



مدیریت آب و آبیاری

دوره ۱۲ ■ شماره ۲ ■ تابستان ۱۴۰۱

صفحه‌های ۳۵۸-۳۴۹

DOI: 10.22059/jwim.2022.341294.981

مقاله پژوهشی:

استخراج الگوهای بهره‌برداری با در نظر گرفتن خطای میراب در تنظیم سازه‌ها در شبکه‌های آبیاری

کازم شاهوردی*

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

تاریخ پذیرش مقاله: ۱۴۰۱/۰۴/۱۰

تاریخ دریافت مقاله: ۱۴۰۱/۰۱/۱۸

چکیده

بهره‌برداری سازه‌ها در کانال‌های انتقال و توزیع آب سنتی به صورت دستی و با استفاده از تجربه میراب انجام می‌شود. استخراج الگوهای بهره‌برداری در این کانال‌ها موضوع مهمی است که در پژوهش‌های اخیر نیز با استفاده از هوش مصنوعی، استخراج شده است. یکی از خطاهایی که در هنگام تنظیم سازه‌ها اتفاق می‌افتد، خطای ناشی از تنظیم سازه‌ها توسط میراب می‌باشد. بدین معنی که همواره، مقدار استخراج‌شده را میراب اعمال نکرده و مقداری خطا در تنظیم سازه‌ها اعمال می‌کند. این موضوع و تأثیرات آن در پژوهش‌های قبلی مورد مطالعه قرار نگرفته است. در این پژوهش، توانایی الگوریتم یادگیری تقویتی در استخراج الگوهای بهره‌برداری با لحاظ کردن خطای میراب که حداکثر ۱۰ درصد است، به صورت تصادفی بررسی شده است. جهت شبیه‌سازی کانال مورد مطالعه، که بخشی از کانال دز از شبکه آبیاری دز در شمال استان خوزستان است، از یک مدل غیرخطی استفاده شده است. نتایج نشان داد که دقت الگوهای استخراج شده زیاد است، به طوری که ارزش عمل‌های انتخاب‌شده به طور عمده برابر با ۰/۹ می‌باشد. هم‌چنین، تعداد تکرارها برای رسیدن به پاسخ برابر با ۶۵۰ تکرار بود.

کلیدواژه‌ها: خطای میراب، کانال، مدیریت آب، یادگیری تقویتی.

Determining operational patterns considering operator's error in structures settings in irrigation networks

Kazem Shahverdi*

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

Received: April 07, 2022

Accepted: July 01, 2022

Abstract

Structures operation in traditional water conveyance and distribution canals is manually done using operators' experience. Determining operational patterns in these canals is an important issue done in recent studies using artificial intelligence. One of the errors occurring during the settings of the structure is the operators' error applying some errors as they operate the determined setting. This issue and its effect hasn't been investigated in the previous research so far. In this research, the reinforcement learning model was used to determine the operational patterns considering the operator errors of five percent and 10 percent applied randomly. A non-linear model of the studied canal that is the EIR1 canal as a part of Dez network located in the north of Khuzestan was employed to simulate. The results showed that reinforcement learning can accurately determine the operational patterns with a maximum iteration of 650 so that the action values are more than 0.9 in most cases.

Keywords: Canal, Operator Error, Water Management, Reinforcement Learning.

مقدمه

شبکه‌های آبیاری و زهکشی وظیفه آبیگری از منبع، انتقال، توزیع و تحویل آب به واحدهای مصرف‌کننده (مزارع) را توسط سازه‌های آبیگر برعهده دارند. در ایران عمده این کانال‌ها به صورت سنتی و توسط یک میراب بهره‌برداری می‌شوند. در کانال‌های درجه سه و چهار، میراب در طول کانال حرکت کرده و متناسب با برنامه تحویلی که توسط اداره آب ارائه می‌شود، عملیات تنظیم سازه‌ها را انجام می‌دهد (Savari et al., 2016). دقت این شیوه تنظیم به تجربه میراب بستگی دارد. علاوه بر آن، انواع خطاهای انسانی همواره در دقت این شیوه مؤثر می‌باشند.

بهبود عملکرد بهره‌برداری شبکه‌های انتقال و توزیع آب، در پژوهش‌های مختلفی مورد توجه قرار گرفته است و در عمده آن‌ها دبی تحویلی، مدت زمان و دور آبیاری به عنوان پارامترهای مورد نظر جهت بهینه‌سازی بهبود عملکرد مورد استفاده قرار گرفته است. در برخی موارد، زمان و حجم آب تحویلی نیز مورد توجه قرار گرفته است (Sothea et al., 2013). در پژوهشی که جهت تحویل عادلانه آب در هند انجام شده است دو مدل خطی و غیرخطی توسعه یافته و عملکرد آن‌ها بررسی شده است. نتایج این پژوهش نشان داد که استفاده از هر دو مدل، منجر به افزایش عدالت تحویل در بین مصرف‌کنندگان شده است (Anwar et al., 2016). الگوریتم بهینه‌سازی جامعه پرندگان به منظور افزایش راندمان تحویل آب توسعه یافت و بر روی دو کانال در چین مورد آزمون قرار گرفت. نتایج نشان داد که این الگوریتم می‌تواند با سرعت زیاد به نقاط بهینه سراسری همگرا شود و دبی پایدار را در کانال تثبیت کند (Liu et al., 2018).

