آموزشی و H_{ik} ماتریس فعالسازی زامین نرون لایه‌ی مخفی برای k امین نمونه‌ی آموزشی است بطوریکه فعالسازی همه‌ی نرون‌های لایه‌ی مخفی برای نمونه‌های مورد استفاده در آموزش توسط این ماتریس ارائه می‌شود. در این ماتریس z ستون و k ردیف است. ماتریس 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 نرون‌های لایه مخفی برای هر نمونه‌ی آموزشی، بکار برده می‌شود که معادل ریاضی آن را می‌توان به شکل زیر بیان کرد:

دار اعمال می‌شود، برای بدست آوردن پاسخ از توابع فعالسازی استفاده می‌شود (پندی^۱ و گوویند^۲ ۲۰۱۶). توابع فعالسازی غیرخطی ELM که در این مطالعه مورد بررسی قرار گرفته است شامل تابع پله‌ای (hardlim)، سیگموئید^۳ (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 "z" نرون در لایه مخفی، "i" نرون ورودی و تعداد "k" نمونه‌ی آموزشی، از رابطه‌ی زیر محاسبه می‌شود:

$$H_{jk} = g\left(\sum W_{ji} X_{ik}\right) + B_j \quad (11)$$

که $g(\cdot)$ می‌تواند هر تابع فعالسازی غیرخطی پیوسته باشد، W_{ji} وزن نرون ورودی i ام و نرون لایه‌ی مخفی j ام، B_j بایاس



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

$$\beta = H^T T \quad (15)$$

که در آن:

$$H(\tilde{a}, \tilde{b}, \tilde{x}) = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_1) \\ \vdots & & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (16)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad \text{and} \quad T = \begin{bmatrix} T_1^T \\ \vdots \\ T_L^T \end{bmatrix}_{L \times m} \quad (17)$$

$$H\beta = T \quad (12)$$

$$\beta = (\beta_1, \dots, \beta_j)_{j \times 1} \quad (13)$$

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 می‌شود:

$$T = (T_1, \dots, T_k)_{k \times 1} \quad (14)$$

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

³ sigmoid

¹ Pandey

² Govind

(یا در برخی منابع به این شکل نوشته می شود (w_0))
ماتریس وزن های خروجی است):

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

رابطه ی فوق یک مآله ی برنامه نویسی غیرمحدب^۵ است. یکی از ساده ترین راه ها جهت حل این مسأله، نوشتن آن به صورت یک مسأله ی محدب قابل کنترل بدون از بین رفتن ویژگی پراکندگی^۶ 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^۷ (کم شدن تابع خطا) می شود بلکه وجود مشخصات پراکندگی یا وجود وقایع حدی (داده های نادر) را نیز تضمین می کند.

$$\min_{\beta} \|e\|_1 + \frac{1}{C} \|\beta\|_2^2 \quad \text{subject to } y - H\beta = e \quad (19)$$

رابطه ی فوق یک مسأله ی بهینه سازی محدب مقید^۸ است به طوری که به طور کامل دامنه ی مناسب رویکرد تکمیل شده ضریب لاگرانژی^۹ را تطبیق می کند.

$$L_{\mu}(e, \beta, \lambda) = \|e\|_1 + \frac{1}{C} \|\beta\|_2^2 + \lambda^2 (y - H\beta - e) + \frac{\mu}{2} \|y - H\beta - e\|_2^2 \quad (20)$$

که $\mu = 2N/\|y\|_1$ (یانگ^{۱۰} و ژانگ^{۱۱})، بر پارامتر جریمه^{۱۲} 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.

