



مدیریت آب و آبیاری

دوره ۱۱ ■ شماره ۴ ■ زمستان ۱۴۰۰

صفحه‌های ۷۷۹-۷۶۹

DOI: 10.22059/jwim.2022.330434.919

مقاله پژوهشی:

ارزیابی استفاده از الگوهای تنظیم سازه‌های یک بازه کانال در سایر سازه‌های آن

کاظم شاهوردی*

استادیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران.

تاریخ پذیرش مقاله: ۱۴۰۰/۱۰/۱۶

تاریخ دریافت مقاله: ۱۴۰۰/۰۶/۱۹

چکیده

کنترل سازه‌های موجود در کانال‌های آبیاری جهت تحویل و توزیع دقیق آب و جلوگیری از اتلاف آن، نیازمند استفاده از تکنیک‌های کنترلی مناسب است. اخیراً، یادگیری تقویتی سارسا (Sarsa)، به‌عنوان یکی از شاخه‌های هوش مصنوعی، با هدف کنترل سازه‌ها و بهبود کفایت و راندمان تحویل و توزیع آب در کانال‌های آبیاری استفاده شده است. جهت افزایش کارایی این الگوریتم و کاهش زمان لازم برای یادگیری الگوهای بهره‌برداری، در این پژوهش، با توسعه الگوریتم سارسا در کانال EIRI از شبکه دز و تلفیق آن با مدل ICSS، یادگیری یک بازه از کانال با روش سارسا انجام شد و الگوهای بهره‌برداری در سایر بازه‌ها با به‌کارگیری نتایج یادگیری استخراج و ارزیابی شد. یادگیری مدل مذکور با تعریف سناریوهای مختلف بهره‌برداری انجام شد و نتایج با استفاده از شاخص‌های استاندارد ارزیابی عملکرد، مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل ارائه‌شده با موفقیت قابل استفاده در کانال مذکور می‌باشد. به‌طوری‌که در مرحله یادگیری، تغییرات عمق در محدوده مجاز پنج درصد و در مرحله استفاده از نتایج یادگیری، در محدوده مجاز ۱۰ درصد قرار می‌گیرد. شاخص‌های کفایت و راندمان نیز نزدیک به مقدار مطلوب می‌باشند.

کلیدواژه‌ها: سازه‌های تنظیم، کانال آبیاری، مدیریت آب، یادگیری تقویتی.

Evaluating utilization of structures' settings of one reach in the others

Kazem Shahverdi*

Assistant Professor, Department of Water Science Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran.

Received: September, 10, 2021

Accepted: January, 06, 2022

Abstract

Controlling structures in irrigation canals to accurately deliver and distribute the water, and to keep it needs the appropriate control techniques. Sarsa reinforcement learning, as a branch of artificial intelligence, has recently been used to control the structures and improve water delivery and distribution in irrigation canals. To improve Sarsa efficiency and reduce the required time of operational pattern learning, the Sarsa algorithm in EIR1 canal was developed and linked to a non-linear model of the canal to learn the operational pattern of one reach of the canal and apply the results to the other reaches. Operational scenarios were defined in this regard, and standard performance indicators was used for assessment. The results showed that Sarsa can be used successfully with the proposed idea, maintaining water depth within a dead band of 5 percent in the learning step and that of 10 percent while utilizing the learning results. The efficiency and adequacy indicators were close to the desired value.

Keywords: Irrigation Canals, Reinforcement Learning, Regulating Structures, Water Management.

مقدمه

روش‌های مختلف آبیاری شامل الف- روش گردشی^۱ با انعطاف‌پذیری و کارایی پایین، ب- روش برحسب تمایل^۲ با انعطاف‌پذیری و کارایی بالا و ج- روش برحسب درخواست^۳ می‌باشد. روش برحسب درخواست، از نظر انعطاف‌پذیری و کارایی در حالت بینابین دو روش دیگر قرار دارد که در کشور کم‌آبی مانند ایران قابلیت کاربرد دارد (Clemmens, 1987). در این روش، دبی، دور و زمان آبیاری با توافق زارعین یا نماینده آن‌ها با مدیر شبکه تعیین می‌شود که تنوع زیادی در آن وجود دارد. نحوه تعیین دستورالعمل‌های آبیاری با توجه به تعداد سازه‌ها، تعداد زیاد نقطه تحویل آب، تنوع درخواست‌های زارعین و پیچیدگی‌های جریان در کانال‌های آبیاری، از چالش‌های اصلی این روش است.

یک دسته‌بندی جامعی از روش‌های مختلف تحویل و توزیع برحسب درخواست در شبکه‌های آبیاری با جمع‌آوری اطلاعات چندین شبکه داخلی شامل قزوین، عقیلی، گرمسار و خارجی شامل المودوار^۴ در اسپانیا، ولتون موهاک^۵ و کالیفرنیا در آمریکا صورت گرفت. یافته‌ها نشان داد که عوامل مهم در شکل‌گیری روش‌های مختلف برحسب درخواست، ثابت یا متغیر بودن عوامل و دامنه نوسان آنها، فاصله زمانی درخواست تا تحویل و فرد تصمیم‌گیرنده (مدیر شبکه آبیاری یا مسئول تحویل و توزیع) می‌باشد. همه این عوامل باعث می‌شود تا فرد تصمیم‌گیرنده از روش‌ها و تکنیک‌های مختلفی جهت اتخاذ تصمیم مناسب بهره‌گیرد (Savari & Monem, 2021). مدل‌ها و راه‌کارهای مختلفی در این راستا ارائه شده است که هرکدام به‌نوبه خود دارای مزایا و معایبی می‌باشند. برخی از این مدل‌ها فقط قابلیت کاربرد در یک روش بهره‌برداری مانند گردشی، برحسب درخواست و برحسب تمایل را دارند و برخی دیگر تنوع و گستردگی

کاربرد زیادتری دارند. در یک تقسیم‌بندی کلی، این مدل‌ها شامل مدل‌های بهینه‌سازی، مدل‌های کنترلی و مدل‌های مبتنی بر هوش مصنوعی هستند.