با توجه به نقاط ضعفی که در شیوه بهره‌برداری سنتی توسط میراب وجود دارد، به تازگی پژوهش‌های مختلفی جهت استخراج الگوها یا دستورالعمل‌های بهره‌برداری در

روش بهره‌برداری توافقی (برحسب درخواست) با استفاده از هوش مصنوعی صورت گرفته است. الگوهای استخراج شده به صورت جدولی در اختیار میراب قرار می‌گیرد و در نهایت، بهره‌برداری براساس جدول مربوطه انجام می‌شود. لازم به ذکر است که در روش توافقی، مقدار و زمان آب تحویلی با توجه به توافق صورت گرفته بین اداره آب و کشاورز تعیین می‌شود.

در اولین پژوهش مربوط به استخراج الگوهای بهره‌برداری با استفاده از هوش مصنوعی، الگوریتم یادگیری تقویتی^۱ به عنوان یکی از شاخه‌های پرکاربرد هوش مصنوعی، فرمول‌بندی شد و مورد استفاده قرار گرفت که در آن یادگیری الگوهای بهره‌برداری سازه‌های آب‌بند و آبیگر در بازه‌های مختلف به صورت جداگانه انجام و نتایج رضایت‌بخش حاصل شد. ضمن این‌که، به علت تنظیم مناسب سازه‌ها، مدت زمان رسیدن دبی مربوط به موج افزایشی/کاهشی از ورودی کانال مقدار قابل توجهی کاهش یافت و از ۲۳ ساعت به حدود ۵/۵ ساعت رسید (Shahverdi et al., 2016). سپس مقایسه روش یادگیری تقویتی با استفاده از روش دستی انجام شد که بیانگر دقت و توانایی بالای این روش در مقایسه با روش دستی، به ویژه در شرایط کم‌آبی می‌باشد (Savari et al., 2016). یکی از مهم‌ترین مزایای الگوریتم‌های یادگیری، توانایی آن‌ها در تعمیم نتایج یادگیری است، بدین معنی که با استفاده از یادگیری چند شرایط خاص در کانال و استخراج الگوهای بهره‌برداری، الگوهای بهره‌برداری برای هر شرایطی به دست می‌آید. این موضوع در پژوهش Shahverdi et al. (2020) بررسی و نتایج با دقت بالا، گزارش شده است. بهره‌برداری دستی کانال‌ها در روش برحسب درخواست با استفاده از الگوریتم جامعه مورچگان مورد توجه قرار گرفته (Fatemeh et al., 2020)، و پس از تحلیل حساسیت و به دست آوردن مقادیر

هرچند که با توجه به پژوهش‌های اخیر، استخراج الگوهای بهره‌برداری با استفاده از روش‌های هوش مصنوعی انجام می‌شود که منجر به استخراج دقیق الگوها می‌شود، اعمال این تنظیمات به علت خودکار نبودن شبکه‌ها، همچنان توسط میراب انجام می‌شود. در نتیجه همواره خطایی در مقدار تنظیم سازه‌ها و در نتیجه دبی تحویلی وجود دارد. از این‌رو، نیاز است تا قابلیت الگوریتم‌های هوش مصنوعی با لحاظ خطای ناشی از عملکرد میراب، مورد ارزیابی قرار گیرد که موضع پژوهش حاضر است.

مواد و روش‌ها

یادگیری تقویتی و اعمال خطا به آن در زمان یادگیری

در روش یادگیری تقویتی، یادگیری براساس برهم‌کنش متوالی بین یک عامل (حرکت دریچه) با محیط (وضعیت هیدرولیکی کانال) است که در هر تکرار، وضعیتی (عمق بالادست آب) مشاهده شده و عملی (بازشدگی دریچه) انتخاب و به محیط (مدل ریاضی کانال) اعمال می‌شود. در نهایت به عمل انجام‌شده پاداشی داده شده و ارزش آن عمل در بلندمدت محاسبه می‌شود. زمانی که مدل عمل مطلوب را پیدا کند، پاداش حداکثر شده و بیش‌ترین ارزش عمل^۲ حاصل خواهد شد. در کانال آبیاری، تابع پاداش معمولاً براساس میزان خطای سطح آب از سطح هدف تعریف می‌شود. روابط اصلی فرایند این روش به صورت روابط (۱) تا (۳) می‌باشد (شکل ۱).

$$p(a_{ij}) = \exp\left(\frac{\mu_i Q^{ij}}{\delta_k}\right) / \sum_{j=1}^m \exp\left(\frac{\mu_i Q^{ij}}{\delta_k}\right) \quad (\text{رابطه ۱})$$

$$r_k = -1 + 2 / \exp(2 * |y_t - y_{target}|) \quad (\text{رابطه ۲})$$

$$Q \leftarrow Q + \beta \times (r - \sum \mu_i Q) \quad (\text{رابطه ۳})$$

در روابط (۱) تا (۳) پارامترهای استفاده شده به صورت زیر می‌باشد.

