

EXTENDED ABSTRACT

Optimal Utilization of Water Resources in Real Time Based on NSGA-II Algorithms and Support Vector Machines (Case Study: Gavoshan Dam)

A. Azari^{*1} and A. Arman²

1* - Corresponding Author, Assistant Professor, Department of Water Engineering, Razi University
(a.azari@razi.ac.ir).

2- Assistant Professor, Department of Water Engineering, Razi University.

Received: 12 September 2017

Revised: 5 June 2018

Accepted: 9 June 2018

Keywords: Artificial Intelligence, Optimization, On-time Operation, Metaheuristic Algorithm, WEAP.

DOI: 10.22055/jise.2018.23042.1639.

Introduction

Ample research has been done on optimization methods for the exploitation of reservoirs in the form of a specific optimization. In this type of studies, a certain series of flow is provided for the reservoir during the operation period and the release from the reservoir to downstream is optimized under such circumstances. They are certain drawbacks for these models. First, optimal solutions cannot be generalized for other possible inputs to the reservoir. Second, in the event of a change in the flow of input into the reservoirs, it is likely that the optimal solutions are not efficient and the operation of the system in the form of an optimization algorithm should be performed again. In such circumstances, one of the solutions is the use of intelligent methods such as support vector machines to apply the results of system optimization in real time. The main goal of this study is to integrate artificial intelligence methods such as support vector machine with NSGA-II optimization algorithm to convert it to real time. In this structure, contrary to the conventional design of the scheduling, in the event of a change in the flow of input, there is no need to perform re-optimization to understand the optimal coefficients. Instead, the extraction relationship of the support vector machine can be based on the input to the reservoir (at the beginning of the month), the volume of water storage in the tank (at the beginning of the month), reservoir storage changes and downstream needs in the current month to yield optimal release rates in real time.

Methodology

The study area of Gavoshan Dam and the coverage of this network is located in western Iran. Initially, the simulation of the system was carried out in the WEAP environment and the river route, the location of the hydrometric stations, the dam site, the water harvesting channels, the nodes of cities, and other factors were given elevations using existing tools. Then, the data of Gavoshan dam utilization and all resources and expenditures were entered into the model. Non-dominated-Sorting Genetic Algorithm (NSGA-II) was used to optimize the system, which has been formulated in a multi-objective manner (Deb et al., 2002). This way, the first objective was to maximize the reliability of the project requirements during the planning period against the second objective, namely, to minimize the amount of violations caused by failure to meet the requirements and to violate the capacity of the reservoir (damage function) during the operation period. To use real-time

optimization results, the method of support vector machines was used in this study. Support vector machines are learning methods essentially developed on the basis of a statistical model for data categorization (Vapnic, 1995). The model was later adopted as regression vector machines to solve regression problems, detect the time series pattern and predict data (Osmola and Skolkov, 1998; Skolkov and Osmola, 2002). The support vector machine was based on the output of the optimization algorithm and was trained for a period of 192 months. Then, for a 24-months period, verification was made of data not used in the training phase. Finally, the model was used to estimate the release rate of the dam in real time.

Results and Discussion

After optimizing, the optimal exchange curve between optimization goals was achieved (reliability maximizing function and fines minimizing function due to system breach from costing need). In the last replication of the model, 32 optimal answers were presented on the Pareto front, among which, based on the valuation of the target functions, a solution that simultaneously had the lowest fines and the highest degree of reliability was chosen as the preferred answer. Based on the best answer, the amount of each of the drinking, agricultural, and environmental needs, as well as the optimal allocation of the dam to the total consumption during the exploitation period (18 years), is shown in Figure (1).

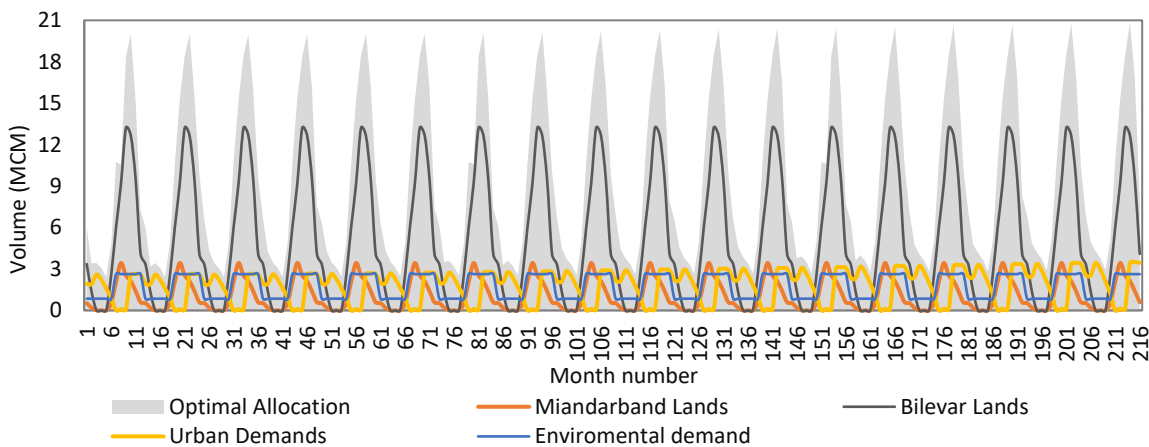


Fig. 1- Optimal allocation of costs to each of the uses during the operation (MCM)

Accordingly, the needs of the lands of the plains under study in most months is satisfied fully and optimally. Then, for the generalization of the results, the calibration and validation of the support vector machine model was performed. Figure (2) shows the results of the verification of the support vector machine prediction based on the output of the optimization algorithm, which indicates the ability of the trained structure to predict the optimal release of the dam in real time. Based on this form, the average error rate for the 24 months was 9.8% and the maximum error rate was 17.7%.

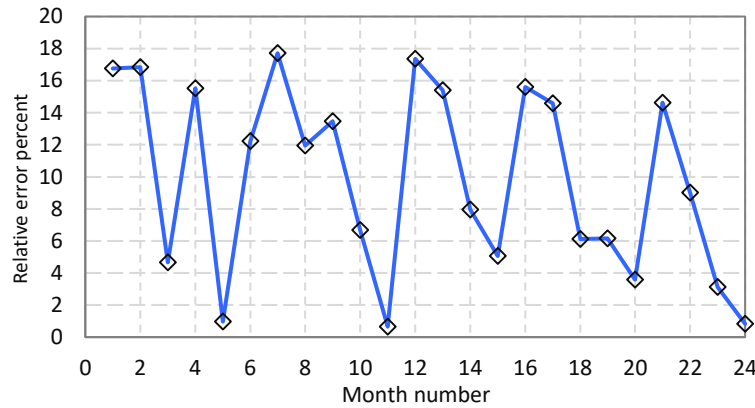


Fig. 2- Relative error percentage of support vector machine model in estimating optimal release rate of Gavoshan Dam

Conclusions

In general, the results showed that, based on the combination of the multi-objective algorithm NSGA-II and the WEAP simulation model, the developed model has the ability and efficiency to solve complex and completely nonlinear problems and provide optimal solutions. However, optimal answers are not generalizable for other possible inputs to the reservoir, and if the flow of input into the reservoirs changes, it is likely that the optimal solutions are not efficient and the operation of the system should be optimized in the form of optimization algorithm. Therefore, to use real-time optimization results, intelligent support vector machine was used. The results showed that the average of the optimal rule errors of the support vector machine compared to the output of the NSGA-II optimization algorithm at verification level was less than 10%, which indicates the effectiveness of this method in predicting the optimal pattern of curve in real time. This means that developed support vector machine has the capability to quickly optimize the policy of optimal operation of the system in real time with regard to new inputs to the dam.

Acknowledgment

The authors would like to thank the Regional Water Company of Kermanshah for providing the Data and information needed for this research.

References

- 1- Deb, k., Pratap, A., Agarwal, S., and Meyarivan, T., 2002. A fast and elitist multi-objective genetic algorithm: NSGA-II, *IEEE Trans Evolutionary Computing, Indian*, 6(2), pp. 182–197.
- 2- Schölkopf, B. and Smola, A., 2002. *Learning with Kernels*. MIT Press.
- 3- Smola, A. J and Schölkopf, B., 1998. On a kernel–based method for pattern recognition, regression, approximation and operator inversion, *Algorithmica*, 22, pp. 211–231.
- 4- Vapnik, V., 1995. *The nature of statistical learning theory*. Springer-Verlag, NewYork.