از مدل‌های بهینه‌سازی می‌توان به برنامه‌ریزی صفر-یک (Wang et al., 1995)، تابه‌کاری فلزات (Monem & Namdarian, 2005) و الگوریتم جامعه مورچگان (Fatemeh et al., 2020) اشاره کرد و به‌کارگیری از آن‌ها در کانال‌های آبیاری هم‌چنان ادامه دارد. در مطالعه Lord et al. (2021)، روشی برای کمینه‌کردن تلفات بهره‌برداری و نشت در کانال‌های آبیاری با استفاده از الگوریتم جامعه مورچگان ارائه شده است. نتایج آن نشان داده است که مدل ارائه‌شده، توانایی بهبود بهره‌وری آب در سیستم‌های بهره‌برداری دستی را دارد. در پژوهش Fatemeh et al. (2020)، بهره‌برداری دستی کانال‌ها در روش برحسب درخواست با استفاده از الگوریتم جامعه مورچگان مورد توجه قرار گرفته است. نتایج نشان داده است که مدل پیشنهاد شده قابلیت ارائه برنامه بهره‌برداری را حتی در شرایط کمبودهای زیاد آب دارد.

مدل‌های کنترلی مختلفی در شبکه‌های آبیاری استفاده شده است. یکی از بهترین و ساده‌ترین مدل‌ها، مدل PID^۶ یعنی مدل انتگرالی تناسبی مشتقی است که ورژن‌های مختلف آن مورد استفاده قرار گرفته است. در پژوهش Arauz et al. (2020)، کنترلر PI با استفاده از روش LMI^۷ طراحی و در کانال استاندارد شماره یک انجمن مهندسان آمریکا به‌کار گرفته شد. مدل MPC^۸ یا مدل کنترل پیش‌بین، یکی دیگر از کنترلرهایی است که در صنعت به‌وفور مورد استفاده قرار گرفته است. استفاده از این مدل در کانال‌های آبیاری نیز سابقه طولانی دارد و از جمله این پژوهش‌ها می‌توان Van Overloop (2006) و Wagemaker (2005) را نام برد. از نمونه دیگر استفاده از این مدل در کانال‌های آبیاری می‌توان Hashemy et al.

اساسی‌ترین مشکلات بود. نتایج بررسی‌ها نشان داد که یادگیری هم‌زمان دستورالعمل بهره‌برداری همه بازه‌های کانال آبیاری، که در بخش تالی مجموعه فازی قرار می‌گیرند، به علت تعداد زیاد قواعد و تابع عضویت فازی مورد استفاده در آن، عملاً بسیار دشوار می‌باشد. از این‌رو، یادگیری بازه‌ای مورد توجه قرار گرفت. بدین معنی که برای هر کدام از بازه‌ها الگوهای بهره‌برداری به صورت مجزا یادگیری شود. با این‌حال، زمان مورد نیاز برای یادگیری هم‌چنان قابل توجه بود. بنابراین، پژوهش بر روی نحوه یادگیری برای کاهش مدت زمان و استفاده مطلوب در کانال‌های آبیاری ضروری می‌باشد.

در این پژوهش، در نظر است تا در یک کانال با عمق هدف یکسان در همه بازه‌ها، یادگیری الگوریتم سارسا برای کنترل سازه‌ها و استخراج الگوهای بهره‌برداری برای یک بازه انجام شود و سپس با استفاده از نتایج به دست آمده از یادگیری در قالب ماتریس Q که ارزش عمل‌های انجام شده در آن ذخیره می‌شود، الگوهای بهره‌برداری سایر بازه‌ها در همان کانال و بدون نیاز به یادگیری مجدد، استخراج و ارزیابی شود. کانال EIR1 از شبکه دز با توجه به یکسان بودن عمق هدف در همه بازه‌ها، مورد استفاده قرار گرفت.

مواد و روش‌ها

یادگیری تقویتی سارسا

در روش یادگیری تقویتی سارسا، اصل یادگیری مبتنی بر تعامل بین یک عامل^{۱۱} با محیط تحت عمل^{۱۱} است که از این پس محیط نامیده می‌شود. این تعامل به صورت تکراری و متوالی ادامه می‌یابد. در هر تکرار، عامل حالت^{۱۲} یا وضعیت محیط را مشاهده می‌کند و عملی را انتخاب^{۱۳} می‌کند. عمل انتخاب شده، در محیط اعمال می‌شود که در نتیجه آن، محیط به حالت بعدی می‌رود و

(2013) Hashemy & Van Overloop و Van Overloop et al. (2015) را نام برد که در هر کدام از آن‌ها اهداف مختلفی با هدف بهبود تحویل و توزیع آب دنبال شده است. به عنوان مثال در پژوهش Hashemy et al. (2013)، مدل کنترل پیش‌بین در کانال آبیاری دز با استراتژی استفاده از ذخیره آب در داخل کانال استفاده شد. ذخیره آب در داخل کانال منجر به کاهش زمان تأخیر رسیدن موج افزایشی یا کاهشی مورد نظر به محل سازه‌ها می‌شود. نتایج حاصل از به کارگیری مدل، بیانگر عملکرد موفقیت‌آمیز آن می‌باشد. کنترلر فازی، نمونه دیگری از کنترلرهاست که در شبکه‌های آبیاری استفاده شده است (Durdu, 2010; Gopakumar & Mujumdar, 2009).