بهینه پارامترهای الگوریتم، در شرایط کمبود آب ارزیابی شده است. نتایج نشان داد که مدل پیشنهادشده قابلیت ارائه برنامه بهره‌برداری را حتی در شرایط کمبودهای زیاد آب دارد.

استفاده از الگوهای استخراج‌شده با استفاده از یادگیری تقویتی در سایر بازه‌های مشابه در یک کانال موضوع پژوهش دیگر در زمینه هوش مصنوعی در کانال‌ها می‌باشد (Shahverdi, 2022). این ویژگی، بهره‌بردار را قادر می‌سازد تا با استفاده از یک الگو، چندین سازه را تنظیم کند. نتایج بررسی این ویژگی الگوریتم یادگیری تقویتی نیز موفق بوده و نتایج آن در کانال دز شرقی مورد ارزیابی قرار گرفته است که نشانگر توانایی الگوریتم در یادگیری رویکرد می‌باشد. دادن ارزش بیش‌تر به الگوهای برتر در به‌روزرسانی الگوهای یادگیری، از رویکردهای یادگیری تقویتی به‌شمار می‌رود، که در پژوهش Shahverdi & Javad Monem (2022) مورد بررسی قرار گرفت و منجر به افزایش سرعت یادگیری شد.

در پژوهش Savari & Monem (2022)، مدل هوشمند دیگری با استفاده از الگوریتم ژنتیک و شبکه عصبی مصنوعی به صورت ترکیبی توسعه یافت و سناریوهای مختلف تحویل از جمله سناریوهای سه‌ساعته و شش‌ساعته بررسی شدند. نتایج نشان داد که مدل توسعه‌یافته، قادر به بهبود شاخص‌های تحویل آب می‌باشد.

همان‌طور که مشاهده می‌شود، پژوهش‌های مختلفی در زمینه تعیین میزان و زمان تنظیم سازه‌ها در سال‌های اخیر انجام شده است. با این‌حال، همچنان تنظیمات سازه‌ها به علت نبود زیرساخت‌های مناسب مانند ابزار اندازه‌گیری دقیق، قدیمی بودن سازه‌های کنترل و آنگیر با استفاده از تجربه شخصی میراب انجام می‌شود. از طرف دیگر

بازشدگی مطلوب ارزش بیش‌تری را کسب می‌کند و احتمال انتخاب آن بیش‌تر خواهد شد. با توجه به عمق به‌دست‌آمده، مقدار پاداش با استفاده از رابطه (۲) محاسبه شده و در نهایت ارزش عمل با استفاده از رابطه (۳) محاسبه می‌شود. هدف روش یادگیری تقویتی این است که مقدار ارزش را در طی فرایند یادگیری حداکثر کند. بدین معنی که در هر تکرار عملی که انتخاب و اعمال می‌شود، پاداشی را دریافت می‌کند و در مرحله بعد، این پاداش در به‌روزرسانی مقدار ارزش طبق رابطه (۳) استفاده می‌شود. با افزایش تعداد تکرارها و افزایش مقدار پاداش، مقدار ارزش عمل نیز افزایش خواهد یافت. قابل ذکر است که با توجه به مصاحبه با کارشناسان شرکت‌های مدیریت شبکه‌های بهره‌برداری و میراب‌ها، حداکثر خطای تنظیم سازه‌ها توسط میراب برابر با $\pm 10\%$ درصد می‌باشد. در این پژوهش، توانایی مدل یادگیری تقویتی در استخراج الگوهای بهره‌برداری با لحاظ کردن این خطا بررسی شده است. تمامی سازه‌های مورد استفاده در کانال مورد پژوهش، به‌صورت دریچه کشویی است که رابطه دبی عبوری از آن به‌صورت زیر می‌باشد.

