



Supervised learning to manage irrigation canals' operation

Kazem Shahverdi 

Corresponding Author, Department of Water Sciences and Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran. E-mail: k.shahverdi@basu.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 27 October 2024

Received in revised form

2 November 2024

Accepted 24 December 2024

Published online 10 February 2025

Keywords:

ANN

Operation Management

SVM

Water canal

ABSTRACT

Due to the ever-increasing need for water due to rapid population growth, increased need for food, urbanization, and industry, the pressure on water resources is high. Optimal management of water in the canal networks can play an effective role in reducing this pressure. The research literature review shows that the support vector machine method, as one of the artificial intelligence methods, has received less attention for optimal water management in the canal network. In this research, the support vector machine method was used to manage the operation of the eastern Aghili canal, by considering the discharge of the canal as the input and associated gate opening as the output so that the water depth remains at the target depth, the training of the support vector machine was done. In the next step, the prediction was made for different inputs, and canal simulation was done using a hydrodynamic model, and the criteria for evaluation of equity, dependability, efficiency, and adequacy were calculated, which were respectively smaller than 0.1, smaller than 0.1, larger than 0.85, and greater than 0.9. The results of the vector machine were compared with the results of the artificial neural network, which indicated the superiority of the support vector machine.

Cite this article: Shahverdi, K. (2025). Supervised learning to manage irrigation canals' operation. *Journal of Water and Irrigation Management*, 14 (4), 1005-1018. DOI: <https://doi.org/10.22059/jwim.2024.384476.1187>



© The Author(s).

DOI: <https://doi.org/10.22059/jwim.2024.384476.1187>

Publisher: University of Tehran Press.



یادگیری نظارت‌شده در مدیریت بهره‌برداری از کانال‌های آبیاری

کاظم شاهوردی ✉

نویسنده مسئول، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران. رایانامه: k.shahverdi@basu.ac.ir

چکیده

اطلاعات مقاله

با توجه به نیاز روزافزون به آب به دلیل رشد روز افزون جمعیت، افزایش نیاز به غذا، شهرنشینی و صنعت، فشار بر روی منابع آب زیاد است. مدیریت بهینه آب در شبکه کانال‌ها می‌تواند نقش مؤثری در کاهش این فشار باشد. بررسی ادبیات پژوهش نشان می‌دهد که روش ماشین بردار پشتیبان، به‌عنوان یکی از روش‌های هوشمند، برای مدیریت بهینه آب در شبکه کانال‌ها کم‌تر مورد توجه قرار گرفته است. در این پژوهش، روش ماشین بردار پشتیبان برای مدیریت بهره‌برداری کانال عقیلی شرقی مورد استفاده قرار گرفت و با در نظر گرفتن دبی آبگیرها به‌عنوان ورودی و بازشدگی آن‌ها به‌عنوان خروجی به‌طوری که عمق آب در عمق هدف بماند، آموزش ماشین بردار پشتیبان صورت گرفت. در گام بعدی، پیش‌بینی برای حالت‌های مختلف صورت گرفت و با استفاده از مدل هیدرودینامیک، شبیه‌سازی کانال انجام شد و نتیجه‌های ارزیابی عدالت، پایداری، راندمان و کفایت محاسبه شد که به ترتیب کوچک‌تر از ۰/۱، کوچک‌تر از ۰/۱، بزرگ‌تر از ۰/۸۵ و بزرگ‌تر از ۰/۹ به‌دست آمد. نتایج کاربرد ماشین بردار با نتایج شبکه عصبی مصنوعی مقایسه شد که نشانگر برتری ماشین بردار پشتیبان بود.

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۸/۰۶

تاریخ بازنگری: ۱۴۰۳/۰۸/۱۲

تاریخ پذیرش: ۱۴۰۳/۱۰/۰۴

تاریخ انتشار: ۱۴۰۳/۱۱/۲۲

کلیدواژه‌ها:

کانال آب

مدیریت بهره‌برداری

ANN

SVM

استناد: شاهوردی، کاظم (۱۴۰۳). یادگیری نظارت‌شده در مدیریت بهره‌برداری از کانال‌های آبیاری. نشریه مدیریت آب و آبیاری، ۱۴ (۴)، ۱۰۰۵-۱۰۱۸.
DOI: <https://doi.org/10.22059/jwim.2024.384476.1187>



۱. مقدمه

تخصیص مؤثر و بهینه منابع آب در کشاورزی، به‌ویژه در مناطق خشک و نیمه‌خشک، مانند ایران، که به‌علت رشد سریع جمعیت، کشاورزی، شهرنشینی و صنعت با کمبود آب مواجه هستند یکی از موضوعات مهم در مدیریت بهینه آب در شبکه کانال‌ها بوده است. از این‌رو، همواره رویکردهای جدید در این راستا مورد استفاده و آزمون و ارزیابی قرار گرفته است (Shahverdi and Maestre, 2022). بهره‌برداری مناسب سازه‌های تنظیم جریان آب در کانال با استفاده از روش‌های توزیع و تحویل، منجر به افزایش راندمان آبیاری و رسیدن به کشاورزی پایدار می‌شود که می‌تواند با استفاده از فناوری‌ها و روش‌های مدرن برای بهبود مدیریت کانال‌ها انجام شود. کاربرد روش‌های هوش مصنوعی مانند ماشین بردار پشتیبان یا SVM (support vector machine) و شبکه‌های عصبی مصنوعی یا ANN (artificial neural network) در سیستم کانال به‌عنوان یک روند نوین و کارآمد در مدیریت منابع آب به‌طور فزاینده‌ای در حال افزایش است (Shahverdi et al., 2023).

مدل ریاضی مبتنی بر هوش مصنوعی برای کنترل خودکار عمق آب در بالادست سازه‌های کنترل برای بهبود انعطاف‌پذیری عملکرد کانال آب توسعه داده شد و در مدل ریاضی یک فلوم آزمایشگاهی مورد استفاده قرار گرفت. سناریوهای مختلف افزایش و کاهش ورودی شبیه‌سازی شد. نتایج نشان داد حداکثر و میانگین خطای عمق آب به ترتیب برابر با ۳/۰۷ و ۰/۱۵۲ درصد است که نشانگر توانایی روش هوش مصنوعی در بهبود عملکرد کانال است (Shahverdi and Monem 2015). برای افزایش کارایی مصرف آب کانال رودشت در مرکز ایران، عملکرد کانال با استفاده از شبکه عصبی مصنوعی، به‌عنوان یک مدل هوشمند، که نوسانات ورودی قابل‌توجهی دارد ارزیابی شد. برای شبیه‌سازی هیدرولیکی کانال و فراهم کردن داده‌های لازم برای آموزش و اعتبارسنجی مدل هوشمند شبکه عصبی مصنوعی از مدل HEC-RAS استفاده شد. نتایج نشان داد که مدل هوشمند ابزاری مناسب برای ارزیابی عملکرد کانال‌ها بوده و عملکرد مطلوبی در تحویل و توزیع بهینه آب در کانال دارد (Sharifi et al., 2021).

