

## مقایسه عملکرد مدل‌های خطی و غیرخطی هیدرولیک کانال در چارچوب یادگیری تقویتی گسسته

### چکیده

مدیریت و کنترل کانال‌های انتقال و توزیع آب به دلیل رفتار غیرخطی جریان، تأخیر زمانی و برداشت‌های متغیر از مسائل چالش‌برانگیز مهندسی آب است. در سال‌های اخیر، یادگیری تقویتی به‌عنوان روشی نوین در این سامانه‌ها استفاده شده است، اما تأثیر نوع مدل هیدرولیکی بر یادگیری به‌صورت کمی بررسی نشده است. هدف این پژوهش، مقایسه عملکرد یادگیری تقویتی گسسته در تلفیق با دو محیط شبیه‌سازی شامل مدل غیرخطی مبتنی بر معادلات کامل سنت‌ونانت و مدل خطی یک کانال است. عامل یادگیرنده به‌طور مستقل با هر یک از دو مدل آموزش داده شد و عملکرد سیاست‌های کنترلی حاصل بر اساس خطاهای تحویل آب و شاخص‌های راندمان و کفایت ارزیابی گردید. نتایج نشان داد مدل غیرخطی در بازه‌های پایین‌دست با حداقل مقادیر شاخص‌های راندمان و کفایت به‌ترتیب ۰/۹۶۲ و ۰/۹۷۲، خطاهای کمتری از مدل خطی با حداقل راندمان برابر با ۰/۴۹۷ در بازه‌های انتهایی و حداکثر خطای مطلق ۵۹ درصد دارد. مدل خطی به دلیل سادگی، همگرایی سریع‌تری در فرآیند یادگیری دارد و در محدوده خطی‌سازی (±۲۰ درصد تغییرات دبی) عملکرد قابل قبولی ارائه می‌دهد، اما در خارج از محدوده خطی‌سازی، سیاست‌های کنترلی ضعیف‌تر یادگیری می‌شود و منجر به کاهش کیفیت توزیع آب، به‌ویژه در پایین‌دست، می‌شود.

**کلمات کلیدی:** کنترل هوشمند، شاخص‌های عملکرد، مدل خطی، مدل غیرخطی.

## Comparison of Linear and Nonlinear Hydraulic Canal Model Performance within a Discrete Reinforcement Learning Framework

### Abstract

Water management and control in irrigation canals are challenging due to the nonlinear behavior of open-channel flow, time delays, and variable water withdrawals. In recent years, reinforcement learning has emerged as a promising approach for controlling such systems; however, the influence of the underlying hydraulic model on the quality of the learning process has not yet been quantitatively investigated. This study compares the performance of a discrete reinforcement learning algorithm integrated with two simulation environments: a nonlinear hydraulic model based on the full Saint-Venant equations and a linearized hydraulic model of an irrigation canal. The learning agent was trained independently using each model, and the resulting control policies were evaluated based on water delivery errors as well as the efficiency and adequacy performance indicators. The results show that the nonlinear model achieved substantially smaller delivery errors than the linear model in the downstream reaches, with minimum efficiency and adequacy values of 0.962 and 0.972, respectively. In contrast, the minimum efficiency of the linear model decreased to 0.497 in the terminal reaches, while the maximum absolute delivery error reached 59%. Although the linear model exhibited faster convergence during training and provided acceptable performance within the linearization range ( $\pm 20\%$  discharge variation), it learned weaker control policies outside this range, resulting in degraded water distribution performance, particularly in the downstream reaches.

**Keywords:** Intelligent Control, Linear Model, Nonlinear Model, Performance Indices.

### مقدمه

مدیریت پایدار منابع آب، به عنوان یکی از چالش‌های بنیادین در حوزه مسائل آبی شناخته می‌شود. کانال‌های انتقال و توزیع آب که نقش شریان‌های اصلی را در رساندن آب از مبدأ تأمین به مزارع بر عهده دارند، برای تأمین امنیت غذایی و معیشت جوامع روستایی حیاتی هستند. با وجود این، بهره‌برداری نامناسب از این کانال‌ها نه تنها به هدررفت آب می‌انجامد، بلکه سبب توزیع نامتوازن جریان میان آبگیرها و عدم تحویل به موقع آب به بخش‌های انتهایی یا پایین‌دست شبکه می‌شود. پیچیدگی ذاتی سیستم‌های هیدرولیکی حاکم بر کانال‌ها - که شامل رفتار غیرخطی، تأخیر زمانی قابل‌ملاحظه بین اعمال فرمان کنترلی و ظهور پاسخ هیدرولیکی در آبگیرها و اغتشاشات ناشی از برداشت‌های متغیر و ناگهانی از سوی کشاورزان - از مهم‌ترین چالش‌ها در این حوزه به شمار می‌روند. به همین دلیل، این مسائل نیازمند پژوهش‌های جدی هستند که عمدتاً

مبتنی بر مدل‌های شبیه‌سازی توسعه‌یافته بر پایه معادلات سنت-ونانت می‌باشند (Conde et al. 2021). مدل‌های موجود دقیق که برای شبیه‌سازی کانال‌ها توسعه یافته‌اند، مدل‌های غیرخطی مبتنی بر معادلات سنت-ونانت هستند و بر اساس روشی فیزیکی و مبتنی بر موازنه جرم و انرژی، مدل‌سازی و شبیه‌سازی پدیده‌های مهم هیدرولیکی را انجام می‌دهند (Arango et al. 2025).

به عنوان یکی از مدل‌های پرکاربرد غیرخطی در شبیه‌سازی کانال‌های انتقال و توزیع آب، از HEC-RAS در تحقیقات مختلفی استفاده شده است (Deshays et al. 2021; Sharifi et al. 2021). به عنوان نمونه، این مدل برای شبیه‌سازی کانال‌های شبکه لیه (Layyah) و ارزیابی عملکرد هیدرولیکی شاخه موندنا کانال مذکور استفاده شد. نتایج شبیه‌سازی نشان داد مدل می‌تواند دبی جریان عبوری از خروجی‌های جانبی و انهار فرعی را با دقت معقول محاسبه کند، به‌طوری‌که مقدار ضریب تعیین برای ترازهای آب برابر با  $0/945$  و برای دبی‌ها برابر با  $0/997$  حاصل شد. در مرحله اعتبارسنجی مدل نیز، مقادیر ضریب تعیین به ترتیب برابر با  $0/911$  و  $0/988$  برای ترازهای آب و دبی‌ها به دست آمد (Ijaz et al. 2025).

در پژوهشی دیگر، برای پیش‌بینی تغییرات سطح آب در کانال‌ها، یک مدل عددی غیرخطی توسعه داده شد و به جای مدل متداول تأخیری-انتگرالی، به عنوان مدل داخلی در کنترل‌کننده پیش‌بین مورد استفاده قرار گرفت. در این مدل، داده‌های اندازه‌گیری شده با فیلتر کالمن تلفیق شدند تا دقت نتایج عددی افزایش یابد. این ترکیب، با ارائه تخمین‌هایی از تغییرات احتمالی در میزان تقاضای آب، دقت پیش‌بینی را به شکل محسوسی بهبود می‌بخشد. برای ارزیابی رویکرد پیشنهادی، از کانال آزمایشی شماره ۲ که توسط انجمن مهندسان عمران آمریکا معرفی شده، استفاده گردید. نتایج نشان می‌دهد که در شرایطی که تغییرات نسبی زیاد در جریان تقاضای آب رخ می‌دهد، روش پیشنهادی در مقایسه با رویکرد مبتنی بر مدل تأخیر-انتگرال گیر، کاهش چشمگیری در شاخص‌های عملکردی به همراه دارد. به گونه‌ای که برای اغتشاشات قابل‌پیش‌بینی، حرکت مطلق تجمعی در پیچه حدود ۹۹ درصد و تعداد دفعات کنترل در پیچه حدود ۷۷ درصد کاهش می‌یابد؛ و برای اغتشاشات غیرقابل‌پیش‌بینی نیز این مقادیر به ترتیب به حدود ۳۴ درصد کاهش در حرکت مطلق تجمعی و ۳۶ درصد کاهش در تعداد دفعات کنترل در پیچه می‌رسد (Kong et al. 2024).

چالش‌های اصلی مدیریت کانال‌های آبیاری، از جمله پیچیدگی‌های هیدرولیکی ناشی از رفتار غیرخطی سیستم، تأخیر زمانی در واکنش‌دهی، اغتشاشات ناشی از برداشت‌های ناگهانی آب توسط کشاورزان، و همچنین عدم قطعیت در پارامترها و میزان تقاضا، موجب شده است که توسعه سیستم‌های هوشمند در این حوزه به شدت مورد توجه قرار گیرد. چنین سیستم‌هایی باید توانایی یادگیری از طریق تعامل مداوم با محیط و انطباق‌پذیری با شرایط پویا و غیرقابل‌پیش‌بینی را داشته باشند تا بتوانند به‌طور مؤثر با این چالش‌ها مقابله کنند (Fateme et al. 2020). شبیه‌سازی دقیق و سریع کانال‌های انتقال و توزیع آب، تأثیر بسیاری در سرعت یادگیری سیستم‌های هوشمند دارد؛ چراکه این سیستم‌ها معمولاً بر پایه تکرارهای فراوان و تعامل پیوسته با محیط عمل می‌کنند. هرچه شبیه‌سازی با دقت بیشتری انجام شود و زمان کمتری برای هر اجرا صرف گردد، فرایند یادگیری سریع‌تر و کارآمدتر خواهد بود و سیستم هوشمند می‌تواند زودتر به عملکرد مطلوب در مواجهه با شرایط مختلف دست یابد (Shahverdi et al. 2020). برای افزایش سرعت یادگیری در سیستم‌های هوشمند، می‌توان از مدل‌های خطی و ساده‌شده استفاده کرد، زیرا این مدل‌ها ساختاری ساده دارند و به خوبی با سازوکارهای بازخورد تطابق می‌یابند. با این حال، کارایی این رویکرد هنگامی با محدودیت مواجه می‌شود که تغییرات عمده و پویا در میزان تقاضای آب در پایین دست رخ دهد. در ادامه، به برخی از پژوهش‌های انجام شده در زمینه به کارگیری مدل‌های خطی اشاره می‌شود.