پژوهش‌های زیادی در زمینه هوش مصنوعی در صنعت انجام شده است و به تازگی الگوریتم یادگیری تقویتی^۹، به عنوان یکی از شاخه‌های پرکاربرد هوش مصنوعی، برای بهبود تحویل و توزیع آب در کانال‌های آبیاری نیز فرموله شده و مورد مطالعه قرار گرفته است (Shahverdi et al., 2016). مطالعات مربوط به آن در کانال‌های آبیاری هم‌چنان در حال انجام می‌باشد. در پژوهش بالا، همگرایی روش یادگیری سارسا در رسیدن به هدف در کانال‌های آبیاری بررسی شد. در کانال عقیلی شرقی در بهره‌برداری سنتی، ورودی آب به کانال افزایش/کاهش می‌یابد و یک موج ناشی از این افزایش/کاهش شروع به حرکت می‌کند. با رسیدن موج به محل هر سازه، بهره‌بردار تنظیمات آن را جهت تحویل آب انجام می‌دهد. مدت زمانی که طول می‌کشد تا اثرات موج به انتهای کانال برسد حدود ۲۳ ساعت می‌باشد. با استفاده از الگوریتم یادگیری تقویتی، این زمان به حدود ۵/۵ ساعت کاهش یافت (Shahverdi et al., 2016). با این حال، فرموله کردن آن برای کانال آبیاری و مدت زمان مورد نیاز برای یادگیری الگوهای بهره‌برداری، از

R_i : If x_1 is L_{i1} and ... and x_n is L_{in} , then $(\alpha_{i1}$ with value Q^{i1}) or ... or $(\alpha_{im}$ with value Q^{im}) (1)

که در آن بردار $s = x_1 \times \dots \times x_n$ بعدی متغیرهای وضعیت ورودی، $L_i = L_{i1} \times \dots \times L_{in}$ شامل n مجموعه فازی با مرکزهای یکتا برای i امین قانون، m تعداد عمل‌های گسسته برای هر قانون، α_{ij} زامین کنش کاندید در قانون i ام و Q_{ij} مقدار ارزش تقریب‌زده شده برای عمل یا کنش j ام در قانون i ام است. ماتریس Q ، یک ماتریس $R \times m$ بعدی است که ارزش عمل‌های انجام‌شده در آن ذخیره می‌شود (رابطه ۲).

$$Q = \begin{bmatrix} Q^{11} & \dots & Q^{1m} \\ \vdots & Q^{ij} & \vdots \\ Q^{R1} & \dots & Q^{Rm} \end{bmatrix} \quad (2)$$

$$i = 1 \dots R, \quad j = 1 \dots m$$

با داشتن سیستم قواعد فازی و ماتریس Q و با فرض این‌که سیستم در حالت s_t قرار دارد، مراحل ارائه‌شده شکل (۱) انجام می‌شود تا این‌که یادگیری صورت بگیرد.

براساس دو حالت متوالی، پاداشی^{۱۴} را به عامل و عمل انتخاب‌شده می‌دهد. این فرایند در تکرارهای مختلف ادامه می‌یابد و عمل‌های بهتر با دریافت پاداش‌های زیاد، ارزش^{۱۵} بیش‌تری پیدا می‌کنند و مدل همگرا می‌شود.

در این پژوهش و برای کانال آبیاری EIRI، سازه آب‌بند در نقش عامل، میزان بازشدگی آب‌بند در نقش عمل، شرایط هیدرولیکی کانال به‌عنوان محیط، دبی عبوری از آب‌بند در نقش حالت می‌باشد. تابع پاداش نیز براساس میزان خطای سطح آب از سطح هدف و میزان خطای دبی مورد نیاز آبیگرها و دبی تحویل‌شده، تعریف می‌شود. محیط یا شرایط هیدرولیکی کانال نیز با استفاده از مدل غیرخطی توسعه‌یافته براساس معادلات سنت و نانت شبیه‌سازی شده و اطلاعات آن در اختیار عامل قرار داده می‌شود.

یک سیستم فازی تاکاگی- سوگنو و کانگ مرتبه صفر (معادله ۱) را در نظر بگیرید:




Figure 1. The steps of Sarsa reinforcement learning in irrigation canals formulated in this research.

بازه از کانال (که بازه اول می‌باشد) انجام می‌شود، مدل ریاضی بازه مذکور تهیه شد. بازشدگی دریاچه آب‌بند به‌عنوان خروجی یادگیر می‌باشد. به‌طور عمده ورودی که در پژوهش‌های قبلی در یادگیر مورد توجه قرار گرفته است، دبی و عمق آب می‌باشد که در این کانال عمق هدف در همه بازه‌ها ثابت است، بنابراین از لیست متغیرهای ورودی حذف شد. دبی عبوری از آب‌بند تابع مساحت روزنه زیر دریاچه کشویی، ضریب دبی و ارتفاع آب می‌باشد. در بازه‌های مختلف کانال، عرض دریاچه تغییر می‌کند در نتیجه باید عرض دریاچه به‌همراه دبی به‌عنوان متغیر ورودی قرار گیرند که منجر به کُندشدن یادگیری و بزرگ‌شدن فضای مسأله خواهد شد. به همین منظور، نسبت دبی عبوری از دریاچه به عرض آن به‌عنوان متغیر ورودی انتخاب شد. با توجه به توضیحات فوق، الگوریتم یادگیری سارسا توسعه یافت و سپس اجرا شد و ماتریس Q به‌عنوان خروجی نهایی این مرحله استخراج شد.