روش شبکه عصبی مصنوعی برای خودکارسازی سرریز با ارتفاع متغیر در سیستم کانال‌ها جهت بهبود مدیریت کانال مورد استفاده قرار گرفت. داده‌های مورد نیاز برای آموزش و اعتبارسنجی مدل شامل دبی ورودی به کانال، تغییر دبی در سه دوره متوالی، انحراف سطح آب از مقدار هدف و دبی خروجی به‌عنوان پارامترهای ورودی به مدل‌های هوش مصنوعی و تنظیم مقدار زاویه سرریز آبی و در نتیجه ارتفاع آب برای حفظ عمق آب در محدوده هدف به‌عنوان پارامتر خروجی بود. نتایج نشان داد که ضرایب همبستگی در حالت آبیاری و دون آبیاری به ترتیب برابر با ۰/۹۵ و ۰/۹۳ می‌باشد که نشان می‌دهد شبکه عصبی مصنوعی دقت بالایی در پیش‌بینی سطح آب و کنترل سرریز دارد (Zamani et al., 2024).

برای پیش‌بینی رابطه بین پارامترهای دبی جریان و تنظیم سازه‌ها و بهینه‌سازی بهره‌برداری کانال‌ها در شرایط جریان غیرماندگار، الگوریتم ژنتیک و شبکه عصبی مصنوعی ترکیب شد. شبکه عصبی مصنوعی با استفاده از مجموعه داده‌های مربوط به جریان غیرماندگار آموزش داده شد. سپس، الگوریتم ژنتیک برای یافتن الگوهای مناسب بهره‌برداری با هدف حداقل کردن زمان تحویل و حداکثر کردن راندمان تحویل آب مورد استفاده قرار گرفت. نتایج نشان داد که رویکرد ترکیبی عملکرد مناسبی در استخراج الگوهای مناسب بهره‌برداری در کانال‌ها دارد که با استفاده از آن زمان تحویل آب کاهش و کارایی تحویل آب در شرایط جریان غیرماندگار افزایش داد. به‌طوری‌که، به‌طور متوسط ۵۰ درصد بهبود در عملکرد کانال حاصل شد که مقدار قابل‌توجهی می‌باشد (Savari and Monem, 2022).

مدل سازی هیدرولیکی یک بازه از کانال اصلی آبیاری با استفاده از شبکه‌های عصبی مصنوعی به‌صورت آزمایشگاهی و عملیاتی در شرایط مختلف جریان بررسی شد. از آنجایی‌که معادلات هیدرولیکی دینامیک کانال غیرخطی هستند، حل آن‌ها نیازمند محاسبات زیادی است. در این پژوهش یک مدل خطی برای کانال آبیاری براساس یک شبکه عصبی

مصنوعی توسعه داده شد و از آن برای شبیه‌سازی کانال استفاده شد. در پژوهش مذکور، سطح آب بازه مجاور پایین‌دست به‌عنوان ورودی به شبکه عصبی استفاده شد. نتایج نشان داد که این مدل می‌تواند در شرایط مختلف جریان، دبی آب را با دقت بالایی به خروجی‌ها تحویل دهد و قادر به تشخیص زودهنگام خطا و کاهش هدررفت آب است (Bentima et al., 2024).

روش ماشین بردار پشتیبان برای تخمین پروفیل سطح آب کانال‌های مرکب دارای دشت‌های سیلابی باریک با استفاده از پارامترهای هندسی و جریان غیربعدي از جمله نسبت عرض، عمق نسبی، فاصله نسبی و شیب بستر استفاده شد. نتایج این مطالعه نشان داد که پروفایل سطح آب تولیدشده توسط ماشین بردار پشتیبان تطابق مناسبی با داده‌های تجربی و یافته‌های پژوهش‌های قبلی دارد، به‌طوری‌که مقدار ضریب تعیین، ریشه میانگین مربع خطاها، میانگین خطای مطلق حداکثر به‌ترتیب برابر با ۰/۹۹، ۰/۱۹۹ و ۱/۲۶۳ است که نشان می‌دهد که مدل ماشین بردار پشتیبان عملکرد مناسبی در پیش‌بینی پروفایل سطح آب دارد (Kaushik and Kumar, 2023).

همانطور که مشاهده می‌شود روش‌های هوش مصنوعی کاربرد زیادی در بهره‌برداری کانال‌های آب دارند. با این حال، به‌کارگیری ماشین بردار پشتیبان برای مدیریت بهره‌برداری کانال‌ها کمتر مورد توجه قرار گرفته است که هدف پژوهش حاضر است. در این پژوهش، ماشین بردار پشتیبان برای مدیریت بهره‌برداری کانال عقلی شرقی مورد استفاده قرار گرفت و با نتایج روش شبکه عصبی مصنوعی مقایسه شد. دبی و بازشدگی آبیگرها به‌ترتیب به‌عنوان ورودی و خروجی به مدل معرفی شد. نتایج با استفاده از شاخص‌های ارزیابی عملکرد کانال‌ها مورد ارزیابی قرار گرفت.

۲. مواد و روش‌ها

روش‌شناسی پژوهش حاضر به‌طور مختصر در ادامه تشریح می‌شود. ابتدا، داده‌های مورد نیاز از کانال مورد مطالعه که در بخش بعدی تشریح می‌شود، جمع‌آوری شد. سپس، با معرفی داده‌ها به روش‌های هوشمند ماشین بردار پشتیبان و شبکه عصبی مصنوعی، یادگیری صورت گرفت. با استفاده از یادگیری انجام‌شده و با معرفی ورودی‌های جدید به روش‌های هوشمند، مقادیر متناظر خروجی استخراج شد. لازم به ذکر است که ورودی و خروجی به روش‌های هوشمند به‌ترتیب مقدار دبی عبوری و بازشدگی آبیگرها بود. با معرفی این داده‌ها به مدل هیدرودینامیک ICSS، مقادیر سری زمانی دبی عبوری از آبیگرها محاسبه شد و با مقایسه با مقادیر هدف و سنج‌های ارزیابی، عملکرد مدل‌ها بررسی شد و مورد مقایسه قرار گرفت.