برای ارزیابی عملکرد سامانه توزیع آب در شرایط مختلف کمبود آب، چارچوبی فنی ارائه شد که در آن، با بهره‌گیری از تکنیک‌های تصمیم‌گیری چندمعیاره، شاخص‌های مختلف در قالب یک شاخص ارزیابی جامع ادغام گردیدند. این روش در منطقه آبیاری نکوآباد در اصفهان پیاده‌سازی شد و با استفاده از داده‌های میدانی، فرآیند واسنجی و اعتبارسنجی بر روی آن انجام گرفت. برای شبیه‌سازی کانال مورد مطالعه، از یک مدل خطی استفاده شد. نتایج نشان داد که در بخش‌های پایین دست کانال، میزان کفایت کاهش می‌یابد، در حالی که قابلیت اطمینان افزایش پیدا می‌کند. به گونه‌ای که با تشدید کمبود آب از حالت عادی تا شدید، شاخص کفایت از حدود ۹۵ درصد به ۳۳ درصد تنزل می‌یابد، در حالی که قابلیت اطمینان در دامنه‌ای بین ۵۶ تا ۹۰ درصد قرار می‌گیرد (Rahparast and Hashemy Shahdany 2024).

در پژوهشی، مدل‌سازی و شبیه‌سازی کانال‌ها بر اساس یک مدل خطی بهبودیافته، انجام شد که در آن، با در نظر گرفتن اثر ارتباط بین دو بازه مجاور، معادلات دینامیکی هر بازه نسبت به مدل تأخیری-انتگرالی اصلاح گردید. پارامترهای زمان تأخیر و سطح ذخیره این مدل خطی، با استفاده از روش حداقل مربعات و به صورت جداگانه برای دو سناریوی جریان زیاد و جریان کم شناسایی شدند. نتایج عددی نشان داد که مدل خطی بهبودیافته، در مقایسه با مدل تأخیری-انتگرالی، به کاهش قابل توجهی در خطاها دست می‌یابد: خطای مطلق حداکثر بین ۱۶ تا ۸۶ درصد و ریشه میانگین مربعات خطا بین ۱۶ تا ۸۹ درصد کاهش می‌یابد. در سناریوی جریان کم، این مدل به ترتیب میانگین خطای مطلق و ریشه میانگین

مربعات خطا را ۶۷ تا ۸۶ درصد و ۵۵ تا ۸۵ درصد بهبود می‌بخشد، در حالی که در سناریوی جریان زیاد، این مقادیر به ترتیب ۳۶ تا ۷۱ درصد و ۲۱ تا ۵۳ درصد است. همچنین، شاخص نش-ساتکلیف تا ۴۱ درصد و شاخص کارایی کلینگ-گوپتا تا ۶۵ درصد افزایش نشان می‌دهد (Li et al. 2025).

یکی دیگر از مدل‌های پرکاربرد غیرخطی در شبیه‌سازی کانال‌های انتقال و توزیع آب، مدل AICSS است که در تحقیقات مختلفی استفاده شده است (Shahverdi 2023; Shahverdi and Maestre 2022; Shahverdi et al. 2020). به عنوان نمونه، در تحقیقی، یک مدل متشکل از سه ماژول اصلی فازی، یادگیر و شبیه‌ساز غیرخطی AICSS برای استخراج دستورالعمل‌های بهره‌برداری در کانال‌ها توسعه یافت. ارزیابی مدل حاکی از عملکرد مناسب بود و شاخص کارایی برابر با ۰/۹۴۳ و شاخص کفایت برابر با ۰/۹۲۲ به دست آمد (Shahverdi et al. 2026). مسیر تکوینی این پژوهش‌ها را می‌توان به صورت زنجیره‌ای از گام‌های مکمل ترسیم کرد: ۱- نخست، تلفیق و ارزیابی روش یادگیری تقویتی با مدل غیرخطی کانال انجام شد که توانمندی مدل‌های غیرخطی را در فرآیند یادگیری آشکار ساخت؛ ۲- در گام بعدی، ترکیب الگوریتم Double Q-PI با مدل خطی در بازه اعتبار ۲۰ درصد حول نقطه هدف مورد آزمون قرار گرفت. اگرچه این ترکیب در محدوده یادشده عملکرد قابل‌قبولی داشت، اما به وضوح مشاهده شد که با خروج از این بازه، همگرایی و پایداری یادگیری به شدت کاهش می‌یابد؛ ۳- هم‌زمان، مدل تحلیلی AICSS توسعه یافت که با ساختار غیرخطی خود، توانست رفتار دقیق‌تری را در شرایط هیدرولیکی متغیر ارائه دهد؛ ۴- در نهایت، روشی فراگیر برای اجرای یادگیری در شبکه‌های بزرگ کانال فرموله شد که امکان تلفیق انعطاف‌پذیر شبیه‌ساز خطی یا غیرخطی را با الگوریتم یادگیری فراهم می‌آورد. جمع‌بندی نتایج این پژوهش‌ها، به‌ویژه ضعف مستندشده مدل خطی در خارج از بازه اعتبار، نویسندگان را به طرح پرسشی بنیادین رهنمون ساخت که نوع مدل هیدرولیکی (خطی در برابر غیرخطی) به عنوان شبیه‌ساز محیطی، چگونه و تا چه اندازه بر فرآیند یادگیری یک الگوریتم یادگیری تقویتی گسسته تأثیر می‌گذارد؟ این موضوع تاکنون به صورت کمی و سیستماتیک ارزیابی نشده است.

از آنجا که الگوریتم‌های یادگیری تقویتی برای دستیابی به یک سیاست کنترلی مناسب به تعداد زیادی تعامل با محیط نیاز دارند، انتخاب مدل شبیه‌ساز می‌تواند بر سرعت همگرایی، کیفیت یادگیری و عملکرد نهایی عامل هوشمند اثرگذار باشد. از این رو، پژوهش حاضر با مقایسه دو محیط شبیه‌سازی مبتنی بر مدل خطی و مدل غیرخطی مرجع (معادلات کامل سنت-ونانت)، تأثیر نوع مدل هیدرولیکی را بر سرعت و دقت یادگیری، کیفیت سیاست کنترلی حاصل از نظر شاخص‌های توزیع آب و میزان پایداری آن ارزیابی می‌کند. بدین ترتیب، این پژوهش با تمرکز بر نقش مدل شبیه‌ساز در فرآیند یادگیری تقویتی، شکاف موجود در مطالعات پیشین را پوشش می‌دهد. لازم به ذکر است که اعتبار مدل خطی در همسایگی نقطه کار و افت کارایی در انحرافات بزرگ، یک اصل پذیرفته شده در تئوری کنترل است و این تحقیق به دنبال رد یا اثبات مجدد آن نیست، بلکه به دنبال تأثیر این ویژگی شناخته‌شده بر فرآیند یادگیری یک عامل یادگیرنده است.

## مواد و روش‌ها

فرآیند انجام کار به صورت زیر است: در هر گام، رایند یادگیر، عامل یادگیرنده ابتدا حالت کنونی سیستم ( $S_t$ ) را که به صورت بردار  $S_t = [Pl_t, QT_t]$  تعریف می‌شود ( $Pl_t$  شماره بازه  $i$  و  $QT_t$  دبی آبگیر  $i$ )، مشاهده کرده و سپس با بهره‌گیری از سیستم فازی و روش انتخاب عمل بی‌شبه نرم، عمل متناظر  $A_t$  را انتخاب می‌کند. پس از آن، شبیه‌ساز کانال فراخوانی می‌شود و اجرا می‌گردد. براساس نتیجه حاصل از شبیه‌سازی، پاداشی به عمل انتخاب شده تخصیص داده می‌شود که این پاداش به اولین گام با  $R_2$  نمایش داده شده است. در ادامه، سیستم به حالت جدید در بازه دوم یعنی  $S_2$  منتقل شده و عامل یادگیرنده، عمل بعدی ( $A_2$ ) را مجدداً با استفاده از سیستم فازی و براساس حالت جدید مشاهده شده، تعیین می‌کند. سپس، جدول مقادیر ارزش (Q-Table) با استفاده از مجموعه اطلاعات شامل حالت قبلی، عمل انجام شده، پاداش دریافتی، حالت جدید و عمل بعدی، به‌روزرسانی می‌شود. این چرخه به صورت متوالی تا رسیدن به آخرین بازه ادامه یافته و پس از اتمام بازه‌ها، فرآیند مجدداً از بازه اول آغاز می‌گردد تا زمانی که به حداکثر تکرار برسد.

## فرآیند یادگیری و فرمول‌بندی آن

در این پژوهش، از یک کانال مرجع استاندارد که برای ارزیابی الگوریتم‌های کنترلی در سیستم‌های توزیع آب سطحی پیشنهاد شده است، استفاده گردید. مشخصات این کانال عبارت است از: شیب کف بسیار ملایم ۰/۰۰۱، شیب جانبی ۱/۵ و ضریب زبری مانینگ ۰/۰۲. به هشت بازه که توسط هشت دریچه تنظیم سطح آب با افت ارتفاع ۰/۲ متر در محل سازه از یکدیگر جدا می‌شوند، در بالادست هر یک از این دریچه‌ها، یک

آبگیر قرار دارد. عمق نرمال بازه‌های اول تا سوم ۲/۱ متر، بازه‌های چهارم و پنجم ۱/۹ متر و بازه‌های ششم تا هشتم ۱/۷ متر است. در انتهای کانال، یک دریچه برای خروج جریان وجود دارد (Clemmens et al. 1998).