$p(a)$: احتمال انتخاب عمل کاندیدشده
 μ : درجه تطابق یا وزن عمل انتخاب‌شده (بین صفر و یک)
 Q : ارزش عمل کاندیدشده
 δ : پارامتر دما
 r : پاداش عمل کاندیدشده
 y_t : عمق
 y_{target} : عمق هدف در کانال
 β : نرخ یادگیری

در ابتدا، چند مقدار اولیه بازشدگی به‌عنوان مقادیر اولیه به مدل تعریف می‌شود. مدل با استفاده از رابطه (۱) احتمال انتخاب هر یک از بازشدگی‌ها را محاسبه می‌کند و در نهایت عملی که احتمال بیش‌تری داشته باشد، انتخاب شده و بر روی دریچه در مدل ریاضی کانال، که در این پژوهش، مدل هیدرودینامیکی ICSS می‌باشد، اعمال می‌شود. لازم به ذکر است که در ابتدا ارزش همه مقادیر بازشدگی یکسان بوده و انتخاب بازشدگی کاندید به‌صورت تصادفی می‌باشد. در ادامه و در روند یادگیری،

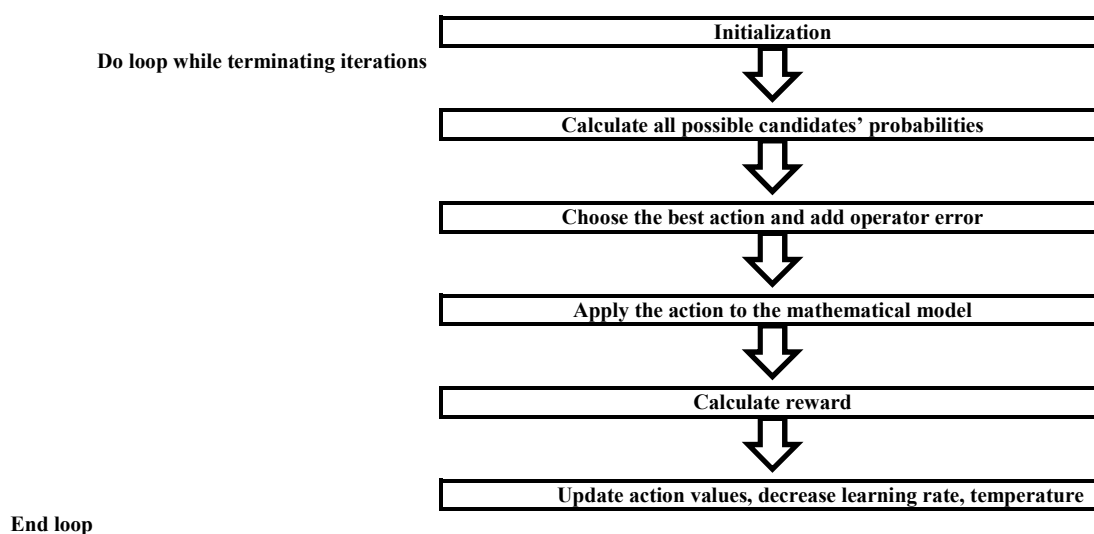


Figure 1. Flowchart of the investigated algorithm during learning.

$c = a \cdot Go$ برابر با حد بالای خطا و $rand()$ تابع تولید عدد تصادفی است که عددی بین صفر و یک تولید می‌کند. در این پژوهش، مدل یادگیری تقویتی براساس مقدار a برابر با ± 5 درصد و ± 10 درصد بررسی شده است. نمونه‌ای از مقادیر تصادفی تولید شده و اعمال شده برای a برابر با ± 5 درصد و ± 10 درصد در شکل (۲) نشان داده شده است.




Figure 2. Random numbers produced and applied for $a = \pm 5$ and ± 10 percent.

مدل غیرخطی شبیه‌سازی کانال

مدل هیدرودینامیکی ICSS در سال ۱۹۸۵ توسط مانز برای شبیه‌سازی یک‌بعدی جریان‌های ماندگار و غیرماندگار متغیر تدریجی تهیه شد که مدل قادر به شبیه‌سازی سازه‌ها و شرایط هیدرولیکی مختلف در کانال می‌باشد. این مدل دارای یک هسته مرکزی است که معادلات جریان‌های غیرماندگار را با استفاده از

$$Q = C_d \cdot B \cdot Go \cdot \sqrt{2 \cdot g \cdot h} \quad (\text{رابطه ۴})$$

که در آن، Q دبی عبوری (مترمکعب در ثانیه)، C_d ضریب دبی که برای همه دریاچه‌ها برابر با 0.6 است، B عرض دریاچه (متر)، Go مقدار بازشدگی دریاچه (متر)، g شتاب ثقل (متر بر مجذور ثانیه) و h ارتفاع آب در بالادست دریاچه (متر) می‌باشد که باید در همه شرایط دبی در عمق هدف تثبیت شود. در کانال مورد مطالعه، عمق هدف در همه بازه‌ها برابر با $1/2$ متر است. در عمل و در شبکه‌های سنتی، میراب براساس دبی‌های درخواست شده توسط زاعین، مقدار بازشدگی دریاچه‌ها را تنظیم می‌کند که همواره با خطای بهره‌برداری مواجه است. اگر مقدار خطا را برابر با a در نظر بگیریم، بجای مقدار Go ، مقدار $(1 \pm a) Go$ بر روی دریاچه اعمال می‌شود (رابطه ۵) که منجر به انحراف عمق از عمق هدف و در نتیجه خطا در دبی تحویلی به آبیگرها می‌شود. در واقع چیزی که در عمل و در هنگام بهره‌برداری توسط میراب اتفاق می‌افتد به صورت رابطه زیر می‌باشد:

$$Q = C_d \cdot B \cdot (1 \pm a) Go \cdot \sqrt{2 \cdot g \cdot h} \quad (\text{رابطه ۵})$$