۲.۱. کانال مورد مطالعه

کانال مورد مطالعه در این پژوهش، کانال بتنی عقلی شرقی با طول حدود ۱۶ کیلومتر و حداکثر دبی ۵ مترمکعب در ثانیه است که هر روز صبح به‌صورت دستی توسط یک میراب بهره‌برداری می‌شود. لازم به ذکر است که در حال حاضر، به‌علت کمبود آب مقدار دبی ورودی به کانال در حدود یک مترمکعب در ثانیه است. میراب با استفاده از یک موتورسیکل در طول کانال از بالادست به پایین‌دست حرکت کرده و تنظیمات سازه‌ها به‌صورت تجربی (با تجربه شخصی) انجام می‌دهد. این کانال دارای شیب ملایم بوده و دارای به‌ترتیب ۲۰ آبیگر، ۱۱ سازه کنترل، که چهار مورد آن دارای شیب‌شکن است و چک-دراپ نامیده می‌شود، و چهار سیفون می‌باشد. عرض و ارتفاع آبیگرها به‌ترتیب برابر با ۳۰ و ۶۰ سانتی‌متر است. ابعاد پنج سازه کنترل ابتدایی برابر با ۱/۵×۱/۵ متر و ابعاد سایر سازه‌های کنترل ۱×۱ متر است.

روش بهره‌برداری این کانال به‌صورت برحسب درخواست (توافقی) است که در مورد دبی، دور و زمان آبیاری توافق صورت می‌گیرد و در هر دور آبیاری حجم مورد توافق را می‌تواند تحویل بگیرد. حجم آب مورد نیاز برای هر آبیگر براساس

مساحت زمین‌های تحت پوشش آن و نیاز آبیاری برای ماه حداکثر مصرف الگوی زارعی منطقه که در حال حاضر کشت غالب آن گندم می‌باشد، در نظر گرفته شده و حجم آب موردنیاز برابر ۱۰۸۰ مترمکعب در هکتار برآورد شده است (Hadiseraji *et al.*, 2022). داده‌های موردنیاز در این پژوهش از سال ۱۳۸۷ تا ۱۳۹۶ از دفتر شبکه آبیاری عقیلی جمع‌آوری شده است. لازم به ذکر است در این پژوهش، جهت سهولت در توضیح و ارائه نتایج دو بازه اول کانال عقیلی شرقی با پنج آبگیر و دو سازه کنترل موردبررسی قرار گرفته است. در شکل (۱) موقعیت کانال در شبکه، استان و کشور نشان داده شده است.

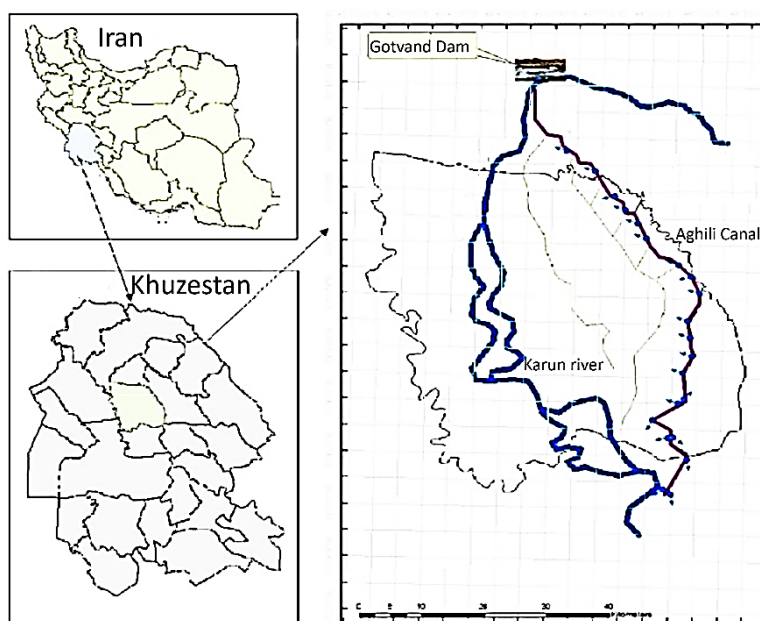


Figure 1. Location of the studied canal (Khorshidi *et al.*, 2024)

۲.۲. ماشین بردار پشتیبان

ماشین بردار پشتیبان یک الگوریتم یادگیری نظارت‌شده قدرتمند است که برای طبقه‌بندی داده‌ها و رگرسیون استفاده می‌شود. نوع طراحی شده برای رگرسیون به‌عنوان بردار پشتیبان شناخته می‌شود. در رگرسیون بردار پشتیبان، متغیر خروجی در فضایی با ابعاد بالا با کنترل مقدار انحرافات از مشاهدات واقعی در یک محدوده مشخص پیش‌بینی می‌شود. در این الگوریتم، متغیر وابسته (خروجی) y با استفاده از رابطه (۱) تخمین زده می‌شود:

$$y = f(x) + \text{noise} \quad , \quad f(x) = w^T \cdot \phi(x) + b \quad (\text{رابطه ۱})$$

که در آن x مقدار متغیرهای مستقل (ورودی)، noise مقدار نوسان که براساس مقدار خطای مجاز ε تعیین می‌شود، $f(x)$ تابعی است که باید با استفاده از داده‌های آموزشی مشخص شود، w بردار ضرایب، b مقدار ثابت پارامترهای تابع رگرسیونی و ϕ تابع هسته یا تابع کرنل می‌باشد. در هر دو نوع این الگوریتم شامل طبقه‌بندی و رگرسیون، رابطه (۲) که مقید به شرایط معادله ۳ است بهینه می‌شود.

$$\frac{1}{2} w^T \cdot w + C \sum_{i=1}^N \xi_i \quad (\text{رابطه ۲})$$

$$y_i (w^T \cdot \phi(x_i) + b_i) \geq 1 - \xi_i \quad , \quad \xi_i \geq 0, \quad i = 1, 2, \dots, M \quad (\text{رابطه ۳})$$

که در آن، C مقدار جریمه را زمانی که خطایی رخ می‌دهد نشان می‌دهد، M تعداد داده‌ها و ξ ضریب کمبود می‌باشد که برای مدیریت ورودی‌های غیرقابل تفکیک استفاده می‌شود. در شکل (۲)، معماری ماشین بردار پشتیبان ارائه شده است.