استخراج الگوهای بهره‌برداری سایر بازه‌ها با استفاده از نتایج یادگیری بازه اول

پس از اتمام یادگیری، مهم‌ترین خروجی آن ماتریس Q است. با استفاده از این ماتریس و روش انتخاب عمل حریصانه، مقدار بازشدگی دریاچه برای هر مقدار از دبی ورودی در هر بازه‌ای را می‌توان استخراج کرد. رابطه انتخاب عمل حریصانه به‌صورت معادله (۳) می‌باشد:

$$a(s) = \operatorname{argmax}_b Q(s) \quad (3)$$

که در آن argmax_b نشان‌دهنده عمل با حداکثر ارزش در ماتریس Q است. با انتقال این خروجی‌ها به مدل شبیه‌ساز، می‌توان جریان در کانال را تحت سناریوی مورد بررسی، شبیه‌سازی کرد که برنامه آن نیز در متلب تهیه شد.

که در آن، $p(a_{ij})$ احتمال انتخاب عمل کاندیدشده z در قاعده i ، μ_i شدت آتش قاعده (درجه تطابق، درجه آتش یا وزن هر قاعده) Q^{ii} ارزش عمل کاندیدشده z در قاعده i ، δ پارامتر دما، k شماره تکرار، t^+ عمل انتخاب‌شده، β نرخ یادگیری، γ فاکتور تخفیف، \mathcal{Y}_i عمق در گام زمانی t ، \mathcal{Y}_{target} عمق هدف، r_k پاداش در تکرار k ، ΔQ_t جمع خطاهای دبی تحویلی از دبی درخواست‌شده و ΔQ_t کل زمان شبیه‌سازی است.

پارامتر دما، تعادل بین اکتشاف و انتفاع را در الگوریتم انجام می‌دهد. در شروع یادگیری مقدار آن زیاد بوده و باعث می‌شود که به‌طور عمده الگوریتم به دنبال اکتشاف عمل‌های مناسب باشد. در طول یادگیری و با افزایش تکرارها، مقدار آن با ضریب 0.991 کاهش می‌یابد. نرخ یادگیری، سرعت یادگیری الگوریتم را نشان می‌دهد و با افزایش تکرارها مقدار آن با ضریب $\frac{1}{1.017}$ کاهش می‌یابد. زمانی که مقدار نرخ یادگیری برابر با صفر باشد، یادگیری الگوریتم صفر می‌شود و عملاً یادگیری پایان می‌یابد.

تابع پاداش نقش مهمی در هدایت الگوریتم دارد. از آنجاکه در کانال‌های آبیاری یک محدوده‌ای برای تثبیت عمق در نظر گرفته می‌شود (در این پژوهش ± 5 درصد در نظر گرفته شده است)، مبنای پاداش نیز این محدوده در نظر گرفته شد. در صورتی که عمق آب در طول زمان شبیه‌سازی داخل این محدوده باشد، خطاهای دبی جمع شده و مقدار عددی پاداش براساس آن محاسبه می‌شود. در صورتی که عمق آب از محدوده عمق هدف خارج شود، براساس میزان انحراف، پاداش منفی (جریمه) برای عمل انجام‌شده منظور خواهد شد.

استخراج الگوهای بهره‌برداری بازه اول با استفاده از یادگیری

با توجه به این که در این پژوهش، یادگیری فقط برای یک

شده و نتایج آن استخراج و با شاخص‌های ارزیابی، مورد ارزیابی قرار می‌گیرد.

کانال مورد مطالعه

برای آزمون گزینه‌های بهره‌برداری، قسمتی از کانال EIR1 در شبکه آبیاری دز استفاده شد. این کانال یک کانال بتنی با مقطع دوزنقه‌ای است. حداکثر ظرفیت کانال ۲/۷۴ مترمکعب بر ثانیه است که از طریق شش آبگیر ثقلی با دریچه‌های کشویی مستطیلی در مسیری به طول ۲۸۳۰/۵ متر آب مورد نیاز را تأمین می‌کند. شیب کانال در طول مسیر متفاوت و حداقل ۰/۰۰۱۲ و حداکثر ۰/۰۱۲ است. عرض کف از ابتدای کانال تا فاصله ۱۰۰۳ متری معادل ۱/۵ متر و ازین نقطه تا محل آخرین آبگیر در فاصله ۲۸۳۰/۵ متری معادل یک متر است. شیب جانبی کانال در تمامی مسیر (1V:1.5H) طراحی شده است. متوسط ضریب زبری مانینگ در طول مسیر ۰/۰۱۷ گزارش شده است. این بخش از کانال دارای شش سازه آبگیر، سه سازه تنظیم‌کننده در بالادست هر زوج آبگیر، دو حوضچه آرامش در پایین‌دست سازه‌های تنظیم‌کننده و یک سیفون می‌باشد (شکل ۲).

سناریوهای بهره‌برداری و شاخص‌های ارزیابی

برای بررسی عملکرد یادگیری سارسا، گزینه‌های مختلف بهره‌برداری، براساس الگوهای پیاده‌شده در بهره‌برداری واقعی از کانال EIR1، تعریف شد (جدول ۱).

