

AI 強化学習を活用した利根川上流ダム群の 低水統合管理への現場適用

かなやま たくひろ¹ もりや まさし² よしだ かずし¹ みうら しん³ さいとう こうえつ⁴
金山 拓広¹・守谷 将史²・吉田 一志¹・三浦 心³・齋藤 光悦⁴

¹ (株) 建設技術研究所 東京本社 河川部 (〒330-6030 埼玉県さいたま市中央区新都心 11-2)

² (株) 建設技術研究所 大阪本社 水システム部 (〒541-0045 大阪府大阪市中央区道修町 1-6-7)

³ (株) 建設技術研究所 東京本社水システム部 (〒103-0007 東京都中央区日本橋浜町 3-15-1)

⁴ 国土交通省関東地方整備局利根川ダム統合管理事務所 (〒371-0846 群馬県前橋市元総社町 593-1)

気候変動に伴う渇水頻度の増加の影響を緩和するため、既存ダムのさらなる有効活用が求められている。本研究では、強化学習の手法を用いてダム群の容量を有効活用するための最適操作を支援するモデルを構築し、その有用性を検証した。構築したモデルは現時刻の各ダムの貯水量や流入量等の各種条件をもとに、最適なダムからの補給量を予測するものである。強化学習モデルでは、単純に日々の貯水量比率で補給配分率を設定した水収支計算結果と比較して、流入量や貯水量等の個別のダムの特徴を踏まえつつ、基準地点での不足や無効放流が少ない操作を予測できる結果が得られた。

Key Words: 低水管理, 統合運用, 人工知能 (AI), 強化学習, Deep-Q-Network

1. はじめに

気候変動に伴う渇水頻度の増加が懸念される中、限られた水資源をより効率的に利用することが一層求められており、これを支援することが必要になっている。流域内に複数のダムが存在する場合、ダムに貯留した水をより効率的に利用するためには、各ダムへの流入量や貯水状況及び下流河川の流量の予測結果等を基に、ダムからの補給量の設定が必要である。

近年、AI 技術の活用は多分野で活発化しており、ダム管理においても深層学習による流入量予測等の適用事例¹もある。その他、状況に応じた適切な操作を AI に支援させることを目的として、洪水調節の操作等に強化学習の手法を適用する研究事例²がある。

本研究では日々の低水管理におけるダム操作に対して、

膨大な状況(ケース)を自動的に AI が学習し、人間が与えた報酬に応じて最適な答え(行動)を出す強化学習(図-1)の仕組みを適用した。この AI 技術を活用し、現状のダム群への流入、貯水状況下において、下流基準地点への確実な利水補給かつ、効率的に貯水量を温存するための最適なダム放流操作の選択を可能とするモデルの構築を図った。

2. 対象流域

本研究の対象流域とした利根川の低水管理は、水系上流9ダム群(矢木沢・奈良俣・藤原・相俣・菌原・八ッ場・下久保・草木ダム、渡良瀬遊水池)の統合運用により、利根川本川、江戸川及び支川の神流川、渡良瀬川等の適正な水利用のための流量を確保することとしている。

統合運用における利水基準点は栗橋地点となり、江戸川及び本川下流域における維持流量、都市用水、灌漑用水の水需要を考慮した流量を確保するよう運用されている。

これらの統合管理によるダム操作は、操作規則等の運用ルールに従いながら、気象特性や貯水状況、ダム放流能力等の多数の情報をもとに放流量が決定されている。それらダムや河川の状況に応じた操作を、より安定的かつ効率的に行うためのツールとして、AI の導入が期待されている。