Figure 2. SVM architecture

در این الگوریتم، تابع هسته یک تابع انتقال می‌باشد که به صورت خطی، چندجمله‌ای، گوسین، سیگموئید و تابع پایه شعاعی (RBF) باشد که به صورت رابطه (۴) تعریف می‌شود (Cristianini and Shawe-Taylor, 2007):

$$K(x_i + x_j) = e^{-\gamma(x_i + x_j)^2}, \quad \gamma > 0 \quad \text{رابطه (۴)}$$

که در آن، γ پارامتر تابع کرنل است. این پارامتر، تأثیر تأثیر نمونه‌های آموزشی فردی را کنترل می‌کند و بر شکل مرز تصمیم تأثیر می‌گذارد. پارامترهای C و γ برای کنترل رفتار مدل و دستیابی به عملکرد مناسب بسیار مهم هستند که در این پژوهش با آزمون و خطا محاسبه شدند. لازم به ذکر است که C بزرگ‌تر جریمه بالاتری را بر خطاها اختصاص می‌دهد و منجر به کاهش قدرت تعمیم می‌شود. برعکس، یک C کوچک‌تر جریمه‌های کم‌تری را به همراه دارد اما توانایی تعمیم بالاتری را ارائه می‌دهد که منجر به یک مدل پیچیده‌تر می‌شود. بنابراین، مقدار آن باید به درستی تعیین شود تا بیش‌برازش یا زیربرازش بوجود نیاید.

۳.۲. شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی از ساختار و عملکرد مغز انسان الهام گرفته شده‌اند که در زمینه یادگیری ماشین و هوش مصنوعی برای تشخیص الگوها، طبقه‌بندی داده‌ها و پیش‌بینی استفاده می‌شوند. نورون‌ها واحد اصلی شبکه بوده که ورودی را دریافت و پردازش می‌کند و یک خروجی تولید می‌کند. این شبکه در چند لایه سازماندهی می‌شوند و از طریق اولین لایه، داده‌های ورودی شبکه دریافت می‌شود. بین لایه‌های ورودی و خروجی یک یا چند لایه به نام لایه‌های پنهان قرار دارند که در آن پردازش و محاسبات انجام می‌شود. هرچه تعداد لایه‌های پنهان زیاد باشد، پیچیدگی شبکه نیز زیاد خواهد شد و یادگیری عمیق خواهد بود. لایه خروجی، براساس پردازش انجام‌شده در لایه‌های قبلی خروجی شبکه را تولید می‌کند.

اتصال بین نورون‌ها دارای وزن است که قدرت و جهت تأثیر اتصال را تعیین می‌کند و بایاس‌ها به مجموع وزنی ورودی‌ها اضافه می‌شوند تا مدل بهتر با داده‌ها مطابقت داشته باشد. پس از محاسبه مجموع وزنی ورودی‌ها به علاوه

بایاس، نتیجه از طریق یک تابع فعال‌سازی که خروجی نوروں را تعیین می‌کند، منتقل می‌شود. توابع فعال‌سازی در شبکه‌های عصبی مصنوعی شامل تابع پله دودویی، تابع فعال‌سازی خطی (همانی) و تابع فعال‌سازی غیرخطی می‌باشد. توابع فعال‌سازی غیرخطی بیش‌ترین استفاده را در این شبکه دارند، زیرا تعمیم‌پذیری و تطبیق‌پذیری مدل با انواع مختلف داده با استفاده از آن‌ها بهتر صورت می‌گیرد. از جمله این توابع می‌توان به توابع سیگموئید، یکسوساز، خطی، نمایی و تانژانت هذلولوی اشاره کرد. این توابع می‌توانند به‌صورت انتشار رو به جلو (پیش‌خور)، انتشار رو به عقب (پس‌خور)، محوشدگی گرادیان انفجار گرادیان عمل کنند (Worden et al., 2023). در شکل (۳) ساختار یک شبکه عصبی مصنوعی با یک ورودی x نشان داده شده است. در طول یادگیری، با انتخاب یک تابع فعال‌سازی f ، ضریب w و بایاس b طوری انتخاب می‌شوند که خطای بین مقادیر خروجی y محاسباتی با $f(w \cdot x + b)$ با مقادیر متناظر واقعی حداقل شود.




Figure 3. ANN architecture with single input

بهبود یادگیری در طول زمان (سازگاری)، مدل‌سازی روابط پیچیده و غیرخطی بین ورودی‌ها و خروجی‌ها، تعمیم (پیش‌بینی دقیق خروجی داده‌های دیده‌نشده) از جمله مزایای شبکه‌های عصبی مصنوعی هستند. نیاز به داده‌های زیاد، تعمیم ضعیف در شبکه‌های پیچیده و هزینه محاسباتی زیاد در آموزش شبکه‌های عمیق از جمله محدودیت‌های این شبکه‌ها می‌باشد. در این پژوهش، داده‌های مربوط به سال‌های ۱۳۸۷ تا ۱۳۹۶ کانال مورد مطالعه به سه قسمت تقسیم گردید و ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد برای واسنجی و ۱۵ درصد برای اعتبارسنجی استفاده شد. دو شبکه مجزا برای یادگیری هر بازه در نظر گرفته شد. در بازه اول سه آنگیر وجود دارد که به‌عنوان ورودی به شبکه و مقادیر متناظر بازشدگی دریچه به‌عنوان خروجی به شبکه معرفی شد. در بازه دوم نیز روند مشابه بود با این تفاوت که در بازه دوم دو آنگیر وجود دارد.

۴.۲. شبیه‌ساز کانال

مدل مورد استفاده در این پژوهش، مدل AICSS است که یک مدل هیدرودینامیکی است که برای شبیه‌سازی جریان آب در کانال‌های آب طراحی شده است و به‌طور گسترده توسط مهندسان و مدیران آب استفاده می‌شود. این مدل، رفتار جریان آب را تحت شرایط مختلف مانند جریان‌های ورودی، هندسه کانال و استراتژی‌های مختلف بهره‌برداری شبیه‌سازی می‌کند. برای شبیه‌سازی جریان ماندگار و محاسبه پروفیل سطح آب، معادله جریان متغیر تدریجی و برای شبیه‌سازی جریان غیرماندگار، معادلات سنت و نانت را حل می‌کند که معادلات پیوستگی و مومنتم در آن به‌صورت روابط (۵) و (۶) تعریف می‌شوند:

$$\frac{A}{B} \frac{\partial V}{\partial x} + V \frac{\partial y}{\partial x} + \frac{\partial y}{\partial t} + \frac{V}{B} A_x^y - \frac{1}{B} (p - i) = 0 \quad \text{رابطه (۵)}$$

$$\frac{\partial V}{\partial t} + V \frac{\partial V}{\partial x} + \frac{\partial V}{\partial x} + g(s_0 - s_f) + \frac{V}{B} (p - i) = 0 \quad \text{رابطه (۶)}$$

که در آن، A سطح مقطع، B عرض سطح آب، V سرعت، x فاصله، t زمان، y عمق، p جریان‌های ورودی، i

جریان‌های خروجی، s_0 شیب کانال، s_f شیب اصطکاکی و g شتاب ثقل است. این معادلات با استفاده از روش تفاضل‌های محدود براساس سیستم چهار نقطه‌ای وزنی پرایزمن که از دقت، همگرایی، پایداری و صحت بالایی برخوردار است، حل شده‌اند. این مدل با گرفتن ورودی‌ها از کاربر در قالب یک فایل متنی، به‌صورت خودکار تمام محاسبات را انجام داده و خروجی‌های موردنظر کاربر را در فایل‌های متنی ذخیره می‌کند (Shahverdi, 2023).