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

مرحله ی آخر این تحقیق، تلفیق مدل ORELM با الگوریتم بهینه سازی MOGWO برای دستیابی به قواعد بهره برداری از سیستم در زمان واقعی در محیط MATLAB می باشد. با توجه به اینکه جعبه ی ابزار آماده ای برای این کار در محیط

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 نرون های لایه های مخفی و لایه پنهان و H' شبه معکوس Moore-Penrose ماتریس H است. T بردار بین وزن های نمونه های آموزشی است. با توجه به توضیحات ارائه شده، می توان گفت که آموزش ELM، شامل دو مرحله است: مرحله اول، اختصاص تصادفی وزن ها و بایاس ها به نرون های لایه ی پنهان و محاسبه ی خروجی لایه پنهان ماتریس H و مرحله ی دوم، محاسبه ی وزن های خروجی با استفاده از شبه معکوس Moore-Penrose ماتریس H و مقادیر هدف برای نمونه های آموزشی مختلف است. روند آموزش، جهت پیدا کردن ماتریس لایه ی پنهان (H)، سریع است بطوریکه از سرعت بالاتری نسبت به الگوریتم های مبتنی بر تکرار رایج مانند لونبرگ-مارکوآردت^۱ که در آن هیچ نوع روالی از بهینه سازی غیر خطی را در بر نمی گیرد، برخوردار است. بنابراین زمان آموزش شبکه به طور قابل توجهی کاهش می یابد (هوآنگ^۲، ۲۰۰۶).

به منظور مدلسازی با استفاده از مدل های مبتنی بر هوش مصنوعی همیشه داده های به صورت *outlier* وجود دارند و به دلیل اینکه عموماً وجود چنین نمونه هایی در بسیاری از موارد به طبیعت موجود در مسأله برمیگردد، امکان حذف آنها وجود ندارد. بنابراین، درصدی از کل خطای آموزش (e) را شامل می شود. به منظور برخورد با چنین داده هایی، وجود *outliers* با *sparsity* تعریف می شود. ژانگ^۳ و لو^۴ (۲۰۱۵) با دانش اینکه استفاده از *sparsity* *do-norm* را نسبت به l_2 -*norm* بهتر منعکس می کند، جهت محاسبه ی ماتریس وزن خروجی (β)، به جای استفاده از l_2 -*norm* خطای آموزش (e) را به گونه ای در نظر می گیرند که *sparse* باشد.

$$\min_{\beta} C \|e\|_0 + \|\beta\|_2^2 \quad \text{subject to } y - H\beta = e \quad (18)$$

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

(β)، ماتریس وزنه های خروجی است (w_0 یا همان w_{output} است).

⁷ minimization convex

⁸ constrained convex

⁹ Augmented Lagrangian (AL) multiplier

¹⁰ Yang

¹¹ Zhang

¹² penalty

¹ Levenberg-Marquardt

² Howang

³ Zhang

⁴ Luo

⁵ non-convex programming

⁶ tractable convex relaxation form without loss of the sparsity characteristic

داد که در تکرارهای پایین تر 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 مسئله 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^۲) 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.

MATLAB وجود ندارد، نسخه‌ی اولیه الگوریتم MOGWO که بصورت منبع باز^۱ 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.