برای پیاده‌سازی الگوریتم یادگیری از سیستم فازی مرتبه‌صفر از نوع تاکاگی-سوگنو-کانگ استفاده شد. بخش مقدماتی این سیستم شامل توابع عضویت فازی و بخش نتیجه آن شامل یک جدول Q با مقادیر ثابت (که مقدار اولیه تمام درایه‌ها صفر در نظر گرفته شد) می‌باشد. متغیر  $Pl_i$  (شماره بازه) با هشت تابع عضویت مثلثی (برای هشت بازه مختلف در کانال) به نام‌های  $Pl_1$  تا  $Pl_8$  و متغیر  $QT_i$  (دبی جریان آبگیر) با دو تابع عضویت مثلثی  $X_1$  و  $X_2$  تعریف گردید. در مرحله فازی‌سازی، درجه‌ی عضویت نرمال شده برای آبگیر  $(\mu_i(X_i))$  و برای شماره بازه  $(\mu_i(Pl_i))$  محاسبه شده و درجه‌ی عضویت نهایی هر قانون فازی از حاصلضرب این دو مقدار به دست می‌آید. در بخش غیرفازی‌ساز، مقدار هر عمل گسسته  $a_j$  در قانون  $R_i$  با نماد  $Q_{i,j}$  نمایش داده می‌شود که شامل خروجی‌های دواندیدی است که در آن  $i$  شمارنده قوانین  $(R_i)$  و  $j$  شمارنده خروجی‌ها است. برای هر خروجی  $j$ ، یک بردار ستونی مجزا به نام  $V_j$  به صورت  $V_j = [Q_{1,j} \quad Q_{2,j} \quad \dots \quad Q_{m,j}]^T$  تعریف می‌شود که در آن  $m$  تعداد کل قوانین است. هر قانون  $R_i$  معادل یک زوج مشخص به صورت  $R_i \equiv (Pl_i, X_i)$  است. بنابراین، مقدار  $Q_{i,j}$  در بردار  $V_j$  متناظر با خروجی  $j$  برای زوج  $(Pl_i, X_i)$  است. نمایش نهایی سیستم به صورت مجموعه‌ای از بردارها بصورت  $\{V_1, V_2, \dots, V_j, \dots, V_n\} \equiv$  سیستم می‌باشد، که در آن  $n$  تعداد کل خروجی‌ها است. در پژوهش حاضر، یادگیری به صورت متوالی در بازه‌های کانال طراحی و فرمول‌بندی شده است. اگر شماره تکرار  $k$  باشد، در تکرار  $k$ ام،  $S_k$  نشان‌دهنده حالت،  $a_k$  نشان‌دهنده عمل و  $r_k$  نشان‌دهنده پاداش خواهد بود. در این صورت، فرمولاسیون ریاضی مساله به صورت زیر خواهد بود.

برای انتخاب عمل در هر حالت، احتمال انتخاب هر عمل  $j$  در قاعده  $i$  در تکرار  $k$ ، که با  $p_k(a_j)$  نمایش داده می‌شود، با استفاده از روش انتخاب عمل بیشینه نرم محاسبه می‌گردد (معادله ۱). این محاسبه با بهره‌گیری از درجه عضویت نرمال شده  $\mu_i$ ، مقدار عمل  $j$  در قاعده  $i$  (یعنی  $Q_{ij}$ ) و پارامتر دما  $(\delta_{k-1})$  انجام می‌شود. عمل دارای بیشترین احتمال در هر قاعده  $i$  با  $a_j^+$  (معادله ۲) و درایه متناظر آن در جدول Q با  $Q_{ij}^+$  نشان داده می‌شود (معادله ۳). عمل نهایی در تکرار  $k$  (یعنی  $a_k$ )، میانگین وزنی عمل‌های با احتمال بالا در هر قاعده  $i$  بوده و در بخش غیرفازی‌ساز محاسبه می‌گردد (معادله ۴). همچنین، ارزش عمل انتخابی  $(w_k)$  نیز به عنوان میانگین وزنی  $Q_{ij}^+$  محاسبه می‌شود (معادله ۵). در گام بعد، عمل انتخابی به شبیه‌ساز اعمال شده و پس از اجرای شبیه‌سازی، پاداش متناظر تخصیص  $(r_{k+1})$  می‌یابد (معادله ۶). آنگاه سیستم در حالت بعدی  $(S_{k+1})$  قرار گرفته و عمل بعدی  $(a_{k+1})$  انتخاب می‌شود. لازم به ذکر است که ضرایب ثابت بر اساس پیشنهاد مقالات پیشین می‌باشد.

$$p_k(a_j) = \exp\left(\frac{\mu_i \times Q_{ij}}{\delta_{k-1} - 0.99^k \times 0.05 \times \delta_{k-1}}\right) / \sum_1 \exp\left(\frac{\mu_i \times Q_{ij}}{\delta_{k-1} - 0.99^k \times 0.05 \times \delta_{k-1}}\right) \quad \text{رابطه ۱}$$

$$a_j^+ = \arg \max_{a_j} p_k(a_j) \quad \text{رابطه ۲}$$

$$Q_{ij}^+ = \max_{a_j} Q_{ij} \quad \text{رابطه ۳}$$

$$a_k = \frac{\sum_i \mu_i \cdot a_j^+}{\sum_i \mu_i} \quad \text{رابطه ۴}$$

$$w_k = \frac{\sum_i \mu_i \cdot Q_{ij}^+}{\sum_i \mu_i} \quad \text{رابطه ۵}$$

$$r_{k+1} = \frac{100}{1 + \sqrt{\sum_{t=0}^T (Y_t - Y_s)^2} + \sqrt{\sum_{n=1}^N \sum_{t=0}^T (QT_t - QT_s)^2}} \quad \text{رابطه ۶}$$

در این روابط،  $Y_s$  و  $QT_s$  به ترتیب نقاط تنظیم (اهداف) عمق و دبی،  $Y_t$  و  $QT_t$  به ترتیب عمق آب و دبی تحویلی در زمان  $t$ ،  $T$  کل زمان شبیه‌سازی و  $N$  تعداد آبگیرها در هر بازه است. در ابتدای یادگیری با توجه به اینکه مقادیر  $Q_{ij}$  در جدول Q صفر می‌باشند، احتمال انتخاب همه عمل‌ها برابر با ۱ است؛ بنابراین، انتخاب عمل کاملاً تصادفی است. با پیشرفت یادگیری، جدول Q به‌روزرسانی شده و انتخاب عمل بر اساس مقادیر  $Q_{ij}$  انجام می‌شود. دمای پایین‌تر و  $Q_{ij}$  بالاتر برای یک عمل، احتمال انتخاب آن عمل را افزایش می‌دهد. در ادامه، خطای تقریبی مقدار عمل،  $dQ_{ij}$  محاسبه شده (معادله ۷) و  $Q_{ij}$  متناسب با آن به‌روزرسانی می‌گردد (معادله ۸).

$$dQ_{ij} = \begin{cases} r_{k+1} + 0.9 \times w_{k+1} - w_k & \text{if } j = j^+ \\ 0 & \text{otherwise} \end{cases} \quad \text{رابطه ۷}$$

$$Q_{ij} = Q_{ij} + \frac{\beta_k}{\beta_d} \times dQ_{ij} \times \mu_i \quad \text{رابطه ۸}$$

در این روابط،  $\delta_k$  نشان‌دهنده دمای الگوریتم در تکرار  $k$ ،  $\beta_k$  نرخ یادگیری در همان تکرار، و  $\beta_d$  ضریب کاهش نرخ یادگیری است. تعداد کل تکرارهای فرآیند یادگیری معادل ۵۰۰ در نظر گرفته شد. با توجه به اینکه مقدار نهایی هر دو پارامتر دما و نرخ یادگیری برابر با ۰/۰۰۰۱ است، مقادیر اولیه این دو پارامتر با روش آزمون و خطا به گونه‌ای انتخاب شدند که در تکرارهای پایانی، به مقدار نهایی موردنظر برسند. زمانی که دما به ۰/۰۰۰۱ می‌رسد، الگوریتم عملی را با بالاترین احتمال انتخاب می‌کند و زمانی که نرخ یادگیری به این مقدار کاهش می‌یابد، مدل عملاً یادگیری جدیدی انجام نمی‌دهد. مقدار اولیه نرخ یادگیری و ضریب کاهش آن، از طریق چندین اجرای آزمایشی و با هدف دستیابی به همگرایی مناسب و حداقل سازی توابع تابع ارزش، تعیین گردیدند. لازم به ذکر است که این ابرپارامترها برای هر دو محیط شبیه‌سازی (مدل خطی و مدل غیرخطی) به‌طور یکسان تنظیم شدند تا مقایسه عملکرد دو مدل صرفاً ناشی از تفاوت در مدل هیدرولیکی باشد و نه ناشی از تنظیمات متفاوت الگوریتم یادگیری.

### مدل‌های خطی و غیرخطی

شبیه‌ساز غیرخطی AICSS برای مدل‌سازی سیستم‌های توزیع آب سطحی توسعه یافته است که در این تحقیق استفاده گردید. این شبیه‌ساز با یادگیر تلفیق شد و در فرایند یادگیری که قبلاً تشریح شد فراخوانی و اجرا گردید. برای تهیه مدل خطی نیز از خروجی‌های مدل غیرخطی استفاده شد که در ادامه تشریح خواهد شد. اثبات شده است که این مدل غیرخطی در تمامی شرایط بهره‌برداری معمولی، چه با تغییرات جزئی و چه با تغییرات شدید، از اعتبار و دقت مناسبی برخوردار است. شایان ذکر است که این مدل غیرخطی، در شبیه‌سازی عمق آب در بالادست و پایین‌دست، به ترتیب دارای دقتی معادل ۰/۶۸ و ۰/۲۹ درصد است. در مدل غیرخطی، جریان دائمی متغیر تدریجی برای کاربردهای عملی مانند کانال‌های منشوری بدون جریان جانبی، با استفاده از معادله ۹ محاسبه می‌شود (Henderson 1966):

$$\frac{dy}{dx} = \frac{S_0 - S_f}{1 - Fr^2} \quad \text{رابطه ۹}$$

در این رابطه،  $dy$  تغییرات عمق در طول کانال،  $dx$  تغییرات فاصله در طول کانال،  $S_0$  شیب کانال و  $S_f$  شیب خط انرژی کل و  $Fr$  عدد فرود می‌باشد. برای شبیه‌سازی جریان غیردائمی، AICSS از معادلات سنت‌ونانت به فرم زیر استفاده می‌کند (Strelkoff 1969):

$$\frac{\partial A}{\partial t} + \frac{\partial Q}{\partial x} = 0 \quad \text{رابطه ۱۰}$$

$$\frac{\partial Q}{\partial t} + \frac{\partial}{\partial x} \left( \frac{Q^2}{A} \right) + gA \frac{\partial y}{\partial x} = gA(S_0 - S_f) \quad \text{رابطه ۱۱}$$