بهره‌برداری بهینه منابع آب در زمان واقعی بر اساس الگوریتم NSGA-II و ماشین‌های بردار پشتیبان (مطالعه موردی: سد گاوشان)

آرش آذری^{۱*} و علی آرمان^۲

*- نویسنده مسئول، استادیار گروه مهندسی آب دانشکده علوم و مهندسی کشاورزی، دانشگاه رازی، a.azari@razi.ac.ir

۲- استادیار گروه مهندسی آب دانشکده علوم و مهندسی کشاورزی، دانشگاه رازی.

پذیرش: ۱۳۹۷/۳/۱۹

بازنگری: ۱۳۹۷/۳/۱۵

دریافت: ۱۳۹۶/۶/۲۱

چکیده

در این تحقیق از ترکیب الگوریتم چندهدفه NSGA-II و مدل شبیه‌ساز WEAP برای استخراج سیاست‌های بهینه بهره‌برداری از مخزن در قالب بهینه‌سازی معین استفاده شد. طوری که در آن، هدف اول، حداکثر نمودن اطمینان‌پذیری تأمین نیازها در مقابل هدف دوم یعنی حداقل نمودن میزان تخطی ناشی از عدم تأمین نیازها و تخطی از ظرفیت مخزن در طول دوره بهره‌برداری قرار گرفت. اما جواب‌های بهینه یعنی مقدار رهاسازی از مخزن قابل تعمیم برای سایر ورودی‌های محتمل به مخزن نیستند. در صورت تغییر جریان ورودی به مخزن جواب‌های بهینه به‌دست آمده کارایی نداشته و باید بهره‌برداری از سیستم در قالب الگوریتم بهینه‌ساز مجدداً بهینه گردد. لذا برای حل این مشکل روش جدیدی بر اساس تلفیق روش ماشین بردار پشتیبان و الگوریتم NSGA-II برای بهره‌برداری بهینه از سیستم در زمان واقعی توسعه داده شد. نتایج نشان داد میانگین خطای قوانین بهینه مستخرج از ماشین‌های بردار پشتیبان نسبت به خروجی الگوریتم NSGA-II در مرحله صحت‌سنجی کمتر از ۱۰ درصد است که نشان دهنده کارایی این روش در پیش‌بینی الگوی بهینه منحنی فرمان سد در زمان واقعی است. در این ساختار می‌توان بر اساس جریان ورودی به مخزن، حجم ذخیره آب در مخزن و تغییرات ذخیره مخزن (در ابتدای ماه) و نیازهای پایین‌دست در ماه حاضر، مقدار رهاسازی بهینه را در زمان واقعی به‌دست آورد. روش مورد استفاده 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.

کلید واژه‌ها: هوش مصنوعی، بهینه‌سازی، بهره‌برداری به هنگام، الگوریتم فراکوشی، WEAP.

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 فرهنگی با خود به همراه دارد، از اولویت‌های برنامه‌ریزی و مدیریت منابع آب است. در حال حاضر با توجه به کاهش حجم آب ورودی به مخازن در مقایسه با دوره‌های گذشته، به منظور افزایش کارایی استفاده از منابع آب موجود در تأمین اهداف مختلف، کاربرد سیاست‌های بهره‌برداری بهینه از سدهای مخزنی در قالب مدل‌سازی سیستم مخازن چند هدفه در سطح حوضه‌های آبریز، امری ضروری می‌باشد. از جمله ابزارهای مناسب در حوزه مدیریت منابع آب استفاده از روش‌های شبیه‌سازی، بهینه‌سازی و ترکیب شبیه‌سازی بهینه‌سازی می‌باشد. بسیاری از مسائل بهینه‌سازی در علوم مهندسی، طبیعتاً پیچیده‌تر و مشکل‌تر از آن هستند که با روش‌های مرسوم بهینه‌سازی، نظیر

روش برنامه‌ریزی ریاضی و نظایر آن قابل حل باشند. در این راستا گروهی از الگوریتم‌های تکاملی توسط محققین مختلف توسعه یافته‌اند که اساساً سعی در ترکیب اصول اولیه روش‌های کاوشی و یافتن روش کاوش مؤثر و کارا در فضای جستجو را دارند. امروزه این روش‌ها به نام روش‌های کاوشی مشهورند (Blum and Roli, 2003).

الگوریتم‌های ژنتیک در بین روش‌های الگوریتم‌های تکاملی، به عنوان شناخته‌شده‌ترین روش‌های مورد استفاده مطرح بوده و در حیطه‌های متفاوت علمی از جمله علوم پایه، اقتصاد، بیولوژی و علوم مهندسی به عنوان ابزاری قدرتمند و مناسب در حل مسائل مختلف بهینه‌سازی است (Gen and Cheng, 1997; Wardlaw and Sharif, 1999). Chang et al. (2005) الگوریتم ژنتیک را برای پیدا کردن منحنی فرمان ماهانه بهینه در یک سیستم تک‌سدی چندهدفه در تایوان به کار بردند. نتایج نشان داد که با استفاده از

بهینه بدست آمده کارایی نداشته و باید بهره‌برداری از سیستم در قالب الگوریتم بهینه‌ساز مجدداً بهینه گردد. در چنین شرایطی یکی از راهکارها، استفاده از ورودی‌های جریان تصادفی در قالب بهینه‌سازی استوکاستیک (Stochastic) است. اما در این روش نیز به دلیل تنوع سری‌های جریان ورودی برای جلوگیری از طولانی شدن زمان حل به ناچار باید از تعداد متغیرهای تصمیم به شدت کاسته شود که خود باعث خطاهایی در بهره‌برداری از سیستم در زمان واقعی خواهد شد. راهکار دیگر، استفاده از روش‌های هوشمند مانند ماشین‌های بردار پشتیبان برای بکار بردن نتایج حاصل از بهینه‌سازی سیستم در زمان واقعی است. در بسیاری از تحقیقات، روش موسوم به ماشین‌های بردار رگرسیون که بر اساس ماشین بردار پشتیبان توسعه یافته است، برای پیش‌بینی سری زمانی استفاده شده است. Thissen et al. (2003) و Lin et al. (2006) دریافتند که ماشین‌های بردار پشتیبان نسبت به مدل‌های ARMA و شبکه عصبی مصنوعی کارایی بهتری برای پیش‌بینی سری زمانی دارد و نتایج آن به واقعیت نزدیکتر است.

Li et al. (2017) از ترکیب الگوریتم بهینه‌سازی ازدحام ذرات و ماشین بردار پشتیبان برای پیش‌بینی جریان روزانه حوضه بوتان (Yuetan) در چین استفاده کردند. Nikoo et al. (2013) از ترکیب مدل بهینه‌سازی بهره‌برداری تلفیقی کمی- کیفی تخصیص آب و بار آلودگی در سطح حوضه آبریز با روش ماشین بردار پشتیبان برای تدوین قوانین بهره‌برداری در زمان واقعی استفاده کردند. Esmikhani et al. (2010) برای مدیریت تلفیقی بهینه منابع آب سطحی و زیرزمینی منطقه مطالعاتی کوهپایه- سگری از الگوریتم بهینه‌سازی ژنتیک و ماشین بردار پشتیبان استفاده نمودند. Mosavi و Mirfendreski (2011) به منظور بهینه‌سازی منابع آب حوضه‌ای، به مقایسه مدل ماشین بردار پشتیبان و ترکیب الگوریتم بهینه‌ساز ازدحام ذرات و مدل شبیه‌ساز MODSIM در حوضه اترک پرداختند. نتایج حاکی از عملکرد مطلوب مدل ماشین بردار پشتیبان در ارائه جواب‌های بهینه و همچنین کاهش زمان حل بود.