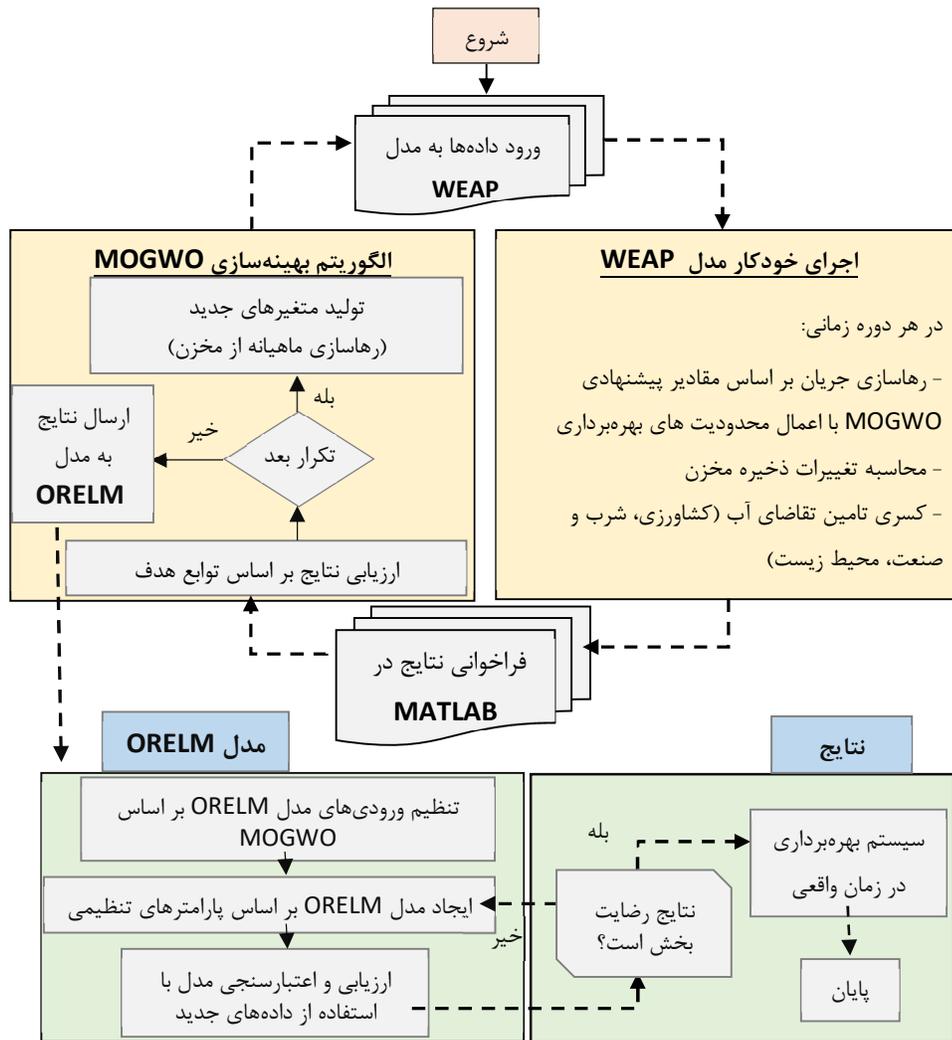
نتایج

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

² Pareto-optimal Front

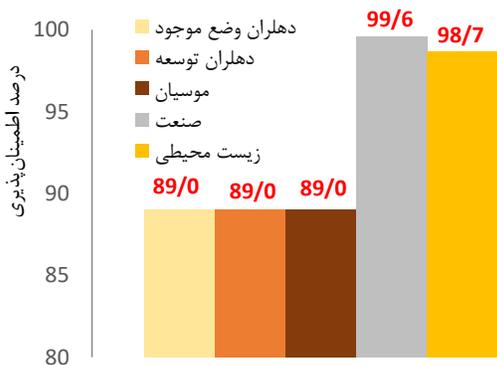
¹ Open Source



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

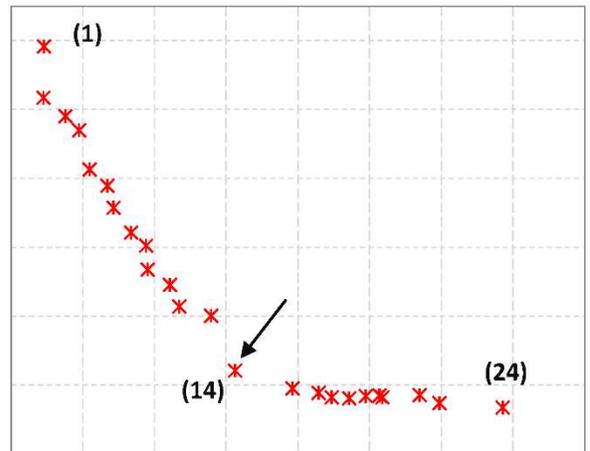
هر کدام از مصارف پس از بهینه‌سازی سیستم را نشان می‌دهد.

شکل ۹ نشان می‌دهد درصد تامین نیاز مصارف مختلف با اعمال جواب بهینه حاصل از الگوریتم MOGWO (راه حل شماره ۱۴)، با در نظر گرفتن کل دوره بهره‌برداری قابل قبول بوده و میانگین درصد تامین نیاز حتی در ماههای کم آب بیش از ۸۴ درصد است. لذا در کل دوره بهره‌برداری، الگوریتم بهینه‌سازی مبتنی بر قواعد جیره‌بندی، بیشترین کارایی خود را در تامین 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 تامین نیاز نبوده و علاوه بر در نظر داشتن حداکثرسازی تامین 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 تامین نیازها 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.