که در آن،  $Q$  دبی جریان،  $A$  سطح مقطع جریان،  $g$  شتاب گرانش،  $x$  طول و  $y$  عمق است. همانطور که اشاره شد یکی از روشهای شبیه‌سازی کانال‌های انتقال و توزیع آب، توسعه یک مدل ریاضی خطی است که رفتار دینامیکی سیستم را با دقت مناسب توصیف کند. در کانال‌های چندبازه‌ای، نمایش فضای حالت به دلیل ارائه چارچوبی فشرده و قدرتمند برای مدیریت سیستم‌های چندورودی-چندخروجی بسیار مناسب است. در این پژوهش، از مدل فضای حالت گسسته-زمان به فرم زیر استفاده شد:

$$x_{lm}(kt + t) = A_{lm} \cdot x_{lm}(kt) + B_{lm} \cdot u(kt) + K_{lm} \cdot e(kt) \quad \text{رابطه ۱۲}$$

$$y_{lm}(kt) = C_{lm} \cdot x(kt) \quad \text{رابطه ۱۳}$$

در این روابط،  $t$  زمان نمونه‌برداری،  $k$  شماره گام زمانی جاری،  $x_{lm}(kt)$  بردار حالت ( $n \times 1$ ) شامل متغیرهایی نظیر عمق آب در پایین‌دست هر بازه و بالادست دریچه‌های کنترل،  $u(kt)$  بردار ورودی ( $r \times 1$ ) شامل موقعیت دریچه‌ها (تعداد دریچه‌ها برابر با  $r$  است)،  $e(kt)$  بردار اغتشاش ( $m \times 1$ ) نظیر آب تحویلی به آبگیرهای فرعی ( $m$  تعداد آبگیرها)، و  $y_{lm}(kt)$  بردار خروجی ( $m \times 1$ ) است. ماتریس خروجی  $C_{lm}$  به صورت ماتریس همانی در نظر گرفته شده، به این معنا که تمام متغیرهای حالت قابل اندازه‌گیری هستند ( $x_{lm}(kt) = y_{lm}(kt)$ ). ماتریس‌های  $A_{lm}$  (دینامیک حالت)،  $B_{lm}$  (ورودی) و  $K_{lm}$  با استفاده از جعبه‌ابزار شناسایی سیستم (System Identification Toolbox) مبتنی




بر داده در متلب تعیین شدند. در گام نخست، داده‌های ورودی-خروجی از مدل غیرخطی کسب می‌شود. بدین منظور، مدل غیرخطی با اعمال یک سری تغییرات پله‌ای در موقعیت هر یک از دریچه‌های کنترل تحریک می‌گردد. برای تحریک سیستم، موقعیت هر دریچه به صورت متوالی به میزان  $5 \pm$ ،  $10 \pm$  و  $20 \pm$  درصد نسبت به مقدار اولیه خود تغییر داده شده و تا رسیدن به شرایط ماندگار جدید ادامه می‌یابد. برای نمونه، دریچه اول از مقدار اولیه ۲۶۷ سانتی‌متر به میزان  $5 +$  درصد (۲۸ سانتی‌متر) افزایش یافته، سپس به مقدار اولیه بازگشته، سپس به میزان  $5 -$  درصد کاهش یافته و مجدداً به مقدار اولیه بازگردانده می‌شود. در طول این آزمایش، عمق آب در هر بازه، موقعیت دریچه‌ها و دبی آبگیرها ثبت می‌گردد. پس از جمع‌آوری داده‌ها، اختلاف بین مقادیر اندازه‌گیری شده با مقادیر مربوط به نقطه خطی‌سازی محاسبه می‌شود.

در گام دوم، داده‌های افزایشی حاصل به جعبه‌ابزار شناسایی سیستم متلب معرفی می‌گردند. داده‌های موقعیت دریچه‌ها به عنوان ورودی و داده‌های عمق آب به عنوان خروجی تعریف می‌شوند. تنظیمات جعبه‌ابزار به صورت زیر انتخاب می‌گردد: یک مدل گسسته-زمان با زمان نمونه‌برداری ۳۶ ثانیه که با گام زمانی مدل غیرخطی مطابقت دارد تنظیم می‌شود. سپس الگوریتم‌های شناسایی اجرا شده و ضرایب ماتریس‌ها استخراج می‌گردند. این ماتریس‌ها در محیط متلب کدنویسی شده و برای استفاده در کنترل‌گر آماده می‌شوند. برای اعتبارسنجی مدل خطی به‌دست‌آمده، مجموعه داده‌های جدیدی با اعمال یک دنباله دودویی شبه-تصادفی (PRBS: pseudorandom binary sequences) به موقعیت دریچه‌ها در شبیه‌ساز غیرخطی تولید می‌شود. سپس خروجی عمق آب حاصل از مدل خطی با خروجی مدل غیرخطی مقایسه می‌گردد.

## ارزیابی

برای ایجاد جریان در داخل کانال و سازه‌ها به منظور ارزیابی سیستم توسعه‌یافته، نیاز به بررسی حالت‌های مختلف جریان است. از آنجا که مقادیر دبی آبگیرهای مختلف به عنوان ورودی به سیستم یادگیرنده در نظر گرفته می‌شوند و این مقادیر بین  $0.5$  تا  $0.35$  در نوسان هستند، لذا مقادیر تصادفی دبی برای هر یک از آبگیرها (۱ تا ۸) انتخاب گردید. این مقادیر در شکل ۱ به ترتیب برای آبگیرهای ۱ تا ۸ ارائه شده است. در یک سیستم واقعی، جریان ورودی به آبگیرها لزوماً تابع نظم خطی نیست و می‌تواند تحت تأثیر عواملی نظیر تقاضای پایین‌دست، زمان، الگوی برداشت آب، شرایط هیدرولیکی کانال و حتی خطای اندازه‌گیری باشد. از این رو، برای شبیه‌سازی شرایط واقعی و آموزش یادگیرنده به گونه‌ای که در مواجهه با هر الگوی ورودی، حتی الگوهای غیرمنتظره و نامنظم، بتواند تصمیم بهینه را اتخاذ کند، داده‌های ورودی به صورت تصادفی تولید و اعمال شده‌اند.



شکل ۱. مقادیر تصادفی تولید شده برای دبی آبگیرها برای انجام یادگیری

تأثیر این تصادفی بودن بر فرآیند یادگیری بسیار مهم و چندلایه است. با ارائه داده‌های تصادفی در مرحله یادگیری، عامل مجبور می‌شود سیاستی عمومی را بیاموزد که به ویژگی‌های خاص یک توالی ورودی مشخص وابسته نباشد. این امر سبب می‌شود که جدول Q یا تابع ارزش، به جای برآزش بر روی یک الگوی خاص، الگوهای کلی حاکم بر سیستم را کشف کند. از سوی دیگر، استفاده از داده‌های تصادفی از بروز پدیده بیش‌برآزش جلوگیری می‌کند. اگر داده‌های ورودی همواره روندی تکراری و قابل پیش‌بینی داشته باشند، عامل ممکن است صرفاً همان روند را حفظ کند و در مواجهه با شرایط جدید در مرحله آزمون، عملکرد ضعیفی از خود نشان دهد.

جهت ارزیابی عملکرد مدل در میزان موفقیت کنترل سطح آب و مقدار انحراف عمق از عمق هدف، از سنج‌های آماری ریشه میانگین مربع خطاها ( $RMSE$ ) و میانگین خطای مطلق ( $AAE$ ) استفاده شد که روابط آنها در ادامه ارائه شده است. لازم به ذکر است که مقدار مطلوب این سنج‌ها، صفر است.

$$AAE = \frac{\sum_{i=1}^N |y_{AICSS,i} - y_{SSM,i}|}{N} \quad \text{رابطه ۱۴}$$

$$R^2 = \left[ \frac{\sum_{i=1}^n (y_{AICSS,i} - \bar{y}_{AICSS,i})(y_{SSM,i} - \bar{y}_{SSM,i})}{\sqrt{\sum_{i=1}^n (y_{AICSS,i} - \bar{y}_{AICSS,i})^2} \sqrt{\sum_{i=1}^n (y_{SSM,i} - \bar{y}_{SSM,i})^2}} \right]^2 \quad \text{رابطه ۱۵}$$


در این رابطه،  $y_{AICSS,i}$  عمق آب حاصل از شبیه‌ساز غیرخطی و  $y_{SSM,i}$  عمق آب پیش‌بینی شده توسط مدل فضای حالت خطی،  $\bar{y}_{AICSS,i}$  میانگین عمق آب حاصل از شبیه‌ساز غیرخطی،  $\bar{y}_{SSM,i}$  میانگین عمق آب حاصل از شبیه‌ساز خطی می‌باشند. ارزیابی عملکرد با استفاده از شاخص‌های استاندارد کارایی و کفایت انجام گرفت. شاخص‌های کارایی ( $Efficiency$ ) و کفایت ( $Adequacy$ ) توزیع آب برای ارزیابی تحویل جریان به آبیگرها ارائه شد (Molden and Gates 1990). شاخص کارایی نشان می‌دهد که چه مقدار آب اضافی نسبت به نیاز تحویل داده شده، در حالی که شاخص کفایت مشخص می‌کند که چه مقدار کمبود در تحویل آب وجود دارد. هرچه شاخص‌های کارایی و کفایت به عدد یک نزدیک‌تر باشند، مطلوبیت عملکرد ( $Desirability$ ) بیشتر است (شکل ۲). طبقه‌بندی خوب ( $good$ ) نشان‌دهنده عملکرد مطلوب و طبقه‌بندی ضعیف ( $poor$ ) بیانگر عملکرد نامطلوب سیستم می‌باشد. شاخص‌های حداکثر انحراف ( $MAE$ ) و میانگین انحراف ( $IAE$ ) عمق آب از مقدار هدف برای ارزیابی مدل‌ها در تثبیت عمق در عمق هدف معرفی شدند (Clemmens et al. 1998). هرچه مقادیر شاخص‌های انحراف کوچک‌تر باشند، مطلوبیت عملکرد سیستم بهتر خواهد بود.

$$Efficiency \text{ (or MPF)} = \frac{\Delta t}{T} \sum_{t=0}^T \left[ \frac{1}{N} \sum_N \left( \frac{Q_r}{Q_d} \right) \right] \text{ if } Q_r \leq Q_d, \text{ otherwise } Efficiency = 1 \quad \text{رابطه ۱۶}$$

$$Adequacy \text{ (MPA)} = \frac{\Delta t}{T} \sum_{t=0}^T \left[ \frac{1}{N} \sum_N \left( \frac{Q_r}{Q_d} \right) \right] \text{ if } Q_r \leq Q_d, \text{ otherwise } Adequacy = 1 \quad \text{رابطه ۱۷}$$

$$MAE = \frac{\max(|Y_s - Y_t|)}{Y_s} \quad \text{رابطه ۱۸}$$

$$IAE = \frac{\Delta t}{T} \sum_{t=0}^T \frac{(|Y_s - Y_t|)}{Y_s} \quad \text{رابطه ۲۰}$$




شکل ۲. مطلوبیت شاخص‌های ارزیابی ارائه شده توسط (Clemmens et al. (1998 و (Molden and Gates (1990.