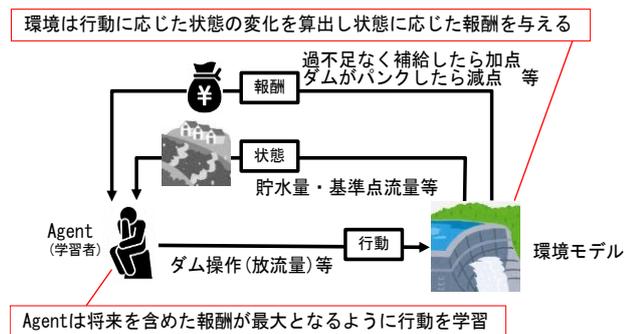


図-1 強化学習のイメージ

3. AI 強化学習モデルの構築

(1) モデルの全体構成

構築したモデルの全体構成を図-2に示す。ダム最適な補給配分を予測する Agent モデル (AI 強化学習部分) と、それらからダム補給量および貯水量を算定する環境モデル (水収支モデル) を組み合わせた構成となる。入力された状態下で設定した報酬に基づく評価 (基準地点となる栗橋に不足を出さない・ダム無効放流量を減少) により、最適なダム補給割合が出力できるように繰り返し学習するモデルとしている。

(2) AI 強化学習モデルの構造

Agent モデルに搭載したダム操作に利用する強化学習アルゴリズムは、Deep-Q-Network (以下 DQN) とした。DQN は強化学習の学習効率化に深層学習手法を利用したものであり、柔軟で高精度なダム操作の学習が期待できる。また、AI に与える状態 (入力項目) と環境モデルの組み合わせで多様な検討にも使用できる。

強化学習の学習アルゴリズムは、3層の全結合層からなる深層学習構造とし、活性化関数には ReLU⁹⁾を用いた。最適化手法は Adam(lr=0.001)⁹⁾、ダム操作選択の方針は ϵ -greedy 方針 ($\epsilon=0.1$)⁹⁾ とした。ここで、lr は学習率⁹⁾、 ϵ は行動空間からランダムに行動を選択する確率である。

(3) 状態空間の設定

Agent モデルの入力層となる状態空間は、表-1 に示す計 20 個の情報を設定する。ここでダム流入量は利根川上流 9 ダム群のうち、渇水時の補助的な補給施設となる渡良瀬遊水池を除く 8 ダムの日単位流入量とした。また現時点の月の情報は、利根川では積雪、融雪を有することから季節により状態に対する最適な行動の傾向が異なることを踏まえ、学習精度を高めるために設定している。

(4) 行動空間の設定

Agent モデルが出力する行動空間として、後述の水収支計算に基づく不足量に対する各ダムの補給配分率を設定した。また、AI による行動パターン数 (補給配分率のパターン数) を抑えるため、ダム群を①奥利根に位置する 5 ダム群 (矢木沢・奈良良・藤原・相俣・菌原ダム)、②吾妻川のハッ場ダム、③神流川の下久保ダム、④渡良瀬川の草木ダムの 4 つにグループ化した。

(5) 環境モデル (水収支モデル)

Agent モデルが出力する補給配分率を受けて、環境モデルとなる栗橋基準地点の不足量および各ダムからの放流量、貯水量を算定する水収支モデルを構築した。

本研究で構築した水収支モデルは図-3 に示すように、栗橋上流を対象に国土交通省・水機構所管の既設 9 ダム、

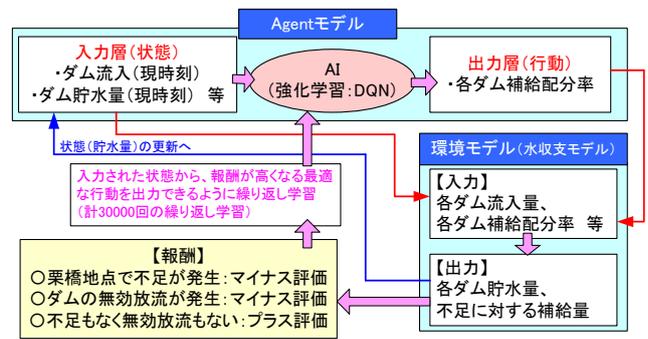


図-2 AI 強化学習モデルの全体構成

表-1 入力項目一覧

状態項目	内訳	個数
ダム流入量	現時点 (日単位) × 8 ダム ※渡良瀬遊水池以外	8
ダム貯水量	現時点 (日単位) × 9 ダム	9
残流域 流出量	ダム地点～栗橋間 (現時点) (日単位)	1
栗橋地点 設定流量	現時点 (日単位) 正常流量 (灌漑期:120m ³ /s, 非灌漑期:80m ³ /s)	1
月	現時点	1
状態 計		20