شبیه‌سازی کانال‌ها یا مقاطع هندسی منظم و نامنظم، شبیه‌سازی طیف وسیعی از سازه‌های آبی و شرایط مرزی، کاربرد مدل برای انواع شبکه‌های آبیاری یا انواع روش‌های بهره‌برداری، شبیه‌سازی انواع جریان‌ات ورودی یا خروجی کنترل‌شده یا نشده به سیستم، دقت هماهنگی محاسبات بین زیر مجموعه‌های مختلف هیدرولیکی، هیدرولوژیکی و عملیات بهره‌برداری، تنظیم اطلاعات ورودی و خروجی در شکل‌هایی مناسب و قابل قبول برای استفاده‌کننده، ایجاد حداکثر امکان برای به‌کارگیری نرم‌افزارهای کمکی موجود، امکان توسعه مدل و افزایش زیرمجموعه‌های جدید با حداقل نیازهای برنامه‌نویسی، امکان ذخیره اطلاعات در هر مرحله از شبیه‌سازی و بازخوانی مجدد آن در هر زمان دیگر و ادامه شبیه‌سازی قبلی از جمله قابلیت‌های این مدل می‌باشد. همچنین، شرایط مرزی و سازه‌های متنوعی در آن قابل تعریف و شبیه‌سازی است که برخی از آن‌ها عبارتند از دریچه‌های کشویی مستطیلی کنترل جریان با بهره‌برداری دستی تحت شرایط آزاد، مستغرق و یا متناوب؛ دریچه‌های آبیگر روزنه‌ای مستطیلی با بهره‌برداری دستی یا اتوماتیک؛ سرریزهای جانبی همراه یا بدون سیستم‌های کنترل؛ جریان‌ات ورودی به‌صورت هیدروگراف؛ مخازن کنترل و تنظیم جریان؛ پمپ‌هایی که به‌عنوان آبیگر استفاده می‌شوند با بهره‌برداری دستی یا خودکار؛ انواع پل‌ها و کالورت‌ها؛ دریچه‌های نیربیک؛ آب بندهای آمیل، آویس و آویو.

۲.۵. سناریوها و سنج‌های بررسی عملکرد مدل‌های هوشمند

ورودی به روش‌های هوشمند مورداستفاده در این پژوهش، دبی آبیگرها و خروجی آن‌ها، مقادیر بازشدگی آبیگرها بود. همانطور که اشاره شد بازه‌های اول و دوم کانال عقیلی شرقی در این پژوهش موردبررسی قرار گرفتند. تغییرات دبی در ورودی کانال و دبی آبیگرها در جدول (۱) ارائه شده است. لازم به ذکر است که در عمده موارد مقادیر دبی تحویلی در بین مقادیر مدرج در جدول است. به‌دلیل سهولت انجام و افزایش دقت یادگیری، در این پژوهش یادگیری ماشین با استفاده از ماشین بردار پشتیبان و شبکه عصبی مصنوعی، برای بازه‌های اول و دوم جداگانه انجام پذیرفت. در بازه اول مقادیر دبی آبیگرهای ۱-۳ (d1-d3) به‌عنوان ورودی به مدل هوشمند و مقادیر بازشدگی متناظر آن‌ها به‌عنوان خروجی به مدل هوشمند در نظر گرفته شد. در بازه دوم، مقادیر دبی آبیگرهای ۴ و ۵ (d4-d5) به‌عنوان ورودی به مدل هوشمند و مقادیر بازشدگی متناظر آن‌ها به‌عنوان خروجی به مدل هوشمند در نظر گرفته شد.

Table 1. Minimum, mean, and maximum inflow and flow demand variations used in this research (l/s)

	Inflow	Pool 1			Pool 2	
		d1	d2	d3	d4	d5
Minimum	1310	69	78	57	56	57
Mean	1491	85	91	78	83	82
Maximum	1650	101	107	104	105	107

پس از انجام یادگیری جهت بررسی نتایج، مقادیر بازشدگی استخراج‌شده با استفاده از خروجی‌های روش‌های هوشمند به مدل شبیه‌ساز وارد شد و کانال شبیه‌سازی گردید. با استفاده از خروجی‌های شبیه‌ساز مانند دبی تحویل‌شده، مقادیر سنج‌های ارزیابی محاسبه گردید. برای ارزیابی عملکرد مدل‌ها، از سنج‌های کیفیت (MPA)، راندمان (MPF)، عدالت (MPE) و پایداری (MPD) استفاده شد که به‌ترتیب در روابط (۷) تا (۱۰) تعریف شده‌اند (Molden and Gates, 1990):

$$MPA = \frac{1}{N} \sum_N \frac{1}{M} \sum_M (PA), \begin{cases} PA = \frac{Q_D}{Q_R} & \text{IF } Q_R > Q_D \\ PA = 1 & \text{IF } 1 < \frac{Q_D}{Q_R} \end{cases} \quad \text{رابطه ۷}$$

$$MPF = \frac{1}{N} \sum_N \frac{1}{M} \sum_M (PE), \begin{cases} PE = \frac{Q_R}{Q_D} & \text{IF } Q_R < Q_D \\ PE = 1 & \text{IF } \frac{Q_R}{Q_D} > 1 \end{cases} \quad \text{رابطه ۸}$$

$$MPD = \frac{1}{R} \sum_R CV_T \left(\frac{Q_D}{Q_R} \right) \quad \text{رابطه ۹}$$

$$MPE = \frac{1}{T} \sum_T CV_R \left(\frac{Q_D}{Q_R} \right) \quad \text{رابطه ۱۰}$$