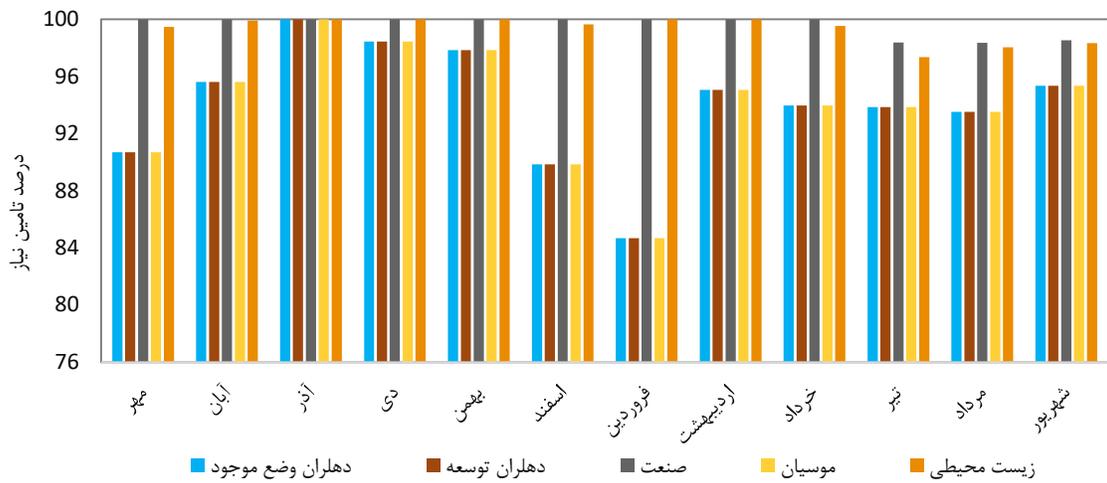
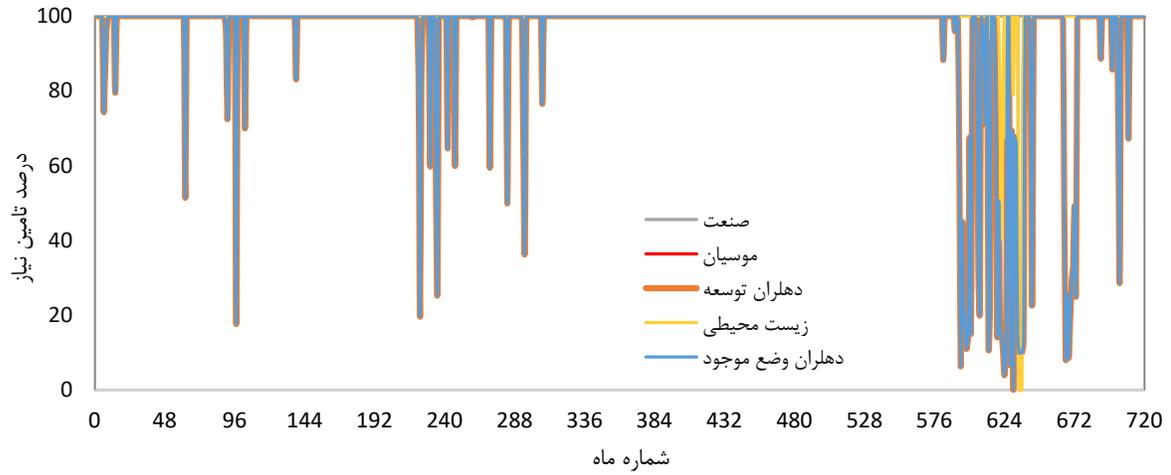
شکل (۸): مقادیر اطمینان‌پذیری تامین نیاز هر کدام از مصارف مختلف پس از بهینه‌سازی سیستم توسط MOGWO