Du et al. (2017) از ترکیب ماشین بردار پشتیبان و الگوریتم ازدحام ذرات برای پیش‌بینی بارندگی سه ساعته ایستگاه هواشناسی واقع در نانجینگ چین استفاده کردند. Bazargan Iari et al. (2011) کاربرد ماشین‌های بردار پشتیبان را در تدوین قوانین احتمالاتی برای بهره‌برداری بهینه کمی- کیفی از منابع آب سطحی و زیرزمینی در زمان واقعی مورد بررسی قرار دادند. در روش ارائه شده با استفاده از خروجی مدل بهینه‌سازی و داده‌های موجود از مدل‌های شبیه‌ساز، این امکان فراهم آمد تا خروجی‌های احتمالاتی که توابع توزیع چگالی احتمال برداشت از آب زیرزمینی دشت در زمان واقعی است، را به‌دست آورد.

منحنی فرمان به‌دست آمده از الگوریتم ژنتیک، نتایج بهتری از لحاظ میزان کمبود در تأمین نیازهای کشاورزی و تولید انرژی برقی نسبت به منحنی فرمان رایج و سنتی موجود، حاصل خواهد گردید.

Momtahan و Dariane (2007) در یک سیستم تک‌مخزنی ساده، برای جستجوی مستقیم پارامترهای مربوط به سیاست بهره‌برداری بهینه مخزن از الگوریتم ژنتیک استفاده کردند. آن‌ها برای تعریف سیاست بهره‌برداری، چندین روش مختلف رابطه خطی، رابطه خطی قطعه‌ای، شبکه عصبی و قاعده فازی را به کار بردند تا ارتباط بین متغیرهای حالت (حجم مخزن و جریان ورودی) و متغیرهای تصمیم‌گیری (خروجی مخزن) از طریق آن‌ها برقرار شود. سپس برای بهینه‌سازی پارامترهای مربوط به آن‌ها از الگوریتم ژنتیک بهره گرفتند. Nakhaei et al. (2014) از الگوریتم ژنتیک به منظور مدیریت بهره‌برداری بهینه از آبخوان دشت ساحلی ارومیه و تعیین نرخ بهینه پمپاژ چاه‌های بهره‌برداری استفاده کردند.

الگوریتم ژنتیک مبتنی بر جواب غیر پست (NSGA-II) که در واقع نوعی الگوریتم ژنتیک چند هدفه محسوب می‌شود، در هر گام حل با جمعیتی از جواب‌های ممکن کار می‌کند. به دلیل ساختار مناسب این مدل و گزینش جواب‌های غیر پست در هر بار تکرار معادلات، این الگوریتم دارای سرعت همگرایی بهتری نسبت به مدل الگوریتم ژنتیک معمولی است (Deb et al., 2002). به دلیل ساختار چندهدفه، همچنین به دلیل پیچیدگی مسئله و تعداد متغیرهای تصمیم، در فرآیند بهینه‌سازی در این تحقیق از این روش بهره گرفته شد. Jian et al. (2005) از الگوریتم ژنتیک چندهدفه، به منظور برنامه‌ریزی سیستم‌های چند مخزنه استفاده نمودند و دریافتند که باوجود افزایش تعداد متغیرها و نیز طولانی شدن زمان اجرای برنامه، الگوریتم ژنتیک در حل مسائل با ورودی‌های کم و شرایط پیچیده از پتانسیل بالایی برخوردار می‌باشد. Hojjati et al. (2013) در یک مطالعه موردی برای بهینه‌سازی یک سامانه دو مخزنه شامل سدهای استور و پیرتقی واقع در حوضه آبریز قزل‌اوزن از الگوریتم‌های ژنتیک ساده و چند هدفه NSGA-II استفاده کردند و در نهایت با مقایسه نتایج حاصل، به این نتیجه رسیدند که الگوریتم NSGA-II جواب‌های مناسب‌تری نسبت به الگوریتم ژنتیک ارائه می‌دهد.

مطابق با آنچه گفته شد، بسیاری از تحقیقات انجام شده بر روی روش‌های بهینه‌سازی بهره‌برداری از مخازن در قالب بهینه‌سازی معین انجام گرفته است. در این نوع از مطالعه‌ها یک سری معین از جریان ورودی به مخزن در طول دوره بهره‌برداری در نظر گرفته شده و رهاسازی از مخزن برای تأمین مصارف پایین‌دست در این شرایط بهینه می‌گردد. اشکال چنین مدل‌هایی این است که جواب‌های بهینه قابل تعمیم برای سایر ورودی‌های محتمل به مخزن نیستند و در صورت تغییر جریان ورودی به مخازن به احتمال زیاد جواب‌های

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 پایین‌دست در ماه حاضر، مقدار رهاسازی بهینه را در زمان واقعی به‌دست آورد.

مواد روش‌ها

منطقه مورد مطالعه سد گاوشان در غرب ایران است. جریان آب رودخانه گاوه‌رود، پس از ذخیره‌سازی توسط سد مخزنی گاوشان، از طریق تونل گاوشان به حوضه رودخانه رازآور انتقال یافته و ضمن تأمین مصارف آب شرب شهر کرمانشاه و کامیاران با منابع آب سطحی رودخانه رازآور تلفیق شده و آب مورد نیاز آبیاری دشت‌های بیله‌وار و میان‌دربند را تأمین می‌نماید. موقعیت منطقه مطالعاتی و منابع و مصارف موجود در شکل (۱) نشان داده شده است.

بر 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 جریان‌های ماهیانه ورودی به مخزن، حجم ذخیره آب در مخزن، تغییرات حجم مخزن و نیازهای پایین‌دست (به عنوان متغیرهای مستقل) و متغیر میزان رهاسازی بهینه (به عنوان متغیر وابسته) وجود خواهد داشت. لذا هدف اصلی این تحقیق تلفیق روش‌های هوش مصنوعی مانند ماشین بردار پشتیبان با الگوریتم بهینه‌سازی NSGA-II برای تبدیل آن به زمان واقعی می‌باشد. 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 درک ضرایب بهینه نیست. بلکه با استفاده از رابطه مستخرج از روش ماشین بردار

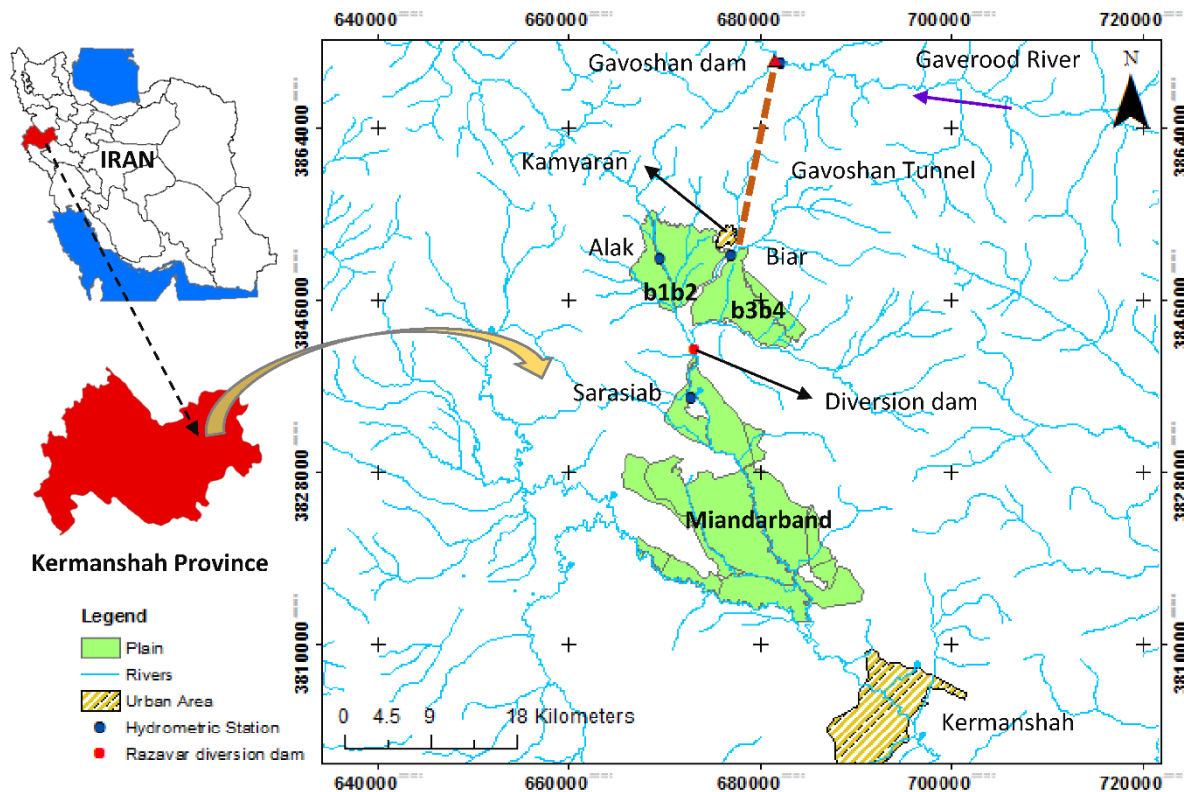


Fig. 1- Location of study area and available resources and demands

شکل ۱- موقعیت محدوده مطالعاتی و منابع و مصارف موجود

شبیه‌سازی سیستم

در مدل WEAP با استفاده از ابزارهای موجود و با توجه به نقشه‌های پایه GIS، مسیر رودخانه‌ها، محل ایستگاه‌های هیدرومتری، محل سد، کانال‌های برداشت آب، گره مربوط به شهرها و مصارف و غیره رقومی شدند. سپس اطلاعات بهره‌برداری سد گاوشان مطابق با جدول (۱) در مدل وارد شد.