که در آن، M تعداد آبیگرها، Q_R دبی موردنیاز یا دبی درخواست‌شده در آبیگر M ، Q_D دبی واقعی تحویل شده به آبیگر M و N تعداد گام‌های زمانی مناسب در یک دوره تحویل، R تعداد آبیگرها، T تعداد گام‌های زمانی و CV ضریب تغییرات می‌باشد. بهترین مقدار برای سنج‌های کفایت و راندمان برابر با یک و برای سنج‌های عدالت و پایداری برابر با صفر است. به‌منظور بررسی صحت نتایج خروجی مدل‌های هوشمند ماشین بردار پشتیبان و شبکه عصبی مصنوعی، از سنج آماری ریشه میانگین مربعات خطای نرمال‌شده (NRMSE: *normalized root mean square error*) مقادیر محاسباتی و مشاهداتی استفاده شد (رابطه ۱۱).

$$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^N (Q_{Dp} - Q_{Dm})^2}{N}}}{Q_{Dm\max} - Q_{Dm\min}} \quad \text{رابطه ۱۱}$$

در روابط بالا، پارامتر Q_{Dm} مقادیر مشاهداتی و پارامتر Q_{Dp} مقادیر محاسباتی، $Q_{Dm\max}$ و $Q_{Dm\min}$ به‌ترتیب مقادیر حداکثر و حداقل داده‌های مشاهداتی است. هرچه مقدار آن به صفر نزدیک‌تر باشد نشان‌دهنده خطای کم‌تر و مقبولیت بیش‌تر مدل می‌باشد.

۳. نتایج و بحث

در این پژوهش، ماشین بردار پشتیبان برای مدیریت بهره‌برداری کانال عقیلی شرقی مورد استفاده قرار گرفت و با نتایج روش شبکه عصبی مصنوعی مقایسه شد. دبی و بازشدگی آبیگرها به‌ترتیب به‌عنوان ورودی و خروجی به مدل معرفی شد. نتایج با استفاده از شاخص‌های ارزیابی عملکرد کانال‌ها مورد ارزیابی قرار گرفت. تجزیه تحلیل مقادیر دبی تحویلی به آبیگرها نشان داد که حداکثر و حداکثر دبی عبوری از آبیگرها به‌ترتیب برابر با ۵۶ و ۱۰۵ لیتر بر ثانیه است که برای تحویل آن باید دبی ورودی بین ۱۳۱۰ و ۱۶۵۰ لیتر بر ثانیه وارد کانال شود. میانگین مقادیر بازشدگی آبیگرها برای آبیگرهای یک تا پنج به‌ترتیب برابر با ۱۵/۲، ۱۲/۰، ۸/۷، ۱۱/۳، و ۸/۷ سانتی‌متر می‌باشد.

مقدار پارامتر تابع کرنل، ۷، برابر با ۷/۱۲ با آزمون و خطا به‌دست آمد. مقدار NRMSE برای آبیگرهای ۱-۵ بین داده‌های محاسباتی و مشاهداتی به‌ترتیب برابر با ۱۲/۵، ۳/۸، ۱/۰، ۲/۳ و ۱/۳ به‌دست آمد که بیانگر دقت مناسب ماشین بردار پشتیبان در ارائه الگوهای مناسب بهره‌برداری می‌باشد. همانطور که مشاهده می‌شود مقادیر NRMSE برای آبیگرهای ۳ و ۵ کم‌تر می‌باشد. دلیل این امر، نزدیکی این آبیگرها به آب‌بندهاست در نتیجه کنترل بیش‌تری روی آن‌ها وجود دارد. لازم به ذکر است که مقدار NRMSE برای آبیگرهای ۳ تا ۵ بین داده‌های محاسباتی و مشاهداتی با استفاده

از شبکه عصبی مصنوعی به ترتیب برابر با $1/1$ ، $1/9$ ، $1/70$ ، $1/5$ و $1/8$ به دست آمد که قابل قبول می‌باشند. در شکل (۴)، داده‌های واقعی و پیش‌بینی شده برای پارامتر اول، به عنوان نمونه، با استفاده از ماشین بردار پشتیبان ارائه شده است. مقدار حداکثر خطای نسبی در حدود ۵۰ درصد داده‌ها کم‌تر از پنج درصد، حدود ۸۲ درصد داده‌ها کم‌تر از ۱۰ درصد و در ۹۹ درصد داده‌ها کم‌تر از ۲۰ درصد است. ماشین بردار پشتیبان در مورد حدود ۸ درصد داده‌ها، پیش‌بینی دقیق، در مورد حدود ۳۳ درصد نمونه‌ها، بیش‌برازش و در سایر موارد زیربرازش داشته است.

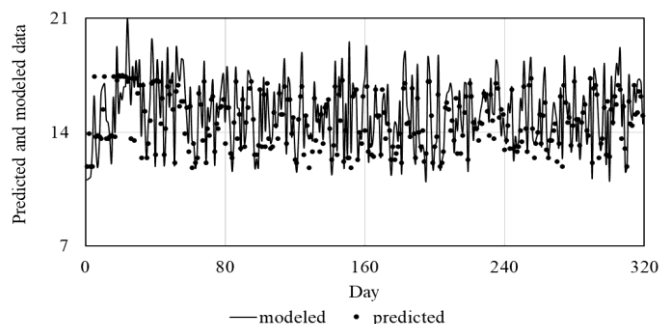
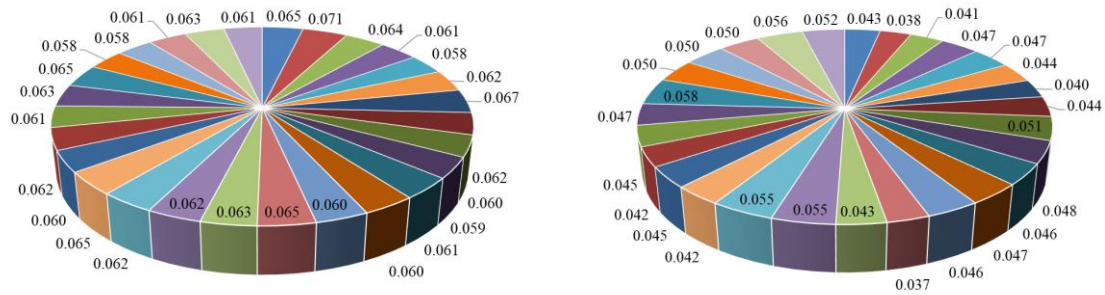