## نتایج و بحث

### پارامترهای ورودی

در این تحقیق، تعداد کل تکرارهای فرآیند یادگیری برابر با ۵۰۰ در نظر گرفته شد. پارامتر دما در روش انتخاب عمل بر اساس بیشینه نرم به شماره تکرارها وابسته است. در مراحل پایانی یادگیری، تأثیر دما بر احتمال انتخاب عمل ناچیز می‌شود و عملاً احتمال انتخاب عمل با برآورد

ارزش آن هم‌راستا می‌گردد. این وضعیت زمانی رخ می‌دهد که اختلاف بین دو مقدار دمای متوالی بسیار کوچک باشد. به منظور تعیین معیار مناسب برای کاهش دما، مقادیر اولیه مختلف دما شامل ۰/۰۵، ۰/۰۱، ۰/۰۰۵ و ۰/۰۰۱ مورد آزمون قرار گرفت و منحنی‌های کاهش دمای متناظر با هر یک و با توجه به نرخ کاهش،  $\delta_k - 0.99^k \times 0.05 \times \delta_k$ ، بررسی شد. معیار مطلوب برای انتخاب دمای اولیه، شرایطی در نظر گرفته شد که دمای نهایی در انتهای فرآیند یادگیری به مقدار کمتر از ۰/۰۰۰۱ برسد که در آن اختلاف بین دو مقدار دمای متوالی بسیار کوچک می‌شود. نتایج حاصل از بررسی دمای نهایی برای هر یک از مقادیر اولیه در شکل ۳ الف ارائه شده است. همان‌طور که در شکل مشاهده می‌شود، زمانی که دمای اولیه از ۰/۰۰۱ کمتر باشد، دمای نهایی به میزان قابل توجهی کاهش می‌یابد. بر این اساس، دمای اولیه برابر ۰/۰۰۰۷ به عنوان مقدار مناسب انتخاب گردید.




شکل ۳. الف) مقدار دمای به دست آمده در آخرین تکرار برای دماهای اولیه مختلف و ب) میزان کاهش نرخ یادگیری در آخرین تکرار برای نرخ‌های یادگیری مختلف

در این تحقیق، نرخ یادگیری با افزایش شماره تکرارها به تدریج کاهش می‌یابد، به گونه‌ای که در تکرارهای پایانی، مقدار آن به حدی کم می‌شود که عملاً یادگیری جدیدی رخ نمی‌دهد. مقدار اولیه نرخ یادگیری با آزمون و خطا برابر ۰/۳ در نظر گرفته شد. نرخ کاهش یادگیری با استفاده از روش آزمون و خطا تعیین گردید. هدف اصلی آن بود که در پایان فرآیند یادگیری، مقدار نرخ یادگیری به توجه به نرخ کاهش،  $\frac{\beta_k}{\beta_d}$ ، به ۰/۰۰۰۱ برسد؛ زیرا پس از این مقدار، دیگر تغییری محسوس در یادگیری ایجاد نمی‌شود. به منظور یافتن مقدار مناسب نرخ کاهش یادگیری، مقادیر اولیه گوناگونی آزمایش شدند. نتایج این آزمایش‌ها در شکل ۳ ب ارائه شده است. همان‌طور که مشاهده می‌شود، با انتخاب نرخ کاهش یادگیری برابر ۱/۰۶۷، مقدار نرخ یادگیری در تکرار پایانی به حدود ۰/۰۰۰۱۸ می‌رسد که نزدیک به مقدار مطلوب (۰/۰۰۰۱) است. بنابراین، مقدار نرخ کاهش یادگیری برابر ۱/۰۶۷ انتخاب گردید.

نمودار تغییرات پاداش بر حسب تعداد تکرارها (اپیزودها) در شکل ۴ ارائه شده است. همان‌طور که مشاهده می‌شود، رفتار منحنی دارای سه مرحله متمایز است. مرحله اول مرحله اکتشاف است که تقریباً از اپیزود صفر تا حدود اپیزودهای ۱۰۰ تا ۱۵۰ ادامه می‌یابد. در این بازه، عمل‌ها به صورت تصادفی‌تر انتخاب می‌شوند و در نتیجه پاداش دریافتی دارای نوسانات زیاد و مقادیری عموماً پایین است. نرخ یادگیری بالا در این مرحله موجب می‌شود که عامل تغییرات نسبتاً بزرگی در جدول ارزش اعمال کند، اما هنوز به یک سیاست پایدار دست نیافته است. مرحله دوم مرحله گذار از اکتشاف به بهره‌برداری است که اپیزودهای حدود ۱۵۰ تا ۳۵۰ را در بر می‌گیرد. با کاهش تدریجی دما و همچنین کاهش نرخ یادگیری به سمت مقادیر کوچک‌تر، رفتار عامل به تدریج از اکتشاف به انتفاع تغییر می‌یابد. پاداش‌ها روندی صعودی و نسبتاً هموار پیدا می‌کنند، هرچند نوساناتی همچنان وجود دارد. عامل سیاست‌های بهتری که منجر به پاداش بالاتر می‌شوند را شناسایی کرده و عمل‌های ضعیف‌تر را کنار می‌گذارد. مرحله سوم مرحله بهره‌برداری خالص و همگرایی است که از حدود اپیزود ۳۵۰ تا ۵۰۰ ادامه می‌یابد. دما از ۰/۰۰۰۱ پایین‌تر رفته و توزیع احتمال انتخاب عمل به شدت نوک‌تیز می‌شود؛ در نتیجه عامل تقریباً همیشه بهترین عمل شناخته شده را انتخاب می‌کند. همزمان، نرخ یادگیری نیز به



۰/۰۰۰۱ یا کمتر رسیده و عملاً جدول ارزش دیگر به روز نمی شود. در نتیجه، پاداش به مقدار نسبتاً ثابت و حداکثری نزدیک به مقدار بهینه می رسد و نوسانات بسیار ناچیز می شوند.




شکل ۴. تغییرات پاداش در طول فرایند یادگیری

### مدل غیر خطی

نتایج ارائه شده در شکل ۵، عملکرد معیارهای مختلف را در بازه های مستقل نشان می دهد. بررسی نتایج نشان می دهد که در اکثر بازه ها، هر دو شاخص خطای MAE و IAE در محدوده بسیار پایین و در طبقه «خوب» قرار دارند که نشان می دهند که حداکثر و میانگین انحراف عمق آب از عمق هدف پائین است. مقدار MAE در بازه های ۱ تا ۴ و ۷ تا ۸ همگی بسیار کمتر از آستانه ۱۵ درصد هستند. شاخص IAE نیز در بازه های مذکور نشان دهنده میانگین انحراف ناچیز عمق آب از مقدار هدف است. با این حال، در سایر بازه ها مقادیر نسبتاً بالاتر و انحراف بیشتری مشاهده می شود؛ هر چند که MAE و IAE، همچنان در محدوده طبقه خوب قرار دارند. نکته قابل توجه در رابطه بین MAE و IAE این است که در همه بازه ها، مقدار IAE به طور قابل انتظاری از MAE کوچک تر است. این پدیده به این دلیل رخ می دهد که MAE حداکثر انحراف لحظه ای را نشان می دهد، در حالی که IAE میانگین انحرافات را در کل دوره محاسبه می کند. نسبت IAE به MAE در بازه های مختلف بین ۰/۴۸ تا ۰/۸۴ متغیر است که نشان می دهد انحرافات بزرگ عمق آب عمدتاً گذرا و در زمان های اولیه بهره برداری بوده و در بیشتر زمان شبیه سازی، سیستم به مقدار هدف نزدیک بوده است.

شاخص راندمان نشان می دهد که آیا آب اضافی به آبیگرها تحویل داده شده است یا خیر، در حالی که شاخص کفایت بیانگر میزان تأمین آب مورد نیاز آبیگرها می باشد. نتایج نشان می دهد که عملکرد سیستم در هر دو شاخص راندمان و کفایت در سطح عالی و کلاس خوب قرار دارد. شاخص راندمان در تمام بازه ها در محدوده ۰/۹۸۷ تا ۱ قرار دارد که بسیار بالاتر از آستانه ۰/۸۵ بوده و در طبقه خوب قرار می گیرند. این مقادیر نشان می دهد که حجم آب اضافی تحویل شده به آبیگرها ناچیز بوده و سیستم از کارایی انتقال بالایی برخوردار است. شاخص کفایت نیز عملکرد بسیار مطلوبی را نشان می دهد و در تمامی بازه ها بالاتر از آستانه ۰/۹ بوده و در طبقه خوب طبقه بندی می شوند.

بررسی همزمان شاخص های راندمان و کفایت، تصویر کاملی از عملکرد سیستم ارائه می دهد. در حالت ایده آل، هر دو شاخص باید برابر با ۱ باشند که نشان دهنده تحویل دقیق آب مورد نیاز بدون کمبود یا مازاد است. نتایج این مطالعه نشان می دهد که در اکثر بازه ها، هر دو شاخص مقادیر بسیار نزدیک به ۱ دارند که بیانگر عملکرد بهینه سیستم می باشد. در بازه هایی که راندمان پایین تر است، کفایت همچنان در سطح عالی باقی مانده است. این وضعیت نشان می دهد که کاهش جزئی راندمان به دلیل تحویل حجم بسیار کمی آب اضافی بوده است، در حالی که نیاز آبیگرها به طور کامل تأمین شده است. در مقابل، در بازه هایی که کفایت پایین تر از ایده آل و راندمان در بالاترین سطح قرار دارد، سیستم آب اضافی تحویل نداده اما کمبود در تأمین نیاز وجود داشته است. نکته قابل توجه این است که در تمام موارد، هیچ بازه ای وجود ندارد که هم راندمان و هم کفایت آن به طور همزمان پایین باشد. این موضوع نشان می دهد که الگوریتم یادگیری توانسته است تعادل مناسبی به طور همزمان بین دو هدف متضاد تحویل آب (یعنی جلوگیری از مازاد و جلوگیری از کمبود) برقرار کند.