همچنین سری‌های زمانی داده‌های ثبت شده هیدرولوژیکی و هواشناسی و اطلاعات مربوط به نیاز ماهیانه مصارف (کشاورزی و شرب)، اطلاعات مخازن و محل‌های برداشت، ضرایب و پارامترهای مورد نیاز و غیره به صورت فایل‌های متنی با پسوند CSV به مدل معرفی شدند. مقادیر آبدهی رودخانه گاوهرود و رازآور در محل ایستگاه‌های واقع بر آن و همچنین آبدهی ماهیانه رودخانه فرعی الک در محل ایستگاه هیدرومتری الک در طول دوره شبیه‌سازی در

مدل تعریف شد. میانگین آبدهی در این ایستگاهها در طول دوره شبیه‌سازی در شکل (۲) ارائه شده است.

نیاز آبی اراضی دشت بیله‌وار و میان‌دریوند از طریق آب تنظیمی سد گاوشان تأمین می‌شود. بخشی از آب مورد نیاز اراضی دشت میان‌دریوند از طریق آب تنظیمی سد گاوشان و بخشی از آن با احداث بند انحرافی رازآور از جریان رودخانه تأمین می‌گردد. در تمام دشت‌های مذکور، نیاز آبی اراضی براساس الگوی کشت غالب دشت‌ها مطابق با آمارنامه‌های کشاورزی پنج سال اخیر، درصد کشت و ضریب گیاهی هر محصول، مساحت اراضی، آب خالص مورد نیاز گیاهان، راندمان آبیاری و سایر پارامترهای مرتبط، محاسبه شد. بر این اساس آب مورد نیاز ماهیانه ۵۹۵ هکتار از اراضی دشت میان‌دریوند و ۸۵۰ هکتار اراضی بیله‌وار (b1,b2) و ۲۸۹۰ هکتار اراضی بیله‌وار (b3,b4)، در شکل (۳) آورده شده است.

جدول ۱- پارامترهای بهره‌برداری از سد گاوشان در طول دوره شبیه‌سازی

Table 1- Parameters of Gavoshan dam operation during simulation period

Parameter	Value
Normal Elevation	1545.5 (m)
Max Reservoir Storage	555 (MCM)
Inactive Storage	50 (MCM)
Active Storage	505 (MCM)
Maximum capacity of water transfer tunnel	30 (m ³ /s)

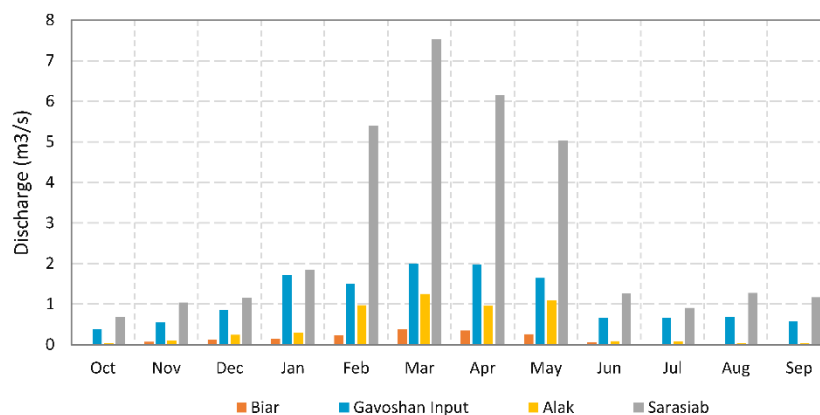


Fig. 2- Average monthly discharge of Gaverood and Razavar Rivers at hydrometric stations

شکل ۲- میانگین آبدهی ماهیانه رودخانه گاوهرود و رازآور در محل ایستگاه‌های هیدرومتری




Fig. 3- Water demand of studied plains in different months (MCM)
شکل ۳- میزان نیاز آبی دشت‌های مورد مطالعه در ماه‌های مختلف (MCM)

بهره‌برداری قرار می‌گیرد. توابع هدف و قیود در این تحقیق به صورت زیر تعریف شدند.
توابع هدف:
۱- بیشینه‌سازی اطمینان‌پذیری تأمین نیاز تمام مصارف

$$F_1 = \text{Maximize} \left(\sum_{t=1}^m \sum_{z=1}^{nz} \sum_{s=1}^{ns} (\text{Reliability}_{tzs}) \right) = \text{Maximize} \left(\sum_{t=1}^m \sum_{z=1}^{nz} \sum_{s=1}^{ns} \left(\text{INT} \left(\frac{TDW_{tzs}}{MD_{tzs}} \right) \times 100 \right) / m \right) \quad (1)$$

به دلیل اینکه الگوریتم بهینه‌سازی چندهدفه NSGA-II به دنبال یافتن کمینه توابع هدف است، می‌توان معادله (۱) را به صورت معادله (۲) تعریف کرد:

$$F_1 = \text{Minimize} \left(\sum_{t=1}^m \sum_{z=1}^{nz} \sum_{s=1}^{ns} \left(\frac{100 - \text{Reliability}_{tzs}}{100} \right) \right) = \text{Minimize} \left(\sum_{t=1}^m \sum_{z=1}^{nz} \sum_{s=1}^{ns} \left(1 - \frac{TDW_{tzs}}{DM_{tzs}} \right) \right) \quad (2)$$

که در آن:

Reliability_{tzs} : اطمینان‌پذیری تأمین نیاز بخش S در دوره t از منطقه Z

m : تعداد ماه‌های بهره‌برداری

DM_{tzs} : نیاز آبی بخش S در دوره t از منطقه Z

TAW_{tzs} : میزان کل آب تخصیص داده شده به بخش S در

دوره t از منطقه Z

۲- کمینه نمودن میزان تخطی ناشی از عدم تأمین نیازها و

تخطی از ظرفیت بهره‌برداری مخزن

مقداری از آب شرب مورد نیاز شهر کرمانشاه از طریق سد گاوشان و مابقی از طریق منابع آب زیرزمینی تأمین می‌شود. همچنین از آب سد گاوشان برای تأمین آب شرب مورد نیاز شهر کامیاران نیز استفاده می‌گردد. جهت محاسبه آب شرب مورد نیاز در دوره آماری شبیه‌سازی در کرمانشاه و کامیاران از آمار و اطلاعات جمعیتی مربوط به سرشماری‌های ۱۳۸۵، ۱۳۹۰ و ۱۳۹۵ استفاده شد. همچنین با توجه به آمار و اطلاعات اخذ شده از اداره آب و فاضلاب استان کرمانشاه میزان مصرف سرانه شهرهای کرمانشاه و کامیاران به ترتیب در حدود ۲۲۵ و ۲۲۰ لیتر در روز در نظر گرفته شد. نهایت با توجه به نرخ رشد جمعیت هر منطقه، جمعیت آینده برآورد شده و در نهایت مقدار نیاز شرب در دوره ۱۸ ساله آتی (از مهر ۱۳۹۳ تا شهریور ۱۴۱۱) محاسبه شد. در این تحقیق برای تعیین جریان زیست‌محیطی، گره مربوط به حداقل جریان زیست‌محیطی در پایین‌دست سدگاوشان و پایین‌دست رودخانه رازآور قرار داده شد. از روش تنانت یا مونتانا که از جمله روش‌های درجه‌بندی هیدرولوژیکی محسوب می‌شود، برای تخمین حداقل جریان زیست‌محیطی پایین‌دست استفاده شد (Tennant, 1976). با توجه به اطلاعات تبخیر از سطح آزاد مخزن سد گاوشان و در نظر گرفتن میزان بارندگی روی سطح مخزن تبخیر خالص از سطح آزاد مخازن محاسبه و در مدل بکار گرفته شد.