که در آن، a مقدار خطای تنظیم بوده و حداکثر برابر با 10 درصد در نظر گرفته شده است. لازم به ذکر است که مقدار بازشدگی هر دریاچه، بین بازشدگی حداقل (Go_{min}) و بازشدگی حداکثر (Go_{max}) قرار دارد. در طول فرایند یادگیری، اگر مقدار بازشدگی دریاچه که براساس بیش‌ترین احتمال انتخاب می‌شود برابر با Go باشد، خطای مربوط به آن با استفاده از رابطه (۶) محاسبه شده و به مقدار Go اضافه می‌شود.

$$e = b + (c - b) * rand() \quad (\text{رابطه ۶})$$

که در آن، e خطای تصادفی تولید شده در هر مرحله در طول یادگیری، $b = -a \cdot Go$ برابر با حد پایین خطا،

سپس خطای ۱۰ درصد به مقدار بازشدگی دریچه انتخاب شده، اعمال می شود. لازم به ذکر است که تعداد تکرارها برای تکمیل یادگیری برابر با ۶۵۰ تکرار می باشد که با آزمون و خطا تعیین شد. مقادیر انحراف عمق به عنوان خروجی یادگیری از عمق هدف نیز با استفاده از درصد انحراف عمق از عمق هدف، جهت مقایسه با میزان خطای اعمال شده، ارزیابی شده است (رابطه ۷).

$$d = |y_{target} - y| * 100 \quad (\text{رابطه ۷})$$

که در آن، d مقدار انحراف برحسب درصد می باشد.

نتایج و بحث

در این پژوهش، توانایی مدل یادگیری تقویتی در تعیین الگوهای بهینه بهره برداری با وجود خطای بهره برداری میراب بررسی شده است. در طول فرایند یادگیری مقدار ارزش عمل بهینه افزایش پیدا می کند و به مقدار حداکثر خود، که با توجه به رابطه (۲)، اگر عمق با عمق هدف مساوی باشد برابر با یک می باشد نزدیک می شود. با این حال، به ندرت مشاهده می شود که دقیقاً به عدد یک برسد. نمونه ای از نمودار تغییرات پارامتر دما و نرخ یادگیری در طول فرایند یادگیری در شکل (۴) نشان داده شده است که بیانگر همگرایی مدل در تکرار ۶۰۰ است. با این حال، عمده یادگیری در تکرار ۵۰۰ انجام شده است و از تکرار ۵۰۰ به بعد مقدار یادگیری کم بوده و به طور عمده بازشدگی های دریچه که در تکرارهای قبل مشاهده شده و دارای ارزش بیشتری می باشد، مورد استفاده قرار می گیرد که باعث می شود به تدریج با افزایش ارزش (Q) آنها، احتمال انتخاب آنها بیشتر شده و در نهایت یک بازشدگی به عنوان بازشدگی بهینه دارای بیشترین احتمال انتخاب شود.

زیربرنامه های مربوطه حل می کند (Manz & Schaalje, 1992). در این پژوهش، این مدل در تلفیق با مدل یادگیری تقویتی مورد استفاده قرار گرفت. در هر زمانی که نیاز به شبیه سازی کانال باشد، ICSS فراخوانی شده و محاسبات لازم را با توجه مقادیر بازشدگی دریچه انجام می دهد و خروجی های عمق و دبی را در مسیر مشخص شده ذخیره می کند. با استفاده از مقادیر عمق، مقدار پاداش و در نهایت ارزش عمل محاسبه می شود.

کانال مورد مطالعه

کانال مورد استفاده در این پژوهش، کانال بتنی E1R1 در شبکه دز با مقطع دوزنقه ای، دارای شش آبگیر و طول ۲۸۳۰/۵ متر است (شکل ۳). شیب کانال بین ۰/۰۰۰۱۲ و ۰/۰۰۱۲، عرض کف از ابتدای کانال تا فاصله ۱۰۰۳ متری معادل ۱/۵ متر و از این نقطه تا محل آخرین آبگیر در فاصله ۲۸۳۰/۵ متری معادل یک متر است. شیب جانبی کانال در تمامی مسیر به صورت 1V:1.5H طراحی شده است.




Figure 3. The schematic view of E1R1 canal.