The Plot of Pareto Front in Iteration 1000

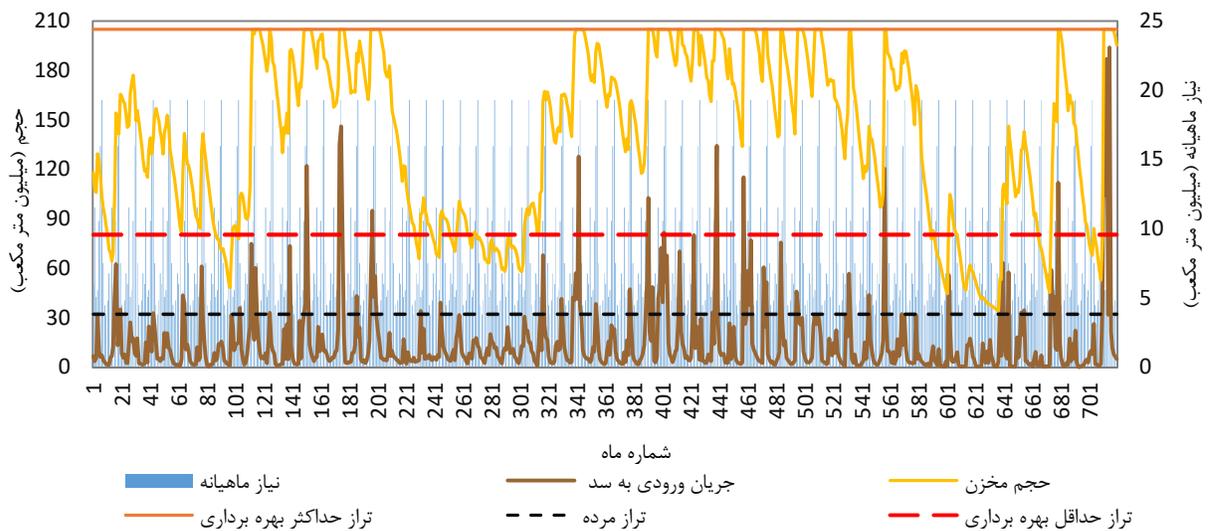


شکل (۷): منحنی تبادل بهینه بین اهداف بهینه‌سازی (منحنی پارتو) در تکرار ۱۰۰۰

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 می‌باشد. لذا بر اساس ارزش‌گذاری توابع هدف، راه‌حلی که بطور نسبی در مقایسه با سایر راه‌حلهای دارای مناسب‌ترین 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 تامین نیاز



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



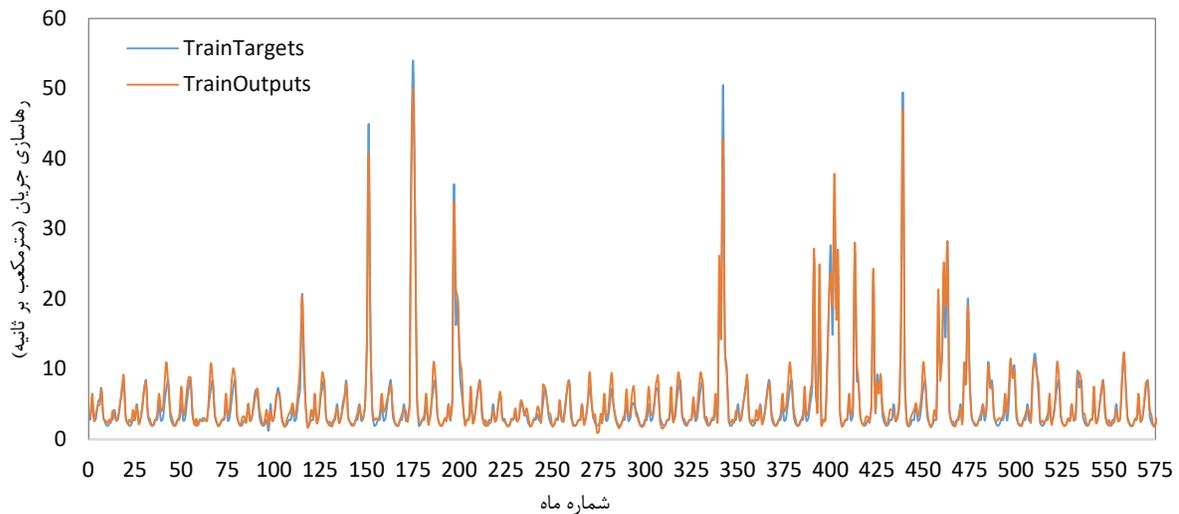
شکل (۱۰): میزان تغییرات ذخیره مخزن سد دویرج در طول دوره‌ی بهره‌برداری پس از بهینه‌سازی سیستم توسط MOGWO