ساختار مدل بهره‌برداری چندهدفه پیشنهادی

در این تحقیق از مدل الگوریتم ژنتیک مبتنی بر جواب غیر پست (NSGA-II) استفاده گردید که به صورت چند هدفه تدوین شده است. به این ترتیب که در آن هدف اول، حداکثر نمودن اطمینان‌پذیری تأمین نیازهای طرح در طی دوره برنامه‌ریزی در مقابل هدف دوم، یعنی حداقل نمودن میزان تخطی ناشی از عدم تأمین نیازها و تخطی از ظرفیت بهره‌برداری مخزن (تابع خسارت) در طول دوره

Q_t : حداکثر ظرفیت انتقال آب تونل گاوشان در دوره t (متر مکعب بر ثانیه)

در بدنه الگوریتم بهینه‌سازی NSGA-II، میزان رهاسازی جریان ماهانه در طول دوره ۱۸ ساله (از مهر ۱۳۹۳ تا شهریور ۱۴۱۱) به عنوان متغیرهای تصمیم‌گیری (۲۱۶ متغیر) به الگوریتم معرفی گردید. اولویت تخصیص به مصارف در این الگوریتم به ترتیب برای آب شرب، جریان‌های زیست‌محیطی، حقابه‌های سنتی و مصارف کشاورزی دشت‌ها در نظر گرفته شد.

ماشین‌های بردار پشتیبان

نتایج بهینه‌سازی منجر به استخراج میزان رهاسازی بهینه سد یا منحنی فرمان بهینه بر اساس جریان‌های ورودی ثبت شده می‌گردد. در بهره‌برداری واقعی از سیستم مخازن، بهره‌برداران معمولاً از منحنی‌های فرمان پیروی می‌کنند که با استفاده از آن می‌توانند در شرایط مختلف، تصمیم نسبتاً صحیحی را برای بهره‌برداری از مخازن اتخاذ نمایند. منحنی فرمان بیانگر مقدار تخلیه مورد نظر از مخزن یا حجم ذخیره مخزن در یک بازه مشخص از سال (معمولاً ماه) است. همچنین منحنی فرمان بهره‌برداری، یک سری قواعد مشخص و ثابت را در اختیار بهره‌برداران قرار می‌دهد تا بتوانند با توجه به آن و پیش‌بینی جریان‌های آتی، تصمیم‌گیری مناسبی را در مورد رهاسازی‌های در زمان واقعی اتخاذ نمایند. لذا برای استفاده از نتایج بهینه‌سازی در زمان واقعی از روش ماشین‌های بردار پشتیبان در این تحقیق استفاده شد. ماشین‌های بردار پشتیبان یک روش یادگیری است که در اصل بر اساس یک مدل آماری برای دسته‌بندی داده‌ها توسعه یافت (Vapnik, 1995). بعدها این مدل تحت عنوان ماشین‌های بردار رگرسیون برای حل مسائل رگرسیونی، تشخیص الگوی سری‌های زمانی و پیش‌بینی داده بکار گرفته شد (Smola and Scholkopf, 1998; Scholkopf and Smola, 2002)

مطابق با تحقیقات انجام شده، روش ماشین‌های بردار پشتیبان (SVM) به دلیل ساختار مناسبی که برای طبقه‌بندی داده‌ها دارد و همچنین قابلیت آن در استفاده از بردارهای پشتیبان که آستانه خطا را به تدریج کاهش می‌دهند دقت بیشتری برای پیش‌بینی سری‌ها نسبت به شبکه عصبی به دنبال دارد. همچنین زمان حل مساله در آن نیز کمتر است (Shirzad et al., 2014; Huang and Tian, 2015). لذا در این تحقیق نیز از روش SVM استفاده شد. در حالت کلی یادگیری در این روش به دو شکل نظارت شده و نظارت نشده انجام می‌شود. در بسیاری از روش‌های یادگیری نظارت شده مجموعه‌ای از بردارهای ورودی مانند $X = \{x_{11}\}$ و بردارهای خروجی متناظر با آن‌ها $X = \{x_{11}\}$ داده می‌شود. هدف این است که ماشین قادر باشد با استفاده از این داده‌های آموزشی برای ورودی x

$$F_2 = \text{Minimize}(\alpha D + \beta A + \gamma R) \quad (۳)$$

در معادله (۳)، α و β و γ ضرایب ثابت برای هم‌بعد نمودن توابع جریمه می‌باشند. در این تحقیق α برابر ۱۰، β برابر ۱ و γ برابر یک در نظر گرفته شده است. لازم به ذکر است که این ضرایب با سعی و خطا تعیین شده‌اند. همچنین توابع جریمه D ، R و A نیز به صورت معادله‌های (۴)، (۵) و (۶) تعریف می‌شوند:

$$R = \sum_{t=1}^m (\text{Max}((1 - \frac{S_t}{S_{min}}), 0)) \quad (۴)$$

$$D = (\sum_{t=1}^m \sum_{z=1}^{nz} \sum_{d=1}^{nd} (DM_{tzd} - TAW_{tzd})^2) \quad (۵)$$

$$A = (\sum_{t=1}^m \sum_{z=1}^{nz} \sum_{a=1}^{na} (DM_{tza} - TAW_{tza})^2) \quad (۶)$$

که در آن:

DM_{tzd} : نیاز آبی بخش شرب در محل مصرف d در دوره t از منطقه Z

TAW_{tzd} : کل آب شرب تخصیص داده شده در محل مصرف d در دوره t از منطقه Z

DM_{tza} : نیاز آبی بخش کشاورزی در محل مصرف a در دوره t از منطقه Z

TAW_{tza} : کل آب کشاورزی تخصیص داده شده در محل مصرف a در دوره t از منطقه Z

S_t : حجم مخزن سد گاوشان در دوره t

S_{min} : حجم مخزن سد گاوشان در تراز حداقل بهره‌برداری

محدودیت‌ها:

$$TSR_t = R_t + R_{r1} + R_{r2} \quad (۷)$$

TSR_t : میزان کل آب سطحی تخصیص داده شده در دوره t
 R_t : حجم آب برداشتی از سد گاوشان در دوره t (که شامل مجموع حجم آب برداشتی از کانال‌های انتقال آب شرب سد گاوشان، حجم آب برداشتی از بند انحرافی رازآور و حجم آب تخصیص یافته به اراضی بیله‌ور ($b1b2$, $b3b4$) و میان‌دریوند می‌باشد.)

R_{r1} : حجم آب برداشتی از رودخانه گاوهرود در دوره t

R_{r2} : حجم آب برداشتی از رودخانه رازآور در دوره t

$$Q_t \leq 30 \text{ m}^3/\text{s} \quad (۸)$$

$$\min \frac{1}{2} \|w\|^2 + \frac{C}{m} \sum_{i=1}^m l(y_i, f(z)) \quad (13)$$

که $l(y_i, f(z))$ تابع هزینه بر اساس مقدار تخطی از خطای مجاز ε است که از رابطه (۱۴) به دست می‌آید.

$$l(y_i, f(z)) = |y - f(z)|_\varepsilon = \max\{0, |y - f(z)| - \varepsilon\} \quad (14)$$

ترم $\frac{1}{2} \|w\|^2$ در اصل با کمینه کردن وزن‌های لایه‌ها که اعداد حقیقی می‌باشند سعی می‌کند مدل را تا حد امکان ساده‌سازی کند. رابطه (۱۳) می‌تواند به شکل رابطه (۱۵) بیان شود که باید با توجه به محدودیت‌های رابطه (۱۶) بهینه گردد:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \quad (15)$$

$$\text{Subject to } \begin{cases} y_i - wx_i - b \leq \varepsilon + \xi_i \\ wx_i + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (16)$$

که ξ_i و ξ_i^* متغیرهای کمبود، y_i مقدار سری زمانی مشاهداتی و $wx_i + b$ مقدار سری زمانی پیش‌بینی شده است. M تعداد داده‌های مورد استفاده در مرحله آموزش است و C یک پارامتر تنظیمی تحت عنوان ضریب تابع هزینه است. در نهایت پس از تعیین ضرایب و تابع کرنل مناسب پیش‌بینی سری زمانی توسط رابطه (۱۷) صورت می‌گیرد.

$$y = \sum_{i=1}^n (\alpha_i^+ - \alpha_i^-) K(x_i, x) + b \quad (17)$$

که b مقدار عرض از مبدا یا مقدار اربب مدل و α_i ضرایب لاگرانژ و $\alpha_i^+ - \alpha_i^-$ وزن تابع کرنل در هر لایه i در کل فضای مشخصه می‌باشد. جهت درک بهتر نحوه عمل مدل ترکیبی الگوریتم NSGA-II و ماشین بردار پشتیبان فلوچارت مراحل کار در شکل (۴) نشان داده شده است.