مدل غیرخطی شبیه‌سازی کانال

مدل هیدرودینامیکی ICSS در سال ۱۹۸۵ توسط مانز تهیه شد، این مدل قادر به شبیه‌سازی سیستم‌های انتقال و توزیع آب با تغییرات زمانی جریان ورودی و خروجی از لحاظ هیدرولیکی و هیدرولوژیکی، شبیه‌سازی جریان‌های ماندگار و غیرماندگار تدریجی یک‌بعدی در شبکه‌های آبیاری با انواع مختلف مقطع کانال همراه با طیف قابل‌توجهی از سازه‌ها توأم با جریان‌های گسترده ورودی و خروجی است. ICSS دارای یک هسته مرکزی است که معادلات جریان‌های غیرماندگار را در شبکه‌های آبیاری حل می‌کند و شرایط مرزی و سازه‌های مختلف به‌صورت زیربرنامه‌هایی با آن تلفیق می‌شوند. از ویژگی‌های بارز این مدل دسترسی به متن برنامه مدل است که به زبان فرترن می‌باشد (Manz & Schaalje, 1992).

در این پژوهش، مدل شبیه‌ساز در دو مرحله مورد استفاده قرار گرفته است. در مرحله اول، در طول فرایند یادگیری است که مقدار بازشدگی را از یادگیر به‌عنوان ورودی دریافت می‌کند و با شبیه‌سازی کانال، مقادیر عمق و دبی را در طول زمان شبیه‌سازی تولید می‌کند و به یادگیر می‌دهد. یادگیر نیز با استفاده از این مقادیر، مقدار پاداش را محاسبه می‌کند. در مرحله دوم و پس از اتمام یادگیری، برای هر سناریوی بهره‌برداری مقدار بازشدگی با توجه به جدول Q مطابق با آنچه که تشریح شد، استخراج شده و سپس با ورود این اطلاعات به مدل شبیه‌ساز، کانال تحت سناریوی موردبررسی شبیه‌سازی




Figure 2. The schematic view of EIR1 canal

آبگیرها، QR دبی مورد نیاز یا دبی درخواست شده در آبگیر M، QD دبی واقعی تحویل شده به آبگیر M و N تعداد گام‌های زمانی مناسب در یک دوره تحویل است. مقدار مطلوب این شاخص‌ها برابر با یک می‌باشد.

شاخص خطای حداکثر مطلق (MAE) برای اندازه‌گیری حداکثر انحراف سطح آب از عمق هدف ارائه شده است که به صورت رابطه (۶) تعریف می‌شود:

$$MAE = \frac{\max(|y_{target} - y|)}{y_{target}} \quad (6)$$

این شاخص منعکس‌کننده حداکثر انحرافی است که مدل در ثابت نگه داشتن سطح آب در عمق هدف داشته است و هرچه مقدار آن کمتر باشد نشان‌دهنده عملکرد مطمئن‌تر سیستم در کنترل سطح آب است. شاخص خطای مطلق تجمعی (IAE) نشان‌دهنده میانگین انحرافات عمق آب از عمق هدف در طول دوره بهره‌برداری می‌باشد و به صورت رابطه (۷) تعریف می‌شود:

$$IAE = \frac{\sum_{t=0}^T (|y_{target} - y_t|)}{y_{target}} \quad (7)$$

هرچه مقدار این شاخص کمتر باشد نشان‌دهنده عملکرد مطمئن‌تر سیستم در کنترل سطح آب است.

Table 1. Scenarios defined in the learning step

	inflow	turnout 1	turnout 2	Flow under check gate 1
Sn. 1	1.000	0.100	0.150	0.75
Sn. 2	1.000	0.100	0.100	0.8
Sn. 3	1.000	0.050	0.100	0.85
Sn. 4	1.000	0.050	0.050	0.9
Sn. 5	1.000	0.025	0.025	0.95
Sn. 6	1.100	0.025	0.025	1.05
Sn. 7	1.175	0.050	0.025	1.1
Sn. 8	1.300	0.100	0.050	1.15

انتخاب دبی‌ها طوری انجام شد که تمامی حالت‌های ممکن در طول یادگیری مورد بررسی قرار گیرند. در عمل می‌توان بی‌نهایت حالت تعریف کرد، اما پیاده‌سازی همه حالت‌ها در مدل سارسا امکان‌پذیر نمی‌باشد. حالت‌هایی که بینابین مقادیر مندرج در جدول قرار می‌گیرند، توسط مدل سارسا تخمین زده می‌شوند که این یکی از مزایای یادگیرنده‌ها می‌باشد. جهت بررسی دقت استفاده از نتایج یادگیری، دو سناریوی حدی شامل حد بالا و حد پایین تعریف شد (جدول ۲). مفهوم حد بالا و حد پایین این است که کلیه مقادیر که در مرحله یادگیری استفاده شده‌اند در بین این دو حد قرار دارند. توجه شود که با توجه به کمبود منابع آب، حداکثر دبی در این کانال جریان نمی‌یابد.