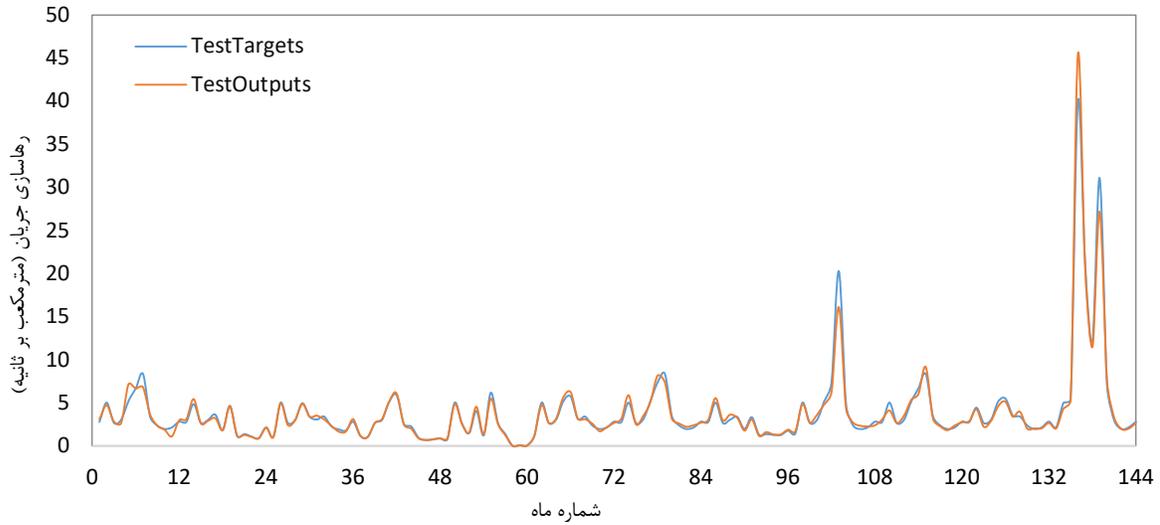
در این تحقیق برای استفاده از نتایج بهینه‌سازی با الگوریتم MOGWO در زمان واقعی از مدل ORELM استفاده شد. ابتدا این مدل بر اساس خروجی الگوریتم MOGWO و برای یک دوره ۵۷۶ ماهه آموزش داده شدند. سپس برای یک دوره ۱۴۴ ماهه از داده‌ها که در مرحله آموزش از آنها استفاده نشده بود صحت‌سنجی صورت گرفت. بدین ترتیب که 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 دوره 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.

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 شکست‌ها 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 MOGWO و ORELM