جدید، خروجی y را پیش‌بینی نماید (Candela and Hansen, 2002). در فرآیند یادگیری ابتدا سیستم تعلیم یافته و سپس به ازای مقادیر ورودی جدید آزمایش می‌شود. به شکل ریاضی مسئله یادگیری ماشین بردار رگرسیون را می‌توان به شکل یک نگاشت در فضای پیوسته در نظر گرفت که طی آن بردار n بعدی x به عنوان ورودی منجر به ایجاد یک بردار y به عنوان خروجی یا هدف می‌شود که هر دو عضو مجموعه اعداد حقیقی هستند در حالی که در مدل SVM بردار خروجی عضو مجموعه باینری است. ابتدا طبق رابطه (۹) تابع Φ تعریف می‌شود (Xi et al., 2007):

$$\Phi: X \rightarrow H \quad ; \quad x \rightarrow z = \Phi(x) \quad (9)$$

در این تابع X مجموعه ورودی‌هاست که شامل بردارهای ورودی x_i است. H فضای مشخصه است که شامل مجموعه بردارهای z می‌باشد. در فضای مشخصه یک تابع خطی بصورت رابطه (۱۰) بر داده‌ها برازش داده می‌شود.

$$f(z) = w \cdot z + b \quad (10)$$

در صورتی که داده‌ها در فضای ورودی اولیه به شکل خطی جداپذیر نباشند ماشین بردار پشتیبان فضای اولیه را به فضای مشخصه با ابعاد بالاتر تبدیل می‌کند. این تبدیل توسط تابع تصویر کننده (کرنل) غیرخطی k انجام می‌شود تابع غیرخطی k بصورت رابطه (۱۱) می‌شود و حاصل ضرب داخلی توابع Φ است.

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) = z_i \cdot z_j \quad (11)$$

یکی از توابع کرنل پرکاربرد که در این تحقیق از آن استفاده شده تحت عنوان تابع گوسی بصورت رابطه (۱۲) تعریف می‌شود.

$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}} \quad (12)$$

پس از مرحله تبدیل غیرخطی، ماشین‌های بردار پشتیبان در این فضای مشخصه جدید یک ابر صفحه جداساز بهینه با حداکثر حاشیه اطمینان را جستجو می‌کنند. در پیش‌بینی سری زمانی در ماشین بردار پشتیبان رابطه (۱۳) باید کمینه گردد:

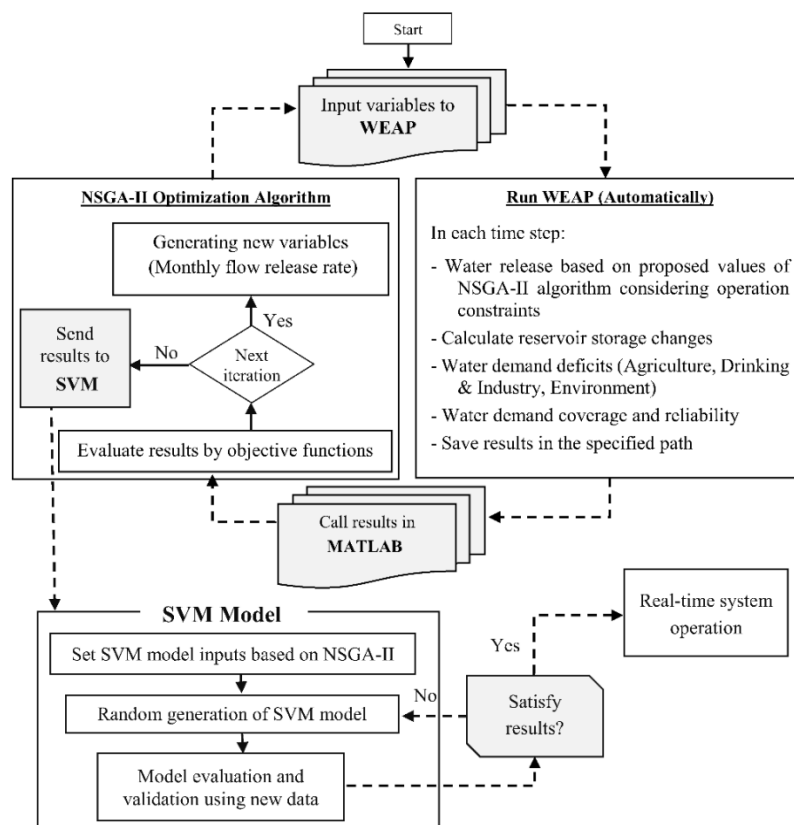


Fig. 4- Flowchart of Combination of NSGA-II Algorithm Results with SVM model

شکل ۴- فلوجارت مراحل ترکیب نتایج الگوریتم NSGA-II با ماشین های بردار پشتیبان

مسأله و تعداد متغیرهای زیاد، تعداد تکرار الگوریتم جهت رسیدن به همگرایی در حدود ۵۰۰ در نظر گرفته شد.

در نهایت پس از انجام بهینه‌سازی، منحنی تبادل بهینه بین اهداف بهینه‌سازی (تابع حداکثرسازی اطمینان‌پذیری و تابع حداقل‌سازی جریمه ناشی از تخطی سیستم از تأمین نیاز مصارف) به دست آمد. مطابق با روش الگوریتم ژنتیک مبتنی بر جواب غیرپست، در هر تکرار بهترین جواب‌ها بر اساس ارزش‌گذاری توابع هدف و فرآیند نخبه‌گرایی 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 مجموعه ۳۲ جواب بهینه بر اساس توابع هدف F_1 و F_2 در آخرین تکرار در شکل (۵) نشان داده شده است. در آخرین تکرار مدل، ۳۲ جواب بهینه بر روی جبهه پارتو ارائه شد که از بین آن‌ها با توجه به ارزش‌گذاری توابع هدف، راه حلی که هم زمان دارای کم‌ترین میزان جریمه و بیش‌ترین میزان اطمینان‌پذیری بود به عنوان جواب برتر انتخاب شد. پس از توقف الگوریتم، از بین جواب‌های تکرار آخر، نتایج حاصل از ورود

نتایج و بحث

در سناریوی بهینه، اجراهای مکرر الگوریتم نشان داد برای رسیدن به نتایج بهتر، جمعیت اولیه کروموزوم‌ها باید حداقل دو برابر تعداد متغیرهای تصمیم باشد که در این تحقیق تعداد جمعیت اولیه در مدل در حدود ۴۳۲ انتخاب شد. انتخاب تعداد جمعیت بیشتر زمان اجرای مدل را به شدت افزایش می‌دهد. پارامترهای دیگر الگوریتم مانند درصد و نرخ جابجایی، نرخ جهش و غیره بطور مناسبی انتخاب شدند. در تمامی تکرارهای الگوریتم بهینه‌ساز، تولید متغیرهای جدید بر اساس متغیرهای قبلی در کسری از ثانیه انجام شده و تاثیر زیادی بر زمان اجرای مدل کوپل شده شبیه‌سازی- بهینه‌سازی نداشت. چون قسمت اعظم زمان اجرای مدل کوپل شده مربوط به اجرای شبیه‌ساز در هر تکرار است که با توجه حل همزمان معادلات بیلان در مدل WEAP، هر بار اجرای آن زمان زیادی نیاز داشت. بر این اساس نتایج نشان داد که در تکرارهای پایین‌تر میزان تابع اطمینان‌پذیری و تابع خسارت (جریمه)، هر دو تغییرات محسوس دارند. اما در تکرارهای بالاتر دامنه تغییرات تابع اطمینان‌پذیری ثابت شد و مدل بر روی کاهش جریمه متمرکز شد. با توجه به پیچیدگی

نشان می‌دهد. این جدول نشان می‌دهد تأمین نیاز اراضی دشت‌های مورد مطالعه در بیشتر ماه‌ها به طور کامل و در حد مطلوب می‌باشد. بر این اساس مقدار هر کدام از نیازهای شرب و کشاورزی و زیست‌محیطی و همچنین مقدار تخصیص بهینه از سد به کل مصارف در طول دوره بهره‌برداری (۱۸ سال) در شکل (۶) نشان داده شده است.