شکل ۵. مقادیر شاخص‌های ارزیابی منتج از مدل غیرخطی در فرایند یادگیری

## مدل خطی

مقادیر حداکثر، متوسط و حداقل معیارهای آماری در کل کانال برای مرحله آزمون و مرحله اعتبار سنجی در یافتن ضرایب ماتریس‌های حالت مدل خطی در جدول ۱ ارائه شده است. توضیح اینکه در جدول مذکور ستون حداقل، میانگین و حداکثر به ترتیب کمترین، متوسط و حداکثر مقدار شاخص‌های آماری را در میان بازه‌های ۱ تا ۸ را نشان می‌دهد. در مرحله اعتبارسنجی، برای رد احتمال بیش‌برازش یا کم‌برازش مدل خطی نسبت به داده‌های آموزش، مدل با استفاده از مجموعه داده‌های اضافی تولید شده توسط شبیه‌ساز AICSS با دنباله‌های دودویی شبه تصادفی (PRBS: pseudorandom binary sequences)، که در آن ورودی‌های تصادفی در پیچه‌ها در یک بازه از پیش تعیین شده تولید می‌شوند، اعتبارسنجی گردید. مقادیر معیارهای آماری حاصل از این اعتبارسنجی نیز در جدول ۱ درج شده است.

بر اساس نتایج ارائه‌شده در جدول، مدل فضایی حالت خطی توسعه‌یافته عملکرد بسیار مطلوبی در هر دو مرحله تست و اعتبارسنجی داشته است. در مرحله تست، مقادیر بسیار پایین معیارهای آماری از جمله AAE در محدوده ۰/۰۰۱۹ تا ۰/۰۱۱۸ و RMSE در محدوده ۰/۰۰۳۲ تا ۰/۰۱۷۳ در سراسر کانال نشان‌دهنده دقت بالای مدل در بازتولید دینامیک خطی سیستم برای تغییرات پله‌ای ۵، ۱۰ و ۲۰ درصد بازشدگی در پیچه‌ها است. در مرحله اعتبارسنجی با سیگنال‌های PRBS که ورودی‌های تصادفی و گسترده‌تری را اعمال می‌کند، مقادیر خطا افزایش نسبی یافته و به AAE حداکثر ۰/۰۲۲۴ و RMSE حداکثر ۰/۰۲۸۳ رسیده است. این افزایش خطا، که به دلیل تحریک سیستم در محدوده وسیع‌تری از حالت‌های دینامیکی و اعمال اغتشاشات آگیرهاست، کاملاً قابل انتظار بوده و از شدت اندکی برخوردار است. از آنجا که خطای اعتبارسنجی نسبت به خطای تست جهش شدیدی نداشته، نمی‌توان مدل را دچار بیش‌برازش یا کم‌برازش دانست. در مجموع، این نتایج حاکی از آن است که مدل خطی ضمن حفظ دقت بالا برای داده‌های درون مرزهای آموزشی، تعمیم‌پذیری خوبی نیز برای ورودی‌های تصادفی و شرایط عملیاتی دیگر داشته و می‌توان از آن با اطمینان مناسب در کاربردهای کنترلی و پیش‌بینی در اطراف نقطه هدف (عمق نرمال) با تغییرات پله‌ای تا حداکثر ۲۰٪ استفاده کرد.

جدول ۱. مقادیر حداکثر، متوسط و حداقل معیارهای آماری در کل کانال برای مرحله آزمون و مرحله اعتبارسنجی


|                   | Criteria (m) | Minimum | Mean   | Maximum |
|-------------------|--------------|---------|--------|---------|
| Test              | AAE          | ۰/۰۰۱۹  | ۰/۰۰۵۶ | ۰/۰۱۱۸  |
|                   | RMSE         | ۰/۰۰۳۲  | ۰/۰۰۹۵ | ۰/۰۱۷۳  |
| Validation (PRBS) | AAE          | ۰/۰۰۷۳  | ۰/۰۱۱۲ | ۰/۰۲۲۴  |
|                   | RMSE         | ۰/۰۰۹۱  | ۰/۰۱۳۹ | ۰/۰۲۸۳  |

بررسی نتایج مربوط به عملکرد مدل یادگیری در تلفیق با مدل خطی توسعه‌یافته نشان می‌دهد که شاخص‌های خطا روند صعودی آشکاری از بازه‌های بالادست به سمت بازه‌های پایین‌دست دارند (شکل ۶). در بازه‌های ۱ تا ۴، مقادیر MAE به ترتیب ۱۱، نه، هفت و ۱۲ درصد هستند که

همگی در طبقه «خوب» قرار می‌گیرند. شاخص IAE نیز در همین بازه‌ها مقادیر شش، شش، پنج و هشت درصد را نشان می‌دهد که بیانگر میانگین انحراف کم عمق آب از مقدار هدف است. اما از بازه ۵ به بعد، عملکرد به شدت کاهش می‌یابد. در بازه ۵، MAE به ۲۱ درصد می‌رسد که در طبقه «متوسط» قرار می‌گیرد. در بازه ۶، MAE برابر ۲۳ درصد (متوسط) است. در بازه ۷، MAE به ۴۲ درصد می‌رسد که در طبقه «ضعیف» محسوب می‌شود. در بازه ۸، MAE به ۵۹ درصد، ضعیف‌ترین عملکرد را نشان می‌دهد. روند مشابهی برای شاخص IAE نیز مشاهده می‌شود. بازه‌های ۱ تا ۴ مقادیر IAE بین ۵ تا ۸ درصد دارند (خوب)، اما بازه ۷ به ۳۲ درصد و بازه ۸ به ۵۱ درصد در طبقه «ضعیف» طبقه‌بندی می‌شوند. نسبت IAE به MAE در بازه‌های بالادست (۱ تا ۴) بین ۰/۵۵ تا ۰/۷۱ متغیر است که نشان می‌دهد انحرافات عمق عمدتاً گذرا بوده‌اند. اما در بازه‌های پایین‌دست، این نسبت تا ۰/۸۶ نیز رسیده است که نشان‌دهنده این است که در بازه‌های پایین‌دست، انحرافات عمق آب نه تنها شدیدتر هستند، بلکه پایدارتر نیز می‌باشند و سیستم در بازه‌های زمانی طولانی‌تری از مقدار هدف فاصله دارد. این پدیده نشانه ضعف شدید عملکرد یادگیری تقویتی با مدل خطی در شبیه‌سازی رفتار هیدرولیکی بازه‌های پایین‌دست است.

نتایج نشان می‌دهد که شاخص راندمان روند نزولی شدیدی از بالادست به پایین‌دست دارد. در بازه‌های ۱ تا ۶ راندمان در محدوده ۰/۸۵۳ و ۰/۹۹۲ قرار دارد که همگی در طبقه «خوب» قرار می‌گیرند. اما در بازه ۷، راندمان به ۰/۶۸۰ و در بازه ۸، ۰/۴۹۷ می‌رسد که در طبقه «ضعیف» قرار می‌گیرد و نشان‌دهنده عملکرد ضعیف یادگیری تقویتی با مدل شبیه‌ساز خطی در شاخص راندمان است. در مقابل، شاخص کفایت روندی معکوس و افزایشی از بالادست به پایین‌دست دارد و نشان می‌دهد که آبیگرهای پایین‌دست به طور کامل آب مورد نیاز خود را، البته با راندمان پائین، دریافت می‌کنند.

بررسی همزمان شاخص‌های راندمان و کفایت نشان می‌دهد که مدل خطی در بازه‌های بالادست از عملکرد مطلوبی برخوردار است، اما در بازه‌های پایین‌دست با افت قابل توجه عملکرد مواجه می‌شود. لازم به ذکر است که اعتبار مدل خطی در ۲۰ درصد تغییرات دبی است. شایان ذکر است که عملکرد مطلوب مدل در بازه‌های بالادست، حاکی از وقوع تحویل دقیق آب در این بخش از کانال است. بدین معنی که آنچه در پایین‌دست مشاهده می‌شود، نه یک نقص عمومی در کل سیستم، بلکه تشدید خطاهای مدل‌سازی در شرایطی است که تقاضای آبی در بالادست به درستی تأمین شده است و جریان باقیمانده برای تأمین نیاز پایین‌دست با دقت کافی کنترل نمی‌گردد. این یافته با واقعیت میدانی شبکه‌های انتقال و توزیع آب نیز همخوانی دارد که معمولاً کمبود و ناپایداری تحویل آب در انتهای کانال شدت بیشتری پیدا می‌کند.



شکل ۶. مقادیر شاخص‌های ارزیابی منتج از مدل غیرخطی در فرایند یادگیری

مقایسه مدل غیرخطی و خطی نشان می‌دهد که مدل غیرخطی خطاهایی به مراتب کمتر از مدل خطی در بازه‌های پایین‌دست دارد و روندی ثابت و پایدار در تمام طول کانال ارائه می‌دهد. در مقابل، مدل خطی روند صعودی نمایی خطا از بالادست به پایین‌دست نشان می‌دهد. به عنوان مثال، بنابر توضیحات مربوط به راندمان در بخش‌های قبل، حداقل مقدار راندمان در مدل غیرخطی برابر با ۰/۹۸۷ بوده و تقریباً ۲ برابر حداقل مقدار راندمان در مدل خطی (که برابر با ۰/۴۹۷ است) می‌باشد. در مورد MAE، مقدار این شاخص در بازه ۸ برای مدل خطی برابر با ۵۰ درصد و برای مدل غیرخطی ۵ درصد می‌باشد (مطابق شکل‌های ۵ و ۶). علت اصلی این است که دقت مدل غیرخطی تنها ناشی از دقت بیشتر شبیه‌سازی نیست، بلکه به نحوه بازنمایی دینامیک واقعی جریان در فرایند یادگیری نیز مربوط می‌شود. مدل خطی با خطی‌سازی معادلات حاکم در اطراف

یک نقطه کار، تغییرات کوچک دبی و تراز آب را با دقت مناسبی شبیه‌سازی می‌کند؛ اما با افزایش فاصله از شرایط مرجع، به‌ویژه در اثر برداشت‌های متغیر و تغییرات هم‌زمان دبی در طول کانال، دقت آن کاهش می‌یابد. این خطاها در طول مسیر کانال تجمع یافته و در بازه‌های پایین‌دست که تأثیر تغییرات بالادست نیز به آن افزوده می‌شود، به‌صورت چشمگیری افزایش می‌یابد. از آنجا که عامل یادگیری تقویتی سیاست کنترلی خود را بر اساس بازخورد محیط آموزش می‌دهد، هرگونه خطای مدل‌سازی مستقیماً در تابع ارزش و سیاست آموخته‌شده منعکس می‌شود. در مقابل، مدل غیرخطی مبتنی بر معادلات کامل سنت-وانانت قادر است انتشار موج، اندرکنش غیرخطی بین دبی و تراز آب و تغییرات شرایط مرزی ناشی از برداشت‌های آب را با دقت بیشتری بازنمایی کند؛ بنابراین، عامل یادگیرنده تصویری نزدیک‌تر به رفتار واقعی سامانه دریافت کرده و سیاست کنترلی حاصل، به‌ویژه در بازه‌های پایین‌دست، از دقت و پایداری بیشتری برخوردار است.