Figure 4. Comparing predicted and modeled data for the first parameter using SVM


در شکل‌های (۵) و (۶)، مقادیر سنجه‌های ارزیابی شامل عدالت، پایداری، راندمان و کفایت برای مقادیر پیش‌بینی شده با استفاده از ماشین بردار پشتیبان ارائه شده است. لازم به ذکر است که سنجه‌های فوق دارای سه کلاس خوب، مناسب و ضعیف هستند که به صورت زیر تعریف می‌شوند (Molden and Gates, 1990):

کلاس خوب: عدالت کوچک‌تر از $0/1$ ، پایداری کوچک‌تر از $0/1$ ، راندمان بزرگ‌تر از $0/85$ و کفایت بزرگ‌تر از $0/9$ ، کلاس مناسب: عدالت بین $0/11$ – $0/25$ ، پایداری بین $0/11$ – $0/2$ ، راندمان بین $0/7$ – $0/85$ و کفایت بین $0/8$ – $0/89$ ، کلاس ضعیف: عدالت بزرگ‌تر از $0/25$ ، پایداری بزرگ‌تر از $0/2$ ، راندمان کوچک‌تر از $0/7$ و کفایت کوچک‌تر از $0/8$. همانطور که از شکل‌های (۵) و (۶) مشخص است مقدار سنجه عدالت حاصل شده در تمام پیش‌بینی‌ها با استفاده از ماشین بردار پشتیبان بین $0/058$ و $0/071$ است که در همگی در کلاس خوب قرار می‌گیرند که بیانگر عدالت در تحویل آب در تمام پیش‌بینی‌هاست. لازم به ذکر است که عدالت تحویل در بین تمام آبیگرهای کانال محاسبه می‌شود و اگر بهره‌برداری درست صورت نگیرد معمولاً آبیگرهای ابتدایی کانال، آب بیش‌تری دریافت می‌کنند و آبیگرهای انتهایی آب کم‌تری دریافت می‌کنند که در نتیجه توزیع آب عادلانه نخواهد بود. مقدار سنجه پایداری حاصل شده در تمام پیش‌بینی‌ها با استفاده از ماشین بردار پشتیبان بین $0/037$ و $0/058$ است که همگی کم‌تر از $0/11$ بوده و در کلاس خوب قرار دارند. مقدار نزدیک به صفر این سنجه نشان می‌دهد قابلیت اطمینان در تحویل و توزیع آب وجود دارد و می‌توان اطمینان حاصل کرد که مصرف‌کنندگان، آب موردنیاز خود را در زمانی که نیاز دارند، به صورت پایدار از لحاظ حجم و دبی آب دسترسی دارند.

روند مشابه با سنجه‌های عدالت و پایداری، در مورد سنجه‌های راندمان و کفایت در سطح کانال نیز وجود دارد، به طوری که مقادیر راندمان $0/967$ تا یک و مقادیر کفایت بین $0/9$ تا یک قرار دارند که از نظر کلاس‌بندی هر دو در کلاس خوب قرار دارند، زیرا به ترتیب بزرگ‌تر از $0/85$ و $0/9$ (یا مساوی) می‌باشند. در نتیجه، در تحویل آب به تمامی آبیگرها هیچ گونه مازاد یا کمبودی وجود ندارد. ذکر این نکته ضروری است که در برخی موارد سنجه کفایت در مرز بین کلاس خوب و مناسب، یعنی $0/9$ ، قرار دارد. با توجه به این که سنجه‌های کفایت و راندمان برای هر آبیگر نیز قابل محاسبه است، بررسی این سنجه‌ها برای هر آبیگر نتایج مشابه با نتایج در سطح کانال دارد و در کلاس خوب قرار دارد.



MPE MPD
Figure 5. Performance metrics (MPE and MPD) obtained using SVM



MPA MPF
Figure 6. Performance metrics (MPA and MPF) obtained using SVM

در شکل (۷)، داده‌های واقعی و پیش‌بینی‌شده برای پارامتر اول، به‌عنوان نمونه، با استفاده از شبکه عصبی مصنوعی ارائه شده است. مقدار خطای نسبی بین پنج تا ۱۰ درصد است که در مقایسه با ماشین بردار پشتیبان که در ۵۰ درصد داده‌ها کمتر از پنج درصد بود، در شبکه عصبی مصنوعی مقادیر خطا بیش‌تر از پنج درصد است. در نتیجه، مقادیر خطاها در روش شبکه عصبی نوسان زیادی ندارند. با این‌حال، همان‌طور که در شکل نیز قابل مشاهده است در مورد تمام نمونه‌ها بیش‌برازش داشته است. در شکل‌های (۸) و (۹)، مقادیر سنج‌های ارزیابی شامل عدالت، پایداری، راندمان و کفایت برای مقادیر پیش‌بینی‌شده با استفاده از شبکه عصبی مصنوعی ارائه شده است.

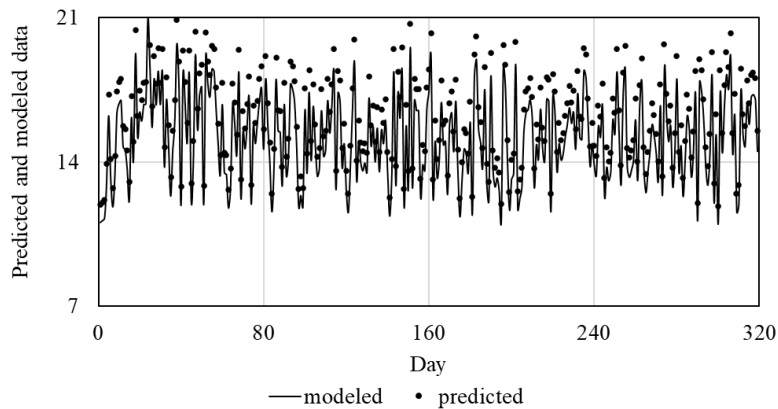


Figure 7. Comparing predicted and modeled data for the first parameter using ANN




Figure 8. Performance metrics (MPE and MPD) obtained using ANN




Figure 9. Performance metrics (MPA and MPF) obtained using ANN

نتایج این شبکه عصبی مصنوعی، مشابه با نتایج ماشین بردار پشتیبان است، به طوری که مقدار عدالت بین $0/013$ تا $0/066$ ، مقدار پایداری بین $0/045$ تا $0/146$ ، مقدار راندمان بین $0/943$ تا یک و مقدار کفایت بین $0/918$ تا $0/99$ قرار دارد. دو نکته در مقایسه نتایج شبکه عصبی مصنوعی با ماشین بردار پشتیبان وجود دارد؛ اول این که کفایت تحویل آب، حداکثر مقدار $0/99$ است و به یک نرسیده است و دوم این که پایداری در تحویل آب در حدود 30 درصد نمونه در کلاس مناسب قرار دارد بدین معنی که قابلیت اطمینان در تحویل حجم و دبی آب در روش شبکه عصبی مصنوعی نسبت به ماشین بردار پشتیبان کم تر است. همچنین، ماشین بردار پشتیبان در مورد حدود 8 درصد داده‌ها، پیش‌بینی دقیق، در مورد 33 درصد نمونه‌ها، بیش‌برازش و در سایر موارد زیربرازش داشته است. این در حالی است که مقادیر خطاها در روش شبکه عصبی مصنوعی نوسان زیادی ندارند و در مورد تمام نمونه‌ها بیش‌برازش وجود دارد.