متغیرهای بهینه ناشی از جواب منتخب در مدل آب سطحی ویپ مورد بررسی و تجزیه و تحلیل قرار گرفت. نتایج مربوط به درصدهای تأمین و اطمینان‌پذیری نیازها در صورت استفاده از این راه حل بهینه در جدول (۲) نشان داده شده است. جدول (۲) درصد تأمین نیاز و اطمینان‌پذیری نیازهای شرب و کشاورزی را بعد از استفاده از متغیرهای تصمیم بهینه حاصل از الگوریتم بهینه‌سازی NSGA-II در بدنه مدل شبیه‌ساز WEAP




Fig. 5- The optimal exchange curve between optimization goals (Pareto curve) in iteration 500

شکل ۵- منحنی تبادل بهینه بین اهداف بهینه‌سازی (منحنی پارتو) در تکرار ۵۰۰

جدول ۲- میانگین شاخص‌های درصد تأمین و اطمینان‌پذیری نیازها (راه حل بهینه)

Table 2- The average percentage of water demand coverage and reliability (Re) for optimal solution

Demands	Watre Demand Coverage (%)												Re (%)
	Oct	Nov	Dec	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	
Miandarband	91.2	77.7	100	100	100	100	100	91.02	100	100	97.5	70.8	79.2
Bilevar- b1b2	91.2	77.7	100	100	100	100	100	91.02	100	100	97.5	70.8	79.2
Bilevar- b3b4	91.2	77.7	100	100	100	100	100	91.02	100	100	97.5	70.8	79.2
Drinking water	100	100	100	100	100	100	100	100	100	100	100	100	100
Enviroment Demand	100	100	100	100	100	100	100	100	100	100	100	100	100

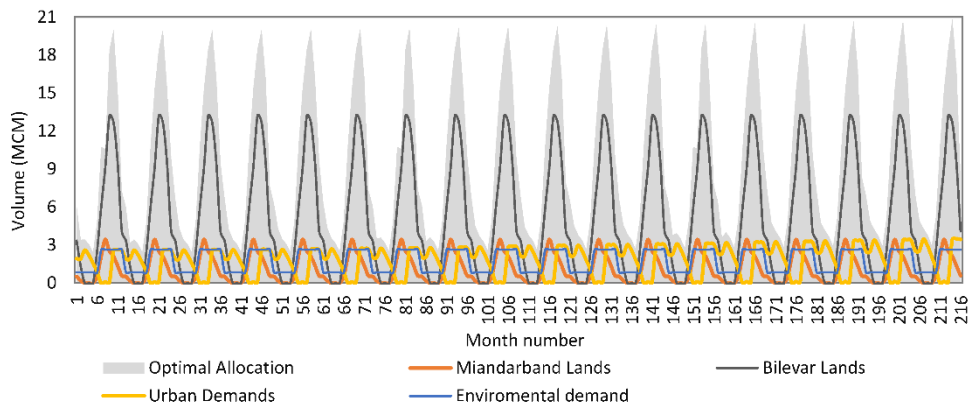


Fig. 6- Optimal amounts allocated to each demand during the operation period (MCM)

شکل ۶- مقادیر بهینه تخصیص به هر کدام از مصارف در طول دوره بهره‌برداری (میلیون متر مکعب)




Fig. 7- Validation of SVM Model to Estimate Optimal Release Rate from Gavshan Dam

شکل ۷- صحت‌سنجی مدل ماشین بردار پشتیبان در تخمین میزان رهاسازی بهینه از سد گاوشان




Fig. 8- Relative Error Percentage of SVM Model to Estimate Optimal Release Rate from Gavshan Dam

شکل ۸- درصد خطای نسبی مدل ماشین بردار پشتیبان در تخمین میزان رهاسازی بهینه از سد گاوشان

تابع کرنل قابل استفاده در مدل ماشین بردار پشتیبان در این تحقیق تابع گوسی (تابع کرنل RBF) می‌باشد.

Noori et al. (2010) و Du et al. (2017) در تحقیقات

خود همین تابع کرنل را پیشنهاد دادند. مقادیر بهینه پارامترهای C ، ϵ

و γ در بدنه ماشین بردار پشتیبان با استفاده از روش جستجوی شبکه برابر با ۱۰۰۰، ۰/۰۲ و ۱۲ بدست آمد. در شکل (۷) نتایج

صحت‌سنجی پیش‌بینی ماشین بردار پشتیبان بر اساس خروجی الگوریتم بهینه‌سازی آورده شده است. شکل (۷) 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. Bazargan lari et al. (2011) نیز از همین رویکرد در

استخراج میزان برداشت بهینه از آب زیرزمینی استفاده کردند و نتایج رضایت‌بخشی برای استفاده از نتایج حاصل در زمان واقعی گرفتند.

Nikoo et al. (2013) نیز از همین روش برای تدوین قوانین

در نهایت ماشین‌های بردار پشتیبان بر اساس خروجی الگوریتم

بهینه‌سازی و برای یک دوره ۱۹۲ ماهه آموزش داده شد. سپس برای یک دوره ۲۴ ماهه از داده‌ها که در مرحله آموزش از آن‌ها استفاده

نشده بود، صحت‌سنجی صورت گرفت. بدین ترتیب که در این دوره بر اساس مقادیر جریان ورودی به مخزن (در ابتدای ماه)، حجم

ذخیره آب در مخزن (در ابتدای ماه) و تغییرات ذخیره مخزن و نیازهای پایین‌دست در ماه حاضر، مقدار رهاسازی بهینه بر اساس

ماشین‌های بردار پشتیبان بدست آمد و نتایج حاصل با خروجی حاصل از الگوریتم بهینه‌سازی در این دوره ۲۴ ماهه مقایسه شد. بر اساس

صحت‌سنجی، بهترین ماشین بردار پشتیبان باید قادر باشد مقادیر رهاسازی بهینه از سد را با توجه به ورودی‌های ذکر شده پیش‌بینی

نماید و نتایج حاصل از آن کم‌ترین اختلاف را با نتایج حاصل از الگوریتم بهینه‌سازی داشته باشد. این امر در تحقیقات Thissen et

al. (2003) و Lin et al. (2006) نیز برای اثبات برتری ماشین بردار پشتیبان مورد توجه قرار گرفته است. نتایج نشان داد بهترین

تامین مصارف پایین‌دست در این شرایط بهینه گردید. اشکال چنین مدل‌هایی این است که جواب‌های بهینه قابل تعمیم برای سایر ورودی‌های ممکن به احتمال زیاد جواب‌های بهینه بدست آمده کارایی نداشته و باید بهره‌برداری از سیستم در قالب الگوریتم بهینه‌ساز مجدداً بهینه گردد. لذا برای استفاده از نتایج بهینه‌سازی در زمان واقعی از روش هوشمند ماشین‌های بردار پشتیبان استفاده شد. نتایج نشان داد میزان میانگین خطای قوانین بهینه مستخرج از ماشین‌های بردار پشتیبان نسبت به خروجی الگوریتم بهینه‌سازی NSGA-II در مرحله صحت‌سنجی کمتر از ۱۰ درصد است که نشان دهنده کارایی این روش در پیش‌بینی الگوی بهینه منحنی فرمان سد در زمان واقعی است. لذا در این ساختار می‌توان بر اساس جریان ورودی به مخزن (در ابتدای ماه)، حجم ذخیره آب در مخزن (در ابتدای ماه) و تغییرات ذخیره مخزن و نیازهای پایین‌دست در ماه حاضر، مقدار رهاسازی بهینه را در زمان واقعی بدست آورد. یعنی مدل ماشین بردار پشتیبان 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.