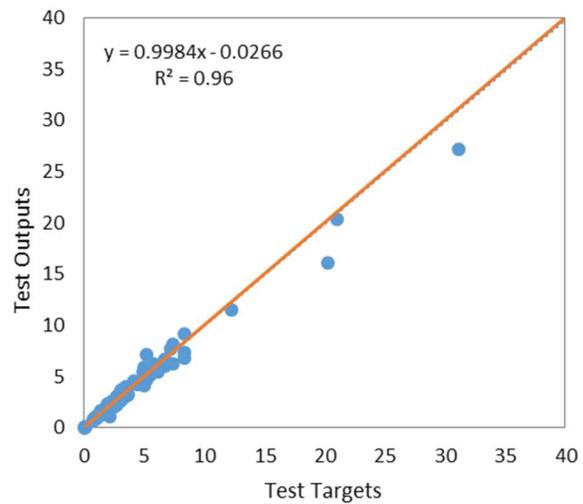
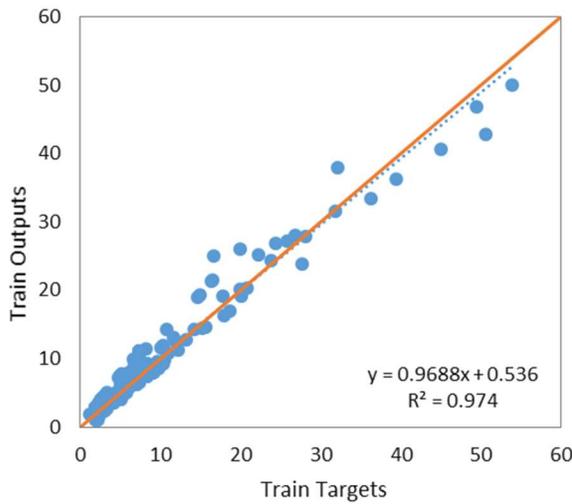


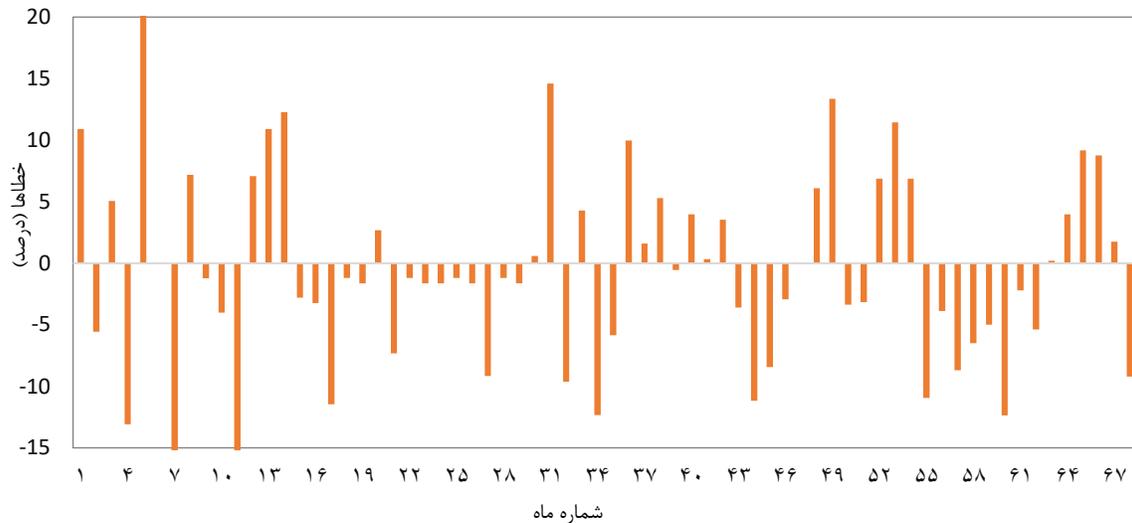


شکل (۱۱): پیش‌بینی میزان رهاسازی بهینه از سد دویرج توسط مدل ORELM در مراحل train و test

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.

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.





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 دوبرج در مرحله test

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 دوره 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 مخزن، به احتمال زیاد جواب‌های بهینه‌ی 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 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 دهنده 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

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 می‌دهد. 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 می‌دهد. 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 کاملاً 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 جریمه‌ناشی از تخطی از ظرفیت مجاز مخزن و بیشترین میزان درصد تأمین نیاز مصارف بود به عنوان جواب برتر انتخاب شد. نتایج کاربرد مقادیر رهاسازی

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.

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 comparison. *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.

- 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, Melsse 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, Roustab 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.

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

Hasan Biglari¹
Saeed Jamali*²
Hooman Hajikandi³
Saeid Shabanlou⁴

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.