برای ارزیابی عملکرد توزیع و تحویل آب از شاخص‌های کفایت^{۱۶} و راندمان^{۱۷} تحویل آب (Molden & Gates, 1990) و برای ارزیابی کنترل سطح آب شاخص‌های خطای حداکثر مطلق^{۱۸} (MAE) و خطای مطلق تجمعی^{۱۹} (IAE) ارائه شده توسط ASCE استفاده شد (Clemmens et al., 1998). شاخص‌های کفایت و راندمان تحویل به صورت روابط (۴) و (۵) تعریف می‌شوند:

$$MPA = \frac{1}{N} \sum_N \frac{1}{M} \sum_M (PA), \quad \begin{cases} PA = \frac{QD}{QR} & \text{IF } QR > QD \\ PA = 1 & \text{IF } 1 < \frac{QD}{QR} \end{cases} \quad (4)$$

$$MPE = \frac{1}{N} \sum_N \frac{1}{M} \sum_M (PE), \quad \begin{cases} PE = \frac{QR}{QD} & \text{IF } QR < QD \\ PE = 1 & \text{IF } \frac{QR}{QD} > 1 \end{cases} \quad (5)$$

در روابط فوق^{۲۱} MPA و^{۲۲} MPE به ترتیب شاخص‌های متوسط کفایت تحویل و راندمان تحویل می‌باشد. M تعداد

Table 2. Scenarios defined in investigating the learning results exploitation

	Inflow	Turnout 1	Turnout 2	Flow under check gate1	Turnout 3	Turnout 4	Flow under check gate2	Turnout 5	Turnout 6	Flow under check gate3
Lower limit	1.000	0.100	0.150	0.75	0.025	0.025	0.700	0.000	0	0.70
Upper limit	1.300	0.100	0.050	1.15	0.05	0.050	1.050	0.100	0.050	0.90

نتایج و بحث

ارزیابی الگوهای یادگیری شده

در شکل (۳)، روند کاهش پارامتر دما در طول یادگیری ارائه شده است که بیانگر همگرایی آن در ۱۰۰ تکرار می‌باشد. در تکرارهای پایین (کمتر از ۴۰) به‌طور عمده، انتخاب عمل طوری بوده که کلیه فضای مسأله جستجو شود. در ادامه، هم‌زمان با جستجوی فضای مسأله از نتایج جستجوهای قبلی که در ماتریس Q ذخیره شده نیز استفاده شده است. در پایان یادگیری، انتخاب عمل فقط بر مبنای شایستگی بوده و برای هر حالتی، عمل‌های با حداکثر ارزش در ماتریس Q انتخاب می‌شوند.




Figure 3. Temperature variations during the learning

هشت با توجه به شکل (۴)، برای یک لحظه خیلی کوچک عمق از محدوده مجاز خارج شده است که علت آن در روش انتخاب عمل بر مبنای میانگین‌گیری وزنی در روش سارسا است. بروز چنین حالت‌هایی در روش یادگیر سارسا، یک شکست محسوب می‌شود و الگوریتم تلاش می‌کند که تعداد شکست‌ها را حداقل کند. بر مبنای نتایج این پژوهش، کمتر از پنج درصد مواقع در الگوریتم شکست مشاهده شد. ذکر این نکته ضروری است که از دیدگاه بهره‌برداری کانال‌های آبیاری، محدوده مجاز ± 5 درصد محدوده کوچک و بسیار دقیقی است و در سناریوی هشت حداکثر خطای عمق $6/4$ درصد بوده و فقط $1/4$ درصد از محدوده خارج شده است.

Table 3. The results of performance indicators in the learning step

Scenario	Flow under check gates (m ³ /s)	MAE (%)	IAE (%)	MPA	MPE
Sn. 1	0.75	2.2	1.2	0.994	0.986
Sn. 2	0.80	1.9	0.8	0.994	0.991
Sn. 3	0.85	4.4	3.8	0.986	1.000
Sn. 4	0.90	1.3	0.6	0.996	0.994
Sn. 5	0.95	1.3	0.9	0.996	0.903
Sn. 6	1.05	4.5	2.6	0.988	1.000
Sn. 7	1.10	4.7	2.5	0.964	1.000
Sn. 8	1.15	6.4	3.2	0.981	0.996

نتایج تغییرات عمق در شکل (۴) نشانگر محدوده تغییرات عمق آب در بالادست آب‌بند در مدت زمان شبیه‌سازی است که داخل محدوده مجاز بالا و پایین ترسیم شده قرار دارد. عمق هدف در بالادست تمامی آب‌بندها برابر با $1/2$ متر است. تغییرات در ابتدا سرعت زیادی داشته و سپس به‌صورت تدریجی انجام می‌شود. در مقایسه با روش‌های کنترل خودکار که با تغییرات متوالی بازشدگی دریاچه سعی در رساندن عمق آب به عمق هدف دارد، در این روش تنظیم سازه‌ها فقط یکبار و توسط بهره‌بردار انجام می‌شود در نتیجه هزینه‌های به مراتب کمتری، نسبت به روش‌های کنترل خودکار دارد. شاخص

در جدول (۳)، نتایج شاخص‌های ارزیابی برای سناریوهای مورد بررسی در مرحله یادگیری، ارائه شده است. دبی تحویلی به آبگیرها، که از نوع دریاچه‌ای می‌باشند، تابع عمق آب در کانال و میزان بازشدگی دریاچه آبگیرها می‌باشد. اگر عمق آب در بالادست آب‌بند در طول بهره‌برداری ثابت باشد مقدار دبی عبوری از آبگیر فقط تابع بازشدگی آن خواهد بود. در این پژوهش، مقدار بازشدگی آبگیرها با استفاده از رابطه روزنه محاسبه شد. با توجه به این‌که محدوده مجاز تغییرات عمق در این پژوهش ± 5 درصد است، حداکثر تغییرات عمق در همه سناریوها به‌جز سناریوی هشت داخل محدوده مجاز می‌باشد. در سناریوی

ارزیابی استفاده از الگوهای تنظیم سازه‌های یک بازه کانال در سایر سازه‌های آن

تحویل آب در آبگیرها، دقت بالایی بوده و مقادیر شاخص‌ها، نزدیک به مقدار مطلوب می‌باشد. منحنی‌های عمق در بالادست آب‌بندها در این حالت نشان می‌دهد که در ابتدا مقدار تغییرات عمق زیاد بوده و سپس تغییرات به صورت تدریجی می‌باشد، به طوری که میانگین تغییرات عمق حداکثر حدود ۱۰ درصد می‌باشد.