تقدیر و تشکر

نویسندگان از شرکت آب‌منطقه ای کرمانشاه به خاطر فراهم نمودن آمار و اطلاعات مورد نیاز این تحقیق تشکر و قدردانی می‌کنند.

بهره‌برداری در زمان واقعی بهره گرفتند و به بهره‌برداری تلفیقی بهینه کمی- کیفی تخصیص آب و بار آلودگی در سطح حوضه سد زاینده‌رود دست یافتند.

همچنین میزان خطای نسبی مدل توسعه داده شده در تخمین مقدار رهاسازی بهینه از سد در شکل (۸) نشان داده شده است. این شکل کارایی مدل ماشین بردار پشتیبان آموزش داده شده برای تخمین خروجی بهینه در حالت استفاده از سری داده‌های جدیدی که در آموزش استفاده نشده را نشان می‌دهد. بر اساس این شکل میانگین درصد خطا برای ۲۴ ماه حدود ۹/۸ درصد و بیشترین میزان خطا حدود ۱۷/۷ درصد بوده است.

نتیجه‌گیری

به طور کلی نتایج نشان داد مدل توسعه داده شده بر اساس ترکیب الگوریتم چندهدفه NSGA-II و مدل شبیه‌سازی WEAP قابلیت و کارایی مناسبی در حل مسائل پیچیده و کاملاً غیرخطی و ارائه جواب‌های بهینه دارد. طوری که در آخرین تکرار الگوریتم، منحنی تبادل اهداف بر اساس ۳۲ جواب در جبهه بهینه پارتو تشکیل شد. از بین این راه‌حل‌ها، با توجه به ارزش‌گذاری توابع هدف، راه‌حلی که هم‌زمان دارای کم‌ترین میزان جریمه و بیش‌ترین میزان اطمینان‌پذیری 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 NSGA-II و شبیه‌ساز WEAP بر اساس یک سری معین از جریان ورودی به مخزن در طول دوره بهره‌برداری است و رهاسازی از مخزن جهت

References

- 1- Bazargan-Lari, M.R., Kerachian, R., Sedghi, H., Fallahnia, M., Abed-Elmdoust, A. and Nikoo, M.R., 2011. Developing probabilistic operating rules for real-time conjunctive use of surface and groundwater resources: Application of support vector machines. *J. of Water and Wastewater*, 76, pp.54-69. (In Persian).
- 2- Blum, C., and Roli, A., 2003. Metaheuristics in combinatorial optimization: Overview and conceptual comparison, *ACM Computing Surveys*, 35(3), pp. 268-308.
- 3- Candela, J. Q. and Hansen, L. K., 2002. Time series prediction based on the Relevance Vector Machine with adaptive kernels, *Acoustics, Speech, and Signal Processing (ICASSP)*, In IEEE International Conference on, Orlando, FL, USA
- 4- Chang, J. F., Chen, L., and Chang, C. L., 2005. Optimizing reservoir operating rule curves by genetic algorithms, *Hydrological Processes*, 19, pp. 2277-2289.
- 5- Deb, k., Pratap, A., Agarwal, S., and Meyarivan, T., 2002. A fast and elitist multi-objective genetic algorithm: NSGA-II, *IEEE Trans Evolutionary Computing*, Indian, 6(2), pp. 182-197.

- 6- Du, J., Liu, Y., Yu, Y. and Yan, W., 2017. A Prediction of Precipitation Data Based on Support Vector Machine and Particle Swarm Optimization (PSO-SVM) Algorithms, *Algorithms*, 10 (57), pp. 1-15.
- 7- Esmikhani, M., Safavi, H. and Yazdani-Poor, M., 2010. Integrated management of surface water and groundwater resources using the methods of support vector machines and genetic algorithms, In 5th National Congress on Civil Engineering, Ferdowsi University of Mashhad, Mashhad, Iran.
- 8- Gen, M., and Cheng, R. W., 1997. *Genetic Algorithms and Engineering Design*. John Wiley & Sons, Inc.
- 9- Hojjati, A., FaridHoseini, A. R., Ghahreman, B. and Alizadeh, A., 2013. The comparison of the application of heuristic methods in optimization of multiobjective water resources systems, *Water and Environment Engineering*, 1(2), pp. 9-14. (In Persian).
- 10- Huang, M. and Tian, Y., 2015. Prediction of Groundwater Level for Sustainable Water Management in an Arid Basin Using Data driven Models, In *International Conference on Sustainable Energy and Environmental Engineering (SEEE)*, Bangkok.
- 11- Jian, C. Qiang, H., and Min, W., 2005. Genetic algorithm for optimal dispatchin, *Water Resource Planning and Management*, 19, pp. 321-331.
- 12- Li, X., Sha, J., Li, Y. M. and Wang, Z. L., 2017. Comparison of hybrid models for daily stream flow prediction in a forested basin, *Journal of Hydro informatics*, Available Online 29 November 2017, 20(1):jh2017189, doi: 10.2166/hydro.2017.189.
- 13- Lin, J. Y., Cheng, C. T. and Chau, K. W., 2006. Using support vector machines for long-term discharge prediction, *Hydrological Sciences–Journal–des Sciences Hydrologiques*, 51(4), pp. 599-612.
- 14- Mirfendreski, G. and Mosavi, S.J., 2011. Supported vector machines for super-modeling in order to optimize the allocation of basin water resources, In 6th National Congress on Civil Engineering, Semnan University, Semnan, Iran.
- 15- Momtahan, Sh., and Dariane, A. B., 2007. Direct search approaches using genetic algorithms for optimization of water reservoir operating policies, *Water Resource Planning and Management*, ASCE, 133(3), pp. 202–209.
- 16- Nakhaei, M., Mohammadi, M. and Rezaei, M., 2014. Optimizing of Aquifer Withdrawal Numerical Model Using Genetic Algorithm (Case Study: Uromiyeh Coastal Aquifer), *Iran Water Resources Research*, 10(2), pp. 94-97. (In Persian).
- 17- Nikoo, M. R., Karimi, A., Kerachian, R. and Bashi-Azghadi, S. N., 2013. Long-term Optimum Water and Waste Load Allocation Rules in River-ReservoirGroundwater Systems: Application of SVR Simulation Model, *Water and Environment Engineering*, 1(1), pp. 1-11. (In Persian).
- 18- Noori, R., Khakpour, A., Dehghani, M. and Farokhnia, A., 2010. Monthly Stream Flow Prediction Using Support Vector Machine Based on Principal Component Analysis, *Journal of Water and Wastewater*, 1, pp.118-129. (In Persian).
- 19- Schölkopf, B. and Smola, A., 2002. *Learning with Kernels*. MIT Press.
- 20- Shirzad, A., Tabesh, M. and Farmani. R. 2014. A Comparison between Performance of Support Vector Regression and Artificial Neural Network in Prediction of Pipe Burst Rate in Water Distribution Networks, *KSCE Journal of Civil Engineering*, 18(4), pp. 941-948.
- 21- Smola, A. J and Schölkopf, B., 1998. On a kernel-based method for pattern recognition, regression, approximation and operator inversion, *Algorithmica*, 22, pp. 211–231.

-
- 22- Tennant, D. L., 1976. Instream flow regimens for fish, wildlife, recreation and related environmental resources, *Fisheries*, 1(4), pp. 6-10.
- 23- Thissen, U., van Brakel, R., de Weijer, A. P., Melssen, W.J. and Buydens, L. M. C., 2003. Using support vector machines for time series prediction, *Chemometrics and Intelligent Laboratory Systems*, 69, pp. 35–49.
- 24- Vapnik, V., 1995. *The nature of statistical learning theory*. Springer-Verlag, NewYork.
- 25- Wardlaw, R., and Sharif, M., 1999. Evaluation of genetic algorithms for optimal reservoir system operation, *Water Resource Planning and Management, ASCE*. 125(1), pp. 25-33.
- 26- Xi, X. C., Poo, A. N. and S. K. Cho., 2007. Support vector regression model predictive control on a HVAC plant, *Control Engineering Practice*, 15, pp. 897–908.