شایان ذکر است که اعتبار مدل خطی در این تحقیق صرفاً در محدوده  $\pm 20\%$  درصد تغییرات دبی حول نقطه کنترل معنا دارد. در بخش‌های بالادست کانال به دلیل دبی بالای ورودی، تغییرات دبی از این محدوده فراتر نمی‌رود؛ به همین دلیل، اگرچه دقت مدل خطی نسبت به مدل غیرخطی کمتر است، اما همچنان در سطح قابل قبولی قرار دارد. در مقابل، در بخش‌های پایین‌دست کانال به دلیل کمبود دبی جاری در کانال و تغییرات بزرگ ایجادشده در دبی آبگیرها (فراتر از  $\pm 20\%$  درصد)، دقت مدل خطی به شدت کاهش می‌یابد. لازم به تأکید است که مدل‌های خطی معمولاً در اطراف نقطه بهره‌برداری خطی‌سازی می‌شوند. برای تغییرات فراتر از این محدوده می‌توان از خطی‌سازی چندنقطه‌ای استفاده کرد، اما چالش اصلی سوئیچ بین مدل‌ها در مرزهای مشترک است که باید مورد توجه قرار گیرد. با این حال، یک مزیت مهم مدل خطی سرعت بسیار بالاتر فرآیند یادگیری الگوریتم یادگیری تقویتی در مقایسه با مدل غیرخطی است.

## نتیجه‌گیری

در این مطالعه، به ارزیابی و مقایسه عملکرد دو رویکرد شبیه‌سازی هیدرولیکی، شامل مدل غیرخطی مبتنی بر معادلات سنت‌وانانت و مدل فضای حالت خطی، در ترکیب با الگوریتم یادگیری تقویتی گسسته برای کنترل هوشمند کانال‌های انتقال و توزیع آب پرداخته شد. کانال آزمایشی استاندارد شماره دو انجمن مهندسين عمران آمریکا با هشت بازه به عنوان مطالعه موردی انتخاب گردید و عملکرد سیستم در قالب شاخص‌های حداکثر و میانگین خطای مطلق، راندمان و کفایت مورد ارزیابی کمی قرار گرفت. مهم‌ترین یافته‌های این تحقیق به شرح زیر است: مدل غیرخطی توانست در تمام بازه‌های کانال عملکردی عالی، یکنواخت و پایدار ارائه دهد. حداکثر خطای مطلق و میانگین خطای مطلق این مدل به ترتیب به  $12/3\%$  درصد و  $8/9\%$  درصد محدود شد و شاخص‌های راندمان و کفایت به ترتیب با مقادیر حداقل  $0/962$  و  $0/972$  در طبقه «خوب» قرار گرفتند. در مقابل، مدل خطی در بازه‌های پایین‌دست با افت عملکرد مواجه شد؛ به طوری که حداکثر خطای مطلق در بازه هشتم به  $59\%$  درصد و راندمان به  $0/497$  (طبقه ضعیف) کاهش یافت.

اگرچه مدل خطی توانست کفایت را در سطح قابل قبول حفظ کند، این موفقیت با تحویل حجم قابل توجه آب اضافی همراه بود که منجر به کاهش راندمان در بازه‌های پایین‌دست گردید. اعتبار مدل خطی صرفاً در محدوده  $\pm 20\%$  تغییرات دبی حول نقطه کنترل معنا دارد. در بازه‌های پایین‌دست که تغییرات دبی آبگیرها از این محدوده فراتر می‌رود، دقت مدل خطی کاهش می‌یابد. اگرچه مدل خطی سرعت یادگیری بالاتری نسبت به مدل غیرخطی دارد، اما این مزیت نمی‌تواند افت دقت و کارایی را در بازه‌های پایین‌دست جبران کند. بنابراین، استفاده از مدل‌های غیرخطی برای کاربردهای یادگیری تقویتی در سیستم‌های کنترل کانال‌های آب مناسب‌تر است. با توجه به ضعف مدل‌های خطی با پارامترهای ثابت در شرایط جریان زیاد، توسعه مدل‌هایی که پارامترهای هیدرولیکی را به صورت برخط به‌روزرسانی می‌کنند، یک اولویت تحقیقاتی کلیدی است.

## فهرست نمادها

| نماد | توضیح          | نماد  | توضیح                      |
|------|----------------|-------|----------------------------|
| $A$  | سطح مقطع جریان | $r_k$ | پاداش دریافتی در تکرار $k$ |

| نماد       | توضیح                                            | نماد          | توضیح                                       |
|------------|--------------------------------------------------|---------------|---------------------------------------------|
| $A_{lm}$   | ماتریس دینامیک حالت در مدل فضای حالت خطی         | $R_i$         | قاعده‌ی فازی شماره $i$                      |
| $a_j$      | عمل گسسته‌ی شماره $j$ در هر قاعده‌ی فازی         | $S_0$         | شیب بستر کانال                              |
| $a_j^+$    | عمل دارای بیشترین احتمال در قاعده‌ی $i$          | $S_f$         | شیب خط انرژی کل                             |
| $a_k$      | عمل انتخابی در تکرار $k$                         | $S_k$         | حالت سیستم در تکرار $k$                     |
| $B_{lm}$   | ماتریس ورودی در مدل فضای حالت خطی                | $t$           | زمان نمونه‌برداری                           |
| $C_{lm}$   | ماتریس خروجی در مدل فضای حالت خطی (ماتریس همانی) | $T$           | کل زمان شبیه‌سازی                           |
| $dQ_{ij}$  | خطای تقریبی مقدار عمل $Q_{ij}$                   | $T$           | کل زمان شبیه‌سازی                           |
| $e(kt)$    | بردار اغتشاش (مانند آب تحویلی به آبیگرهای فرعی)  | $u(kt)$       | بردار ورودی شامل موقعیت دریچه‌ها            |
| $Fr$       | عدد فرود                                         | $V_j$         | بردار ستونی مقادیر $Q_{i,j}$ برای خروجی $j$ |
| $g$        | شتاب گرانش                                       | $w_k$         | ارزش عمل انتخابی $Q_{ij}^+$                 |
| $i$        | شمارنده قوانین فازی                              | $x$           | طول کانال                                   |
| $j$        | شمارنده خروجی‌ها/اعمال گسسته                     | $X_1, X_2$    | توابع عضویت فازی برای متغیر دبی آبیگر       |
| $k$        | شماره گام زمانی جاری یا شماره‌ی تکرار            | $x_{lm}(kt)$  | بردار حالت در مدل فضای حالت خطی             |
| $K_{lm}$   | ماتریس ضرایب در مدل فضای حالت خطی                | $y$           | عمق جریان                                   |
| $m$        | تعداد کل قوانین فازی یا تعداد آبیگرها            | $Y_s$         | نقطه‌ی تنظیم (هدف) عمق                      |
| $N$        | تعداد آبیگرها در هر بازه                         | $Y_t$         | عمق آب در زمان $t$                          |
| $n$        | تعداد کل خروجی‌های گسسته                         | $y_{lm}(kt)$  | بردار خروجی در مدل فضای حالت خطی            |
| $p_k(a_j)$ | احتمال انتخاب عمل $j$ در قاعده $i$ در تکرار $k$  | $y_{AICSS,i}$ | عمق آب حاصل از شبیه‌ساز غیرخطی AICSS        |
| $Pl_i$     | شماره بازه‌ی $i$                                 | $y_{SSM,i}$   | عمق آب پیش‌بینی‌شده توسط مدل فضای حالت خطی  |

| نماد       | توضیح                                                   | نماد                     | توضیح                                                 |
|------------|---------------------------------------------------------|--------------------------|-------------------------------------------------------|
| $Q$        | دبی جریان                                               | $\overline{y_{AICSS,t}}$ | میانگین عمق آب حاصل از شبیه‌ساز غیرخطی                |
| $Q_{i,j}$  | مقدار عمل $j$ در قاعده‌ی فازی $i$                       | $\overline{y_{SSM,t}}$   | میانگین عمق آب حاصل از شبیه‌ساز خطی                   |
| $Q_{ij}^+$ | درایه متناظر با عمل دارای بیشترین احتمال در قاعده‌ی $i$ | $\beta_k$                | نرخ یادگیری در تکرار $k$                              |
| $QT_i$     | دبی آبیگر $i$                                           | $\beta_d$                | ضریب کاهش نرخ یادگیری                                 |
| $QT_s$     | نقطه تنظیم (هدف) دبی                                    | $\delta_k$               | دمای الگوریتم در تکرار $k$                            |
| $QT_t$     | دبی تحویلی در زمان $t$                                  | $(X_i)\mu_i$             | درجه‌ی عضویت نرمال شده برای دبی آبیگر در قاعده‌ی $i$  |
| $r$        | تعداد دریچه‌های کنترل                                   | $(Pl_i)\mu_i$            | درجه‌ی عضویت نرمال شده برای شماره بازه در قاعده‌ی $i$ |

## References

- Arango JP, Duviella E, Etienne L, Langueh K, Segovia P, Puig V (2025) A Nonlinear State Feedback Tracking Controller for Open Channel Irrigation Systems IFAC-PapersOnLine 59:44-49 doi:<https://doi.org/10.1016/j.ifacol.2025.12.420>
- Clemmens AJ, Kacerek TF, Grawitz B, Schuurmans W (1998) Test cases for canal control algorithms J Irrig Drain Eng 124:23-30 doi:[https://doi.org/10.1061/\(ASCE\)0733-9437\(1998\)124:1\(23\)](https://doi.org/10.1061/(ASCE)0733-9437(1998)124:1(23))
- Conde G, Quijano N, Ocampo-Martinez C (2021) Modeling and control in open-channel irrigation systems: A review Annu Rev Control 51:153-171 doi:<https://doi.org/10.1016/j.arcontrol.2021.01.003>
- Deshays R, Segovia P, Duviella E (2021) Design of a MATLAB HEC-RAS Interface to Test Advanced Control Strategies on Water Systems Water 13:763 doi:<https://doi.org/10.3390/w13060763>
- Fatemeh O, Hesam G, Shahverdi K (2020) Comparing Fuzzy SARSA Learning (FSL) and Ant Colony Optimization (ACO) Algorithms in Water Delivery Scheduling under Water Shortage Conditions Irrigation and Drainage Engineering doi:[https://doi.org/10.1061/\(ASCE\)IR.1943-4774.0001496](https://doi.org/10.1061/(ASCE)IR.1943-4774.0001496)
- Henderson F (1966) Open channel flow, . Macmillan, New York,
- Ijaz N, Haider S, Muaaz M (2025) Development of a hydrodynamic model of the irrigation canal network by using HEC-RAS: a case study of Layyah Canal Division, Pakistan Modeling Earth Systems and Environment 11:195
- Kong L, Liu Y, Li J, Tian Y, Yang Q, Chen Z (2024) Nonlinear model predictive controller for gate control in open canal irrigation systems with flexible water demands Comput Electron Agric 222:109023 doi:<https://doi.org/10.1016/j.compag.2024.109023>