Table 4. The results of performance indicators based on the Q matrix

Scenario	Flow	MAE (%)	IAE (%)	MPA	MPE
Lower limit	check gate1	2.3	0.9	0.990	0.998
	check gate2	7.0	5.5	0.985	0.999
	check gate3	9.1	6.3	0.947	0.999
Upper limit	check gate1	4.6	3.3	0.998	0.991
	check gate2	11.3	10.2	1.000	1.000
	check gate3	5.2	4.2	0.995	0.999




Figure 5. Water depth variations upstream of the check structure 1 based on the Q matrix.

نتایج نشان داد که یادگیری هر سناریو برای یک آب‌بند حدود یک ساعت زمان می‌برد. در صورتی که تعداد سناریوهای (تعداد درخواست‌های زارعین)، برای استخراج الگوی بهره‌برداری مربوط به همه سناریوها، باید تعداد سناریوها را در تعداد دریچه‌های آب‌بند و در یک ساعت ضرب کرد که در یک فصل زراعی با تعداد زیاد سناریوها و آب‌بندها، مدت زمان زیادی برای استخراج الگوی بهره‌برداری نیاز خواهد بود. در این پژوهش، حدود هشت ساعت زمان نیاز بود که الگوهای سناریوهای مورد بررسی برای آب‌بند یک استخراج شود. برای افزایش دقت یادگیری پنج بار تکرار شد. نتایج استفاده از یادگیری الگوهای مربوط به بازه یک در سایر بازه‌ها

IAE بین ۰/۶ تا ۳/۸ درصد به دست آمده است که نشان می‌دهد میانگین انحراف عمق آب از عمق هدف، درصد قابل توجهی نمی‌باشد. با این حال، شاخص‌های کفایت و راندمان نشان می‌دهد که دقت تحویل آب نیز، دقت بالایی است به طوری که حداقل مقدار شاخص‌های کفایت و راندمان به ترتیب برابر با ۰/۹۶۴ در سناریوی هفت و ۰/۹۰۳ در سناریوی پنج است. در عمده موارد، مقادیر این شاخص‌ها بسیار نزدیک به مقدار مطلوب می‌باشد.




Figure 4. Water depth variations upstream of the check structure 1 during the learning

ارزیابی الگوهای استخراج شده بدون یادگیری

پس از انجام یادگیری و ارزیابی نتایج که نشانگر دقت بالای یادگیری می‌باشد، در مرحله بعد با استفاده از ماتریس Q که حاصل مرحله یادگیری است الگوهای بهره‌برداری بدون نیاز به یادگیری مجدد، برای آب‌بندهای دو و سه، با تعریف دو سناریوی حدی استخراج شد که در جدول (۴)، شاخص‌های ارزیابی ارائه شده است. برای این منظور از روش انتخاب عمل حریصانه استفاده شد که در هر حالت، عملی را انتخاب می‌کند که بیشترین مقدار ارزش متناظر را در ماتریس Q داشته باشد. برای آب‌بند یک در هر دو حالت، تغییرات عمق داخل محدوده مجاز بوده است که با توجه به نتایج مرحله یادگیری، قابل انتظار بود. در مورد آب‌بندهای دو و سه، عمق آب از محدوده مجاز پنج درصد خارج شده است (شکل ۵) و تقریباً در محدوده ۱۰ درصد قرار دارد و با ملاحظه شاخص‌های کفایت و راندمان می‌توان دریافت که دقت

مقدار مطلوب می‌باشد. استفاده از نتایج یادگیری بازه یک در سایر بازه‌ها نیز نشانگر عملکرد قابل قبول می‌باشد و تغییرات عمق آب تقریباً در محدوده مجاز ده قرار می‌گیرد و شاخص‌های کفایت و راندمان نیز هم‌چنان نزدیک به مقدار مطلوب می‌باشد. بنابراین، در یک جمع‌بندی کلی نتایج حاصل از به‌کارگیری ماتریس Q مربوط به بازه یک، در سایر بازه‌ها با موفقیت می‌تواند مورد استفاده قرار گیرد. هر چند به سایر پارامترهای مؤثر در یادگیری باید توجه جدی شده و پژوهش‌های بیش‌تری در این زمینه انجام شود. البته، بررسی اثر کاهش محدوده مجاز عمق در مرحله یادگیری بر روی تغییرات عمق در مرحله استفاده از ماتریس Q می‌تواند در پژوهش‌های بعدی مورد توجه قرار گیرد. هم‌چنین، بررسی استفاده از این رویکرد در کانال‌های با تعداد زیاد بازه‌ها که پیچیدگی بیش‌تری دارند نیز باید مورد توجه قرار گیرد.