حداکثر ظرفیت کانال مورد مطالعه برابر با ۲/۷۴ مترمکعب بر ثانیه است. اما، با توجه به کمبود آب جریان آبی که در آن جریان دارد و در مطالعات مختلف استناد می شود، برابر با ۱/۲ مترمکعب در ثانیه است. در این پژوهش، دبی ورودی بین ۰/۵ تا ۱/۴ مترمکعب مورد بررسی قرار گرفته است. در هر کدام از دبی ها نیز، در اعمال روش یادگیری تقویتی خطای پنج درصد و

را انتخاب پیدا خواهد کرد و هر چقدر تعداد تکرارها زیاد شود، نتایج بهتر و دقیق‌تر به دست خواهد آمد.

Table 1. The final action values and average water depth deviations from target value.

flow (m ³ /s)	Operator Error (%)			
	±5%		±10%	
	Action Value	Deviation (%)	Action Value	Deviation (%)
0.5	0.981	0.5	0.935	2.5
0.6	0.979	2.2	0.935	2.5
0.7	0.980	0.3	0.935	2.5
0.8	0.989	0.3	0.935	2.5
0.9	0.986	0.2	0.778	5.9
1.0	0.987	0.6	0.705	8.1
1.1	0.993	2.4	0.848	2.8
1.2	0.850	3.8	0.767	9.1
1.3	0.935	2.5	0.874	7.8
1.4	0.935	2.5	0.666	10.5
max	0.993	3.8	0.935	10.5
min	0.850	0.2	0.666	2.5

نمودار تغییرات ارزش در طول فرایند یادگیری برای خطای پنج درصد در دبی‌های مورد بررسی در شکل (۵) ارائه شده است. همان‌طور که مشاهده می‌شود روند تغییرات با روند تغییرات دما همخوانی دارد و تقریباً در همه موارد، همگرایی مدل بعد از تکرار ۶۰۰ مشاهده می‌شود. در ابتدا تعداد عمل‌های بیش‌تری انتخاب شده و آزمون می‌شود. سپس در اواسط یادگیری تعداد این عمل‌ها کم‌تر شده و در نزدیکی تکرار ۶۰۰، حدود کم‌تر از ۱۰ عمل با احتمال بیش‌تر بررسی می‌شود و بعد از تکرار ۶۰۰، تقریباً یک یا دو عمل نهایی، با بیش‌ترین احتمال انتخاب و بیش‌ترین ارزش بررسی و در نهایت عمل نهایی انتخاب می‌شود. در دبی‌های ۱/۲ مترمکعب در ثانیه، پاداش‌های منفی نیز مشاهده می‌شود که به معنی جریمه عمل مذکور می‌باشد. هرچند بعد از تکرار ۵۰۰ پاداش منفی مشاهده نمی‌شود. همان‌طور که در این شکل‌ها مشاهده می‌شود، مدل یادگیری تقویتی، حتی یک مورد نیز با شکست مواجه نشده است. این روند در حالت خطای ۱۰ درصد میراب نیز مشاهده می‌شود که به جهت کاهش تعداد شکل‌ها در اینجا ارائه نشده است.




Figure 4. Temperature and learning rate curves during the learning.

در جدول (۱) مقدار نهایی ارزش (Q) بازشدگی‌های بهینه و متوسط انحراف عمق از عمق هدف در حالت خطای پنج درصد و ۱۰ درصد برای دبی‌های مورد بررسی ارائه شده است. حداقل و حداکثر ارزش عمل انتخاب شده به ترتیب برابر با ۰/۸۵۰ و ۰/۹۹۳ در حالت خطای پنج درصد می‌باشد که منجر به خطای عمق بین ۰/۲ تا ۳/۸ درصد شده است. در مورد خطای ۱۰ درصد میراب، حداقل و حداکثر ارزش عمل انتخاب شده به ترتیب برابر با ۰/۶۶۶ و ۰/۹۳۵ می‌باشد که منجر به خطای عمق ۲/۵ درصد و ۱۰/۵ درصد شده است. البته، خطای عمق ۱۰ درصد یا مقادیر نزدیک به آن‌ها در کم‌تر از ۴۰ درصد مواقع اتفاق افتاده است که مقدار دبی زیاد می‌باشد. این نتایج نشان می‌دهد که مدل یادگیری تقویتی در صورت اعمال خطا به آن در طول یادگیری نیز قادر به یادگیری الگوهای بهینه می‌باشد. با بررسی انجام شده بر روی نتایج خروجی، مشخص شد که مدل یادگیری تقویتی، اعمال خطای بهره‌بردار مدل را از روند اصلی خود خارج نمی‌کند و در نهایت، مدل مقدار عمل بهینه را براساس میانگین خطای میراب یاد می‌گیرد. با توجه به شکل (۱) که میانگین خطا صفر می‌باشد، بنابراین می‌توان نتیجه گرفت که در هر شرایطی مدل، عمل بهینه