- Li X, Mao Z, Jia M, Liu W, Guan G, Luo Y (2025) Model predictive control based on an integrator delay coupled model applied to open canal irrigation systems *Journal of Hydroinformatics* 27:1390-1411 doi:<https://doi.org/10.2166/hydro.2025.037>
- Molden DJ, Gates TK (1990) Performance measures for evaluation of irrigation-water-delivery systems *J Irrig Drain Eng* 116:804-823 doi:[https://doi.org/10.1061/\(ASCE\)0733-9437\(1990\)116:6\(804\)](https://doi.org/10.1061/(ASCE)0733-9437(1990)116:6(804))
- Rahparast D, Hashemy Shahdany SM (2024) Spatiotemporal Assessment Model for Manual Operation Systems' Technical Performance in Surface Water Distribution Under Water Scarcity Scenarios *Water Resour Manag* 38:3639-3656 doi:<https://doi.org/10.1007/s11269-024-03832-w>
- Shahverdi K (2023) AICSS: Automatic simulator–controller/optimizer model of open channels *Irrigation and Drainage* 72:1124-1136 doi:<https://doi.org/10.1002/ird.2052>
- Shahverdi K, Loni R, Yoosefdoost I, Berndtsson R, Kaviani M, Yoosefdoost A (2026) Enhancing Operational Efficiency in Water Canals Using Sequential Fuzzy Reinforcement Learning *Water Resour Manag* 40:189 doi:<https://doi.org/10.1007/s11269-026-04543-3>
- Shahverdi K, Maestre J (2022) Gray Wolf Optimization for Scheduling Irrigation Water *J Irrig Drain Eng* 148:04022020 doi:[https://doi.org/10.1061/\(ASCE\)IR.1943-4774.0001688](https://doi.org/10.1061/(ASCE)IR.1943-4774.0001688)
- Shahverdi K, Maestre J, Alamiyan-Harandi F, Tian X (2020) Generalizing Fuzzy SARSA Learning for Real-Time Operation of Irrigation Canals *Water* 12:2407 doi:<https://doi.org/10.3390/w12092407>
- Sharifi H, Roozbahani A, Shahdany SMH (2021) Evaluating the Performance of Agricultural Water Distribution Systems Using FIS, ANN and ANFIS Intelligent Models *Water Resour Manag*:1-20 doi:<https://doi.org/10.1007/s11269-021-02810-w>
- Strelkoff T (1969) One-dimensional equations of open-channel flow *Journal of the Hydraulics Division* 95(3):861-876 doi:<https://doi.org/10.1061/JYCEAJ.00021>

## **Comparison of Discrete Reinforcement Learning Performance Integrated with Linear and Nonlinear Hydraulic Simulators for Canal Water Conveyance and Distribution Systems**

### **Introduction:**

Water management in conveyance and distribution canals is inherently challenging due to nonlinear hydraulic behavior, significant time delays between control actions and system responses, disturbances caused by variable and often sudden farmer off-takes, and uncertainties in hydraulic parameters. Accurate simulation of these systems is a prerequisite for designing intelligent controllers capable of maintaining stable water levels and ensuring fair water allocation. Two main categories of hydraulic simulators exist: fully nonlinear models based on the Saint-Venant equations, which provide high accuracy but require substantial computational resources, and simplified linear models, such as state-space representations, which offer faster computations at the cost of physical fidelity. Discrete reinforcement learning (RL) algorithms, particularly SARSA (State-Action-Reward-State-Action), have emerged as powerful tools for learning optimal control policies through interaction with an environment. However, a critical research gap persists: no prior study has quantitatively evaluated how the choice of hydraulic simulator (nonlinear vs. linear) affects the learning process, convergence speed, and final control policy quality of discrete

RL algorithms. This study addresses this gap by providing the first systematic comparison of RL performance integrated with both simulator types.

### **Purpose:**

The primary purpose of this research is to quantitatively compare the performance of discrete reinforcement learning (SARSA) when integrated with two distinct hydraulic simulators: (1) a fully nonlinear model based on the Saint-Venant equations (implemented in the AICSS software), and (2) a linear state-space model identified from input-output data of the nonlinear simulator. The comparison focuses on three key aspects: (a) prediction accuracy (error indices such as IAE and MAE), (b) control performance (efficiency and adequacy indices), and (c) learning speed (convergence rate). The study aims to answer the fundamental question: does the computational simplicity and higher speed of linear models justify their accuracy loss in discrete RL-based control of irrigation canals?

### **Research Method:**

The study was conducted on the ASCE (American Society of Civil Engineers) standardized Test Canal No. 2, which consists of eight consecutive pools, eight vertical sliding gates (with a pump at the final pool), and eight lateral off-takes. This configuration represents a typical irrigation canal with cascaded hydraulic interactions.

The nonlinear hydraulic behavior was simulated using the AICSS (Agricultural Irrigation Conveyance System Simulator) software, which solves the full one-dimensional Saint-Venant equations (continuity and momentum) to model both steady and unsteady flow conditions.

A linear state-space model was derived using a data-driven system identification approach. First, the nonlinear model was excited by applying step changes of +5%, +10%, and +20% to each gate position relative to its reference value. The resulting input (gate positions) and output (water depths) data were recorded. Second, this incremental data was imported into MATLAB's System Identification Toolbox to estimate the state-space matrices with a sampling time of 36 seconds. Validation was performed using Pseudo-Random Binary Sequence (PRBS) signals to ensure generalizability and avoid overfitting.

The SARSA algorithm was integrated with both simulators. The state vector was defined as  $S_i = [P_{li}, Q_{Ti}]$ , where  $P_{li}$  is the reach number and  $Q_{Ti}$  is the off-take discharge. Actions corresponded to gate position adjustments. The reward function was designed to penalize deviations from target water depths. Hyperparameters were systematically tuned: initial temperature of 0.0007 for the Softmax action selection, initial learning rate of 0.3 with a decay factor of 1.067, discount factor of 0.9, and 500 learning episodes with 8 independent runs.

Quantitative evaluation used Maximum Absolute Error (MAE), Integral Absolute Error (IAE), Efficiency and Adequacy indices, classified into "Good," "Moderate," and "Poor" categories based on established thresholds.

### **Results:**

The results clearly demonstrate the superior performance of the nonlinear simulator across all evaluation metrics.

The nonlinear model achieved remarkably low errors, with MAE and IAE limited to 12.3% and 8.9%, respectively, across all eight reaches. In contrast, the linear model exhibited an exponential error increase from upstream to downstream. In Reach 8, the linear model's MAE reached 59% and IAE reached 51%, both classified as "Poor." The nonlinear model produced errors smaller than the linear model in downstream reaches.

The nonlinear model achieved minimum efficiency of 0.962 and minimum adequacy of 0.972, both in the "Good" category, indicating precise water delivery without significant surplus or deficit. The linear model, while maintaining adequacy (adequacy up to 1.00), suffered a dramatic efficiency drop to 0.497 in Reach 8 ("Poor"), indicating substantial water wastage to compensate for modeling errors. A deep "gap" between efficiency and adequacy was observed for the linear model but not for the nonlinear model.

The linear model converged faster due to its simpler computational structure. However, this speed advantage did not translate into better control policies; instead, the linear model learned skewed policies that favored upstream off-takes while over-delivering to downstream ones.

Averaging Q-tables from 8 independent runs reduced operational phase errors significantly, lowering MAE from 21% (learning phase) to 10.7% (operational phase) for the nonlinear model.

### **Conclusion:**

This study provides definitive quantitative evidence that the choice of hydraulic simulator fundamentally determines the success of discrete reinforcement learning for irrigation canal control. The nonlinear Saint-Venant model consistently delivers high accuracy, stable performance, fair water distribution, and balanced efficiency-adequacy trade-offs across all canal reaches. The linear state-space model, despite its faster learning speed and acceptable performance within a  $\pm 20\%$  linearization range, suffers from inherent limitations: it cannot simulate key nonlinear phenomena such as flow-dependent energy losses, wave propagation delays, and flow interactions between adjacent pools. These limitations become critically pronounced in downstream reaches, where cumulative errors lead to inefficient control policies, excessive water wastage, and unfair distribution. The findings refute the notion that linear models' computational simplicity can compensate for their accuracy loss in RL-based control. For sustainable, efficient, and equitable water resource management in conveyance and distribution canals, nonlinear simulators are better choice. Future work should focus on developing adaptive, hybrid models that combine physical constraints with data-driven learning to maintain accuracy across wider operating ranges while preserving computational efficiency.

### **Funding**

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

### **Authorship contribution**

Conceptualization, methodology, software, validation, formal analysis, investigation, resources, data curation, writing—original draft preparation, writing—review and editing, visualization, supervision, project administration, funding acquisition; K.Sh. All authors have read and agreed to the published version of the manuscript.

### **Declaration of Generative AI and AI-assisted technologies in the writing process**

**Statement:** During the preparation of this work the author(s) used [Deepseek] in order to [wring]. After using this tool/service, the author(s) reviewed and edited the content as needed and take(s) full responsibility for the content of the publication.

#### *Data availability statement*

In this section, please provide details regarding where data supporting reported results can be  
Data available on request from the authors.

#### *Ethical considerations*

The authors avoided data fabrication, falsification, and plagiarism, and any form of misconduct.

#### *Acknowledgements*

The authors would like to thank anonymous referees for their constructive comments.

#### *Conflict of interest*

The authors declare no conflict of interest.

فیلد استادی