۴. نتیجه‌گیری

در این پژوهش، دو روش هوشمند یادگیری بانظارت شامل ماشین بردار پشتیبان (با تابع کرنل پایه شعاعی) و شبکه‌های عصبی مصنوعی برای مدیریت بهره‌برداری از کانال عقیلی شرقی مورد استفاده قرار گرفت. برای آموزش و انجام یادگیری، داده‌های از سال 1387 تا 1396 کانال مذکور از دفتر شبکه آبیاری عقیلی جمع‌آوری شد و دبی آگیرها به‌عنوان ورودی و بازشدگی آن‌ها به‌عنوان خروجی به مدل‌های هوشمند معرفی شد. جهت شبیه‌سازی کانال، از مدل هیدرودینامیک AICSS، که با استفاده از معادلات سنت و نانت جریان غیرماندگار متغیر تدریجی را حل می‌کند، استفاده شد و پارامترهای جریان محاسبه شد. با استفاده از مقادیر دبی جریان، سنج‌های عدالت، پایداری، راندمان و کفایت تحویل محاسبه شد و تجزیه و تحلیل شد.

مقدار پارامتر تابع کرنل برابر با $7/12$ و مقدار NRMSE بین مقادیر محاسباتی و مشاهداتی بین $1/0$ تا $12/5$ درصد با ماشین بردار پشتیبان به دست آمد که نشانگر دقت قابل قبول مدل است، به طوری که در 82 درصد نمونه‌ها، خطای نسبی کم‌تر از 10 درصد است. در شبکه عصبی مصنوعی مقدار NRMSE بین مقادیر محاسباتی و مشاهداتی بین $1/5$ تا $10/1$ درصد به دست آمد و در تمام نمونه‌ها بیش‌برازش داشته است. بررسی سنجه‌های ارزیابی عدالت، پایداری، راندمان و کفایت نشان داد که در ماشین بردار پشتیبان، تمام سنجه‌ها در کلاس خوب قرار دارند و به ترتیب مقادیر آن‌ها کوچک‌تر از $0/1$ ، $0/1$ و بزرگ‌تر از $0/85$ و $0/9$ می‌باشد؛ در نتیجه، تحویل آب به تمام آبیگرها به صورت عادلانه و با اطمینان، راندمان و کفایت بالا صورت گرفته است. در مورد روش شبکه عصبی مصنوعی، نتایج مشابه می‌باشد با این تفاوت که کفایت تحویل آب در کلاس مناسب قرار دارد و در برخی پیش‌بینی‌ها، کمبود آب در تحویل وجود دارد. به‌طور کلی می‌توان نتیجه گرفت که کاربرد روش‌های هوشمند بانظارت برای مدیریت بهره‌برداری کانال‌ها موفقیت‌آمیز می‌باشد و روش ماشین بردار پشتیبان نسبت به روش شبکه عصبی مصنوعی برتری نسبی دارد.

۵. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۶. منابع

- Benftima, S., Gharab, S., Rivas-Pérez, R., & Feliu-Battle, V. (2024). Modeling of an Irrigation Main Canal Pool based on a NARX-ANN System Identification. *Communications in Nonlinear Science and Numerical Simulation*, 132, 107929.
- Cristianini, N., & Shawe-Taylor, J. (2007). Support vector and kernel methods. *Intelligent Data Analysis: An Introduction*, Springer, 169-197.
- Hadiseraji, G., Monem, M. J., & Savari, H. (2022). Evaluation of Operational Flexibility for on Request Delivery Method from Hydraulic Point of view in Irrigation Networks. *Iranian Journal of Irrigation & Drainage*, 16(4), 685-696.
- Kaushik, V., & Kumar, M. (2023). Water surface profile prediction in non-prismatic compound channel using support vector machine (SVM). *AI in Civil Engineering*, 2(1), 6.
- Khorshidi, A., Monem, M. J., & Mazaheri, M. (2024). Investigation of the effect of operational errors on the performance uncertainty of irrigation networks in arranged delivery. *Iranian Journal of Soil and Water Research*, 55(2), 179-195. (In persian)
- Molden, D. J., & Gates, T. K. (1990). Performance measures for evaluation of irrigation-water-delivery systems. *Journal of Irrigation and Drainage Engineering*, 116(6), 804-823.
- Savari, H., & Monem, M. J. (2022). Optimal operational instructions for on-request delivery using hybrid genetic algorithm and artificial neural network, considering unsteady flow. *Irrigation and Drainage*, 71(3), 735-748.
- Shahverdi, K. (2023). AICSS: Automatic simulator-controller/optimizer model of open channels. *Irrigation and Drainage*, 72(4), 1124-1136.
- Shahverdi, K., & Maestre, J. (2022). Gray Wolf Optimization for Scheduling Irrigation Water. *Journal of Irrigation and Drainage Engineering*, 148(7), 04022020.
- Shahverdi, K., Mollazeinyali, H., & Marofi, M. (2023). Design of Operation Strategy for Canal Structures. *Journal of Hydraulics*, 18(4).
- Shahverdi, K., & Monem, M. J. (2015). Application of reinforcement learning algorithm for automation of canal structures. *Irrigation and drainage*, 64(1), 77-84.
- Sharifi, H., Roozbahani, A., & Shahdany, S. M. H. (2021). Evaluating the Performance of Agricultural Water Distribution Systems Using FIS, ANN and ANFIS Intelligent Models. *Water Resources Management*, 1-20.

- Worden, K., Tsialiamanis, G., Cross, E., & Rogers, T. (2023). Artificial neural networks. *Machine Learning in Modeling and Simulation: Methods and Applications*, Springer, 85-119.
- Zamani, S., Parvaresh Rizi, A., Kouchakzadeh, S., & Sajedi, H. (2024). Evaluation of Machine-Learning Approaches in the Automation of Irrigation Canals Using a Variable-Height Weir. *Journal of Irrigation and Drainage Engineering*, 150(6), 04024030.