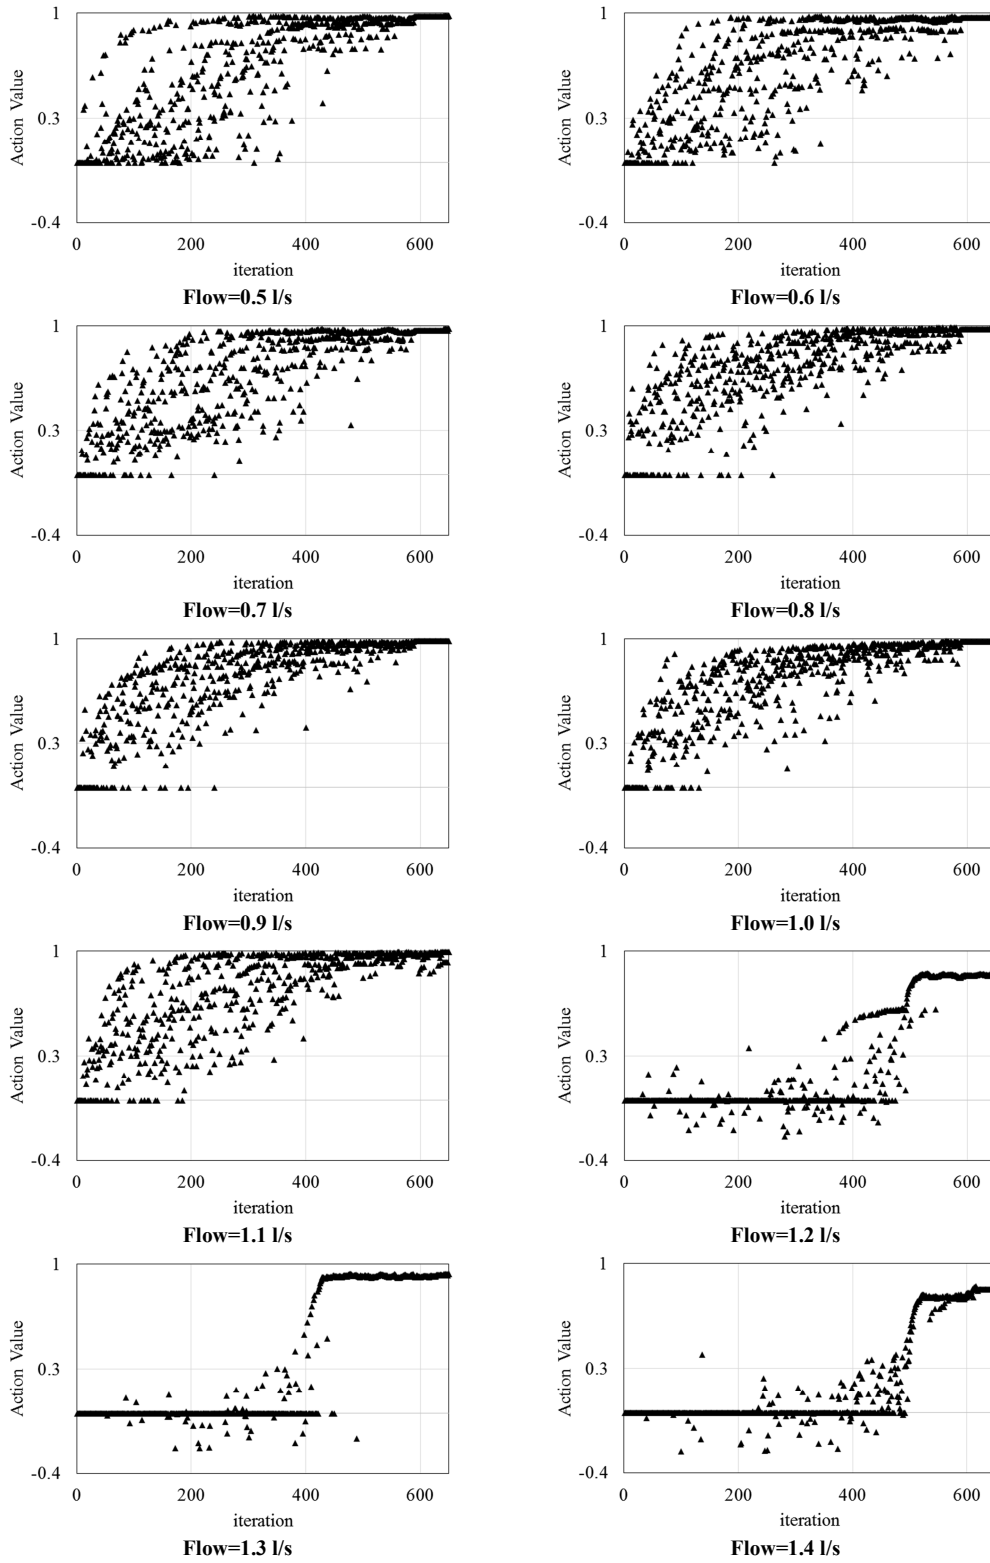


Figure 5. Action values for different flows for the operator's error of 5%.