پی‌نوشت‌ها

1. Rotational
2. On-will or on-demand
3. On-request or arranged
4. Almodévar
5. Welton-Mohak
6. Proportional integral derivative
7. Linear matrix inequalities
8. Model Predictive Control
9. Reinforcement learning
10. Agent
11. Environment
12. State
13. Action
14. Reward
15. Value
16. Adequacy
17. Efficiency
18. Maximum Absolute Error
19. Integral of Absolute Magnitude of Error
20. Measure of Performance relative to Adequacy
21. Measure of Performance relative to Efficiency

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

رضایت بخش بود. به‌عبارتی، با ۴۰ ساعت یادگیری، می‌توان الگوهای بهره‌برداری کانال EIRI تحت هر سناریو به‌دست آورد و بر روی سازه‌ها اعمال کرد. ذکر این نکته ضروری است که در این پژوهش همان‌طور که اشاره شد، عمق هدف در بالادست آب‌بندها برابر می‌باشد و تنها تفاوت کانال‌ها در عرض درجه آب‌بندها است. در این شرایط با توجه به نتایج حاصله، استفاده از نتایج یادگیری یک بازه در سایر بازه‌ها، با موفقیت انجام شد. با این حال، طول کانال، عمق هدف متفاوت، تعداد سازه‌ها و ... در نتایج یادگیری و استفاده آن‌ها در سایر بازه‌ها از پارامترهای مهم و اثرگذار در این فرایند می‌باشند. در این پژوهش، برای اولین بار نتایج یادگیری یک بازه از کانال در بازه‌های دیگر مطالعه و بررسی شد که گام مؤثری می‌باشد، اما هم‌چنان پژوهش‌های بیش‌تر روی این موضوع مورد نیاز است.

نتیجه‌گیری

در این پژوهش، به‌منظور افزایش کارایی روش یادگیری سارسا و کاهش زمان لازم برای یادگیری الگوهای بهره‌بردار، ایده یادگیری الگوریتم برای یک بازه از یک کانال و به‌کارگیری نتایج آن در سایر بازه‌های کانال بررسی شد. الگوریتم سارسا برای این منظور در قسمتی از کانال EIRI شبکه دز توسعه داده شد و با یک مدل غیرخطی کانال تلفیق شد. با تعریف سناریوهای بهره‌برداری و با اجرای مدل، نتایج حاصل‌شده با استفاده از شاخص‌های استاندارد ارزیابی شد.

نتایج حاصل از یادگیری مدل نشان داد که مدت زمان لازم برای یادگیری حدود ۴۰ ساعت می‌باشد و نتایج حاصل از یادگیری در استخراج الگوهای بهره‌برداری کاملاً رضایت‌بخش بوده و تغییرات عمق در محدوده مجاز عمق قرار می‌گیرد و شاخص‌های کفایت و راندمان نیز نزدیک به

منابع

1. Arauz, T., Maestre, J.M., Tian, X., & Guan, G. (2020). Design of PI controllers for irrigation canals based on linear matrix inequalities. *Water*, 12(3), 855.
2. Clemmens, A.J. (1987). Delivery system schedules and required capacities. *Proc., Planning, operation, rehabilitation and automation of irrigation water delivery systems*, ASCE, 18-34.
3. Clemmens, A. J., Kacerek, T. F., Grawitz, B., & Schuurmans, W. (1998). Test cases for canal control algorithms. *Journal of Irrigation and Drainage Engineering*, 124(1), 23-30.
4. Durdu, Ö.F. (2010). Fuzzy logic adaptive Kalman filtering in the control of irrigation canals. *International Journal for Numerical Methods in Fluids*, 64(2), 187-208.
5. 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*.
6. Gopakumar, R., & Mujumdar, P. (2009). A fuzzy logic based dynamic wave model inversion algorithm for canal regulation. *Hydrological processes*, 23(12), 1739-1752.
7. Hashemy, S., Monem, M., Maestre, J., & Van Overloop, P. (2013). Application of an In-Line Storage Strategy to Improve the Operational Performance of Main Irrigation Canals Using Model Predictive Control. *Journal of Irrigation and Drainage Engineering*, 139(8), 635-644.
8. Hashemy, S., & Van Overloop, P. (2013). Applying decentralized water level difference control for operation of the Dez main canal under water shortage. *Journal of irrigation and drainage engineering*, 139(12), 1037-1044.
9. Lord, S. A., Shahdany, S. M. H., & Roozbahani, A. (2021). Minimization of Operational and Seepage Losses in Agricultural Water Distribution Systems Using the Ant Colony Optimization. *Water Resources Management*, 35(3), 827-846.
10. Manz, D.H., & Schaalje, M. (1992). Development and application of the irrigation conveyance system simulation model. *Proc., International Seminar on the Application of the Irrigation Mathematical Modeling for the Improvement of Irrigation Canal Operation*.
11. 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.
12. Monem, M.J., & Namdarian, R. (2005). Application of simulated annealing (SA) techniques for optimal water distribution in irrigation canals. *Irrigation and Drainage*, 54(4), 365-373.
13. Savari, H., & Monem, M.J. (2021). Analysis and Classification of Arranged Delivery Methods in Irrigation Networks. *Journal of water and irrigation management*, 11(2), 145-158.
14. Shahverdi, K., Monem, M.J., & Nili, M. (2016). Fuzzy SARSA learning of operational instructions to schedule water distribution and delivery. *Irrigation and Drainage*, 65(3), 276-284.
15. Van Overloop, P.-J. (2006). *Model predictive control on open water systems*, IOS Press.
16. Van Overloop, P., Maestre, J., Sadowska, A. D., Camacho, E. F., & De Schutter, B. (2015). Human-in-the-Loop Model Predictive Control of an Irrigation Canal [Applications of Control]. *IEEE Control Systems Magazine*, 35(4), 19-29.
17. Wagemaker, R. (2005). *Model Predictive Control on Irrigation Canals Application of various internal models*, Delft University of Technology, Faculty of Civil Engineering and Geosciences, Section of Operational Watermanagement.
18. Wang, Z., Reddy, J. M., & Feyen, J. (1995). Improved 0-1 programming model for optimal flow scheduling in irrigation canals. *Irrigation and Drainage Systems*, 9(2), 105-116..