استفاده شده و خطای میراب را نیز لحاظ کرد و اقدام به یادگیری الگوها کرد. با این حال، برای یک کانال با تعداد زیاد بازه‌ها پیشنهاد می‌شود که پژوهش مستقلی انجام گیرد.

پی‌نوشت‌ها

1. Reinforcement Learning
2. Action Value

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

منابع

1. Anwar, A. A., Bhatti, M. T., & de Vries, T. T. (2016). Canal operations planner. I: Maximizing delivery performance ratio. *Journal of Irrigation and Drainage Engineering*, 142(12), 04016057.
2. 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.
3. 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*.
4. Liu, Y., Yang, T., Zhao, R.-H., Li, Y.-B., Zhao, W.-J., & Ma, X.-Y. (2018). Irrigation Canal System Delivery Scheduling Based on a Particle Swarm Optimization Algorithm. *Water*, 10(9), 1281.
5. 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*.
6. 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.
7. Savari, H., Monem, M., & Shahverdi, K. (2016). Comparing the Performance of FSL and Traditional Operation Methods for On-Request Water Delivery in the Aghili Network, Iran. *Journal of Irrigation and Drainage Engineering*, 142(11), 04016055.

همان‌طور که مشاهده می‌شود در دبی‌های $1/4-1/2$ مترمکعب، پراکنش نقاط کم می‌باشد که بدین معنی است که اکثر عمل‌های انتخاب و اعمال شده مناسب نبوده‌اند و پاداش‌های منفی (جریمه) دریافت کرده‌اند. با این حال، همگرایی حاصل شده است. نتایج این پژوهش، اهمیت استفاده از روش‌های هوش مصنوعی و توسعه آن‌ها در کانال‌های انتقال و توزیع آب می‌باشد که حتی با وجود اعمال خطا در طی یادگیری نیز به درستی، مقادیر بهینه را پیدا می‌کند.

نتیجه‌گیری

در این پژوهش، توانایی مدل یادگیری تقویتی در صورت لحاظ کردن خطای میراب مورد بررسی قرار گرفت و در هر تکرار، خطای پنج و ۱۰ درصد میراب به‌طور جداگانه در دبی‌های مختلف به مدل اعمال شد. کانال مورد مطالعه بخشی از کانال دز شرقی است و شبیه‌سازی آن با مدل هیدرودینامیک ICSS انجام شد. احتمال انتخاب هر عملی براساس میزان ارزش یا شایستگی عمل مذکور می‌باشد که در طول فرایند یادگیری عمل‌های بهتر، دارای ارزش بیشتری می‌شوند و در نهایت عمل با بیش‌ترین ارزش به‌عنوان عمل بهینه انتخاب می‌شود. نتایج نشان داد که در حالت خطای پنج درصد میراب، خطای خروجی در $0/2$ تا $3/8$ درصد، و برای خطای ۱۰ درصد میراب خطای خروجی $2/5$ تا $10/5$ درصد می‌شود. در تمامی آزمون‌ها، مدل همگرا شده و حتی یک مورد شکست نیز مشاهده نشد. حداکثر تعداد تکرارها ۶۵۰ بود. با این حال در تکرارهای کم‌تر از ۶۰۰ مدل عمل بهینه را پیدا کرد. در پژوهش‌های قبلی استخراج الگوها انجام شده است و نتایج موفق‌تری گزارش شده است، اما در این پژوهش، استخراج الگوها با در نظر گرفتن خطای ناشی از عملکرد میراب نیز لحاظ شد و نتایج موفق‌آمیز حاصل شد. بنابراین، پیشنهاد می‌شود از این مدل

8. 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*, <https://doi.org/10.1002/ird.2670>.
9. Shahverdi, K. (2022). Evaluating utilization of structures' settings of one reach in the others. *Water and Irrigation Management*, 11(4), 769-779 (In Persian).
10. Shahverdi, K., & Javad Monem, M. (2022). Irrigation canal control using enhanced fuzzy SARSA learning. *Irrigation and Drainage*, <https://doi.org/10.1002/ird.2684>.
11. Shahverdi, K., Maestre, J., Alamiyan-Harandi, F., & Tian, X. (2020). Generalizing Fuzzy SARSA Learning for Real-Time Operation of Irrigation Canals. *Water*, 12(9), 2407.
12. 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.
13. Sothea, H., Pierre-Olivier, M., Gilles, B., & Cyril, D. (2013). Optimization of water distribution for open-channel irrigation networks.