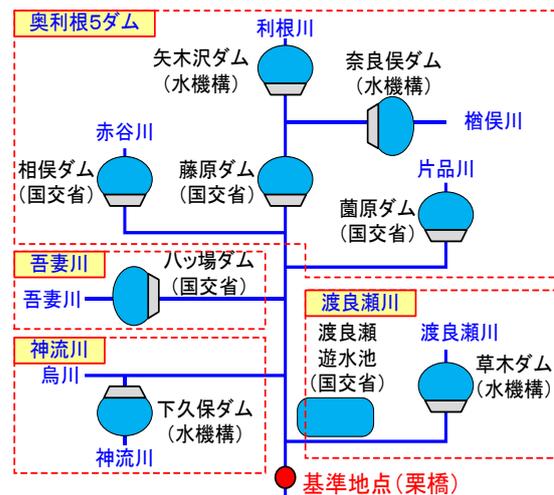


図-3 水収支モデルの概要 (赤点線: グループ化範囲)

基準地点は栗橋地点の 1 点確保のモデルとした。

水収支計算ではまず、現時点の実績の栗橋流量に対してダム調整量を戻したダム補給前の流況から栗橋地点での設定流量に対する不足量を算定し、上流ダム群からの必要補給量を算出する。

次に、算出した必要補給量に Agent モデルが出力する補給配分率を割り当て各ダムの補給量を算定する。なお、Agent モデルでは奥利根 5 ダムを 1 つにグルーピングした補給率として出力されるため、本研究では、各ダムの年間の流入総量とダム容量から水のたまりやすさ、たまりにくさに応じて個別のダムに補給量を分配している。

最後に、上流から各ダム地点の流入出に伴う貯水量変化や、ダム群からの補給後の栗橋地点流況を計算し、後述する Agent モデルの行動に対する報酬評価や、次のパラメータ学習に向けた状態を更新する。

(6) 報酬の設定

最適な低水運用を学習させる場合、Agent モデルの行動によりある状態に遷移したことを評価する必要がある。本研究における最適な低水運用とは、複数のダム群の統合運用により、極力無効放流を少なくし、ダムが枯渇した場合の下流での不足量を極力小さくする運用と定義した。なお、無効放流とは、ダム放流のうち下流の必要量への補給に寄与することなく流下した流量であり、出水時やドローダウン時の放流量も含む。

本研究では以下に示す、栗橋地点での不足量や各ダムの無効放流量、ダム群の貯水率を指標としたプラスとマイナスの報酬設定を行った。

① 栗橋地点で不足を生じた場合：

$$\text{報酬} = -10 \times \text{不足量}(\text{m}^3/\text{s})$$

② 無効放流が生じた場合：

$$\text{報酬} = -\text{無効放流量}(\text{m}^3/\text{s}) / 10$$

③ 栗橋地点不足も無効放流もない場合：

$$\text{報酬} = +\text{全ダム貯水率} \times 100$$

(7) 学習データ

学習期間は経年渇水と大規模渇水を含み、利根川上流の渇水特性を網羅している 1991 年～1994 年の 4 年間とした。検証期間は学習期間の 4 年間に加え、未経験期間としてさらに大規模な渇水年の 1996 年を含む 1991 年～1998 年の 8 年間とした。（図-4 参照）

学習では、1 回のパラメータ学習期間を 1 エピソードといい、トライアル計算による学習の進捗具合や、前年の貯水状況がその年の貯水量に影響する実態を鑑み 2 年を 1 エピソードとした。2 年に渡る複数パターンを学習させるため、図-4 のように 1991 年～1994 年の 4 ケ年を 1 ケース 2 ケ年にスライドさせて分割し、各ケース 10000 エピソードずつ学習させた。なお、各ケース間の学習パラメータは引き継いで継続学習させている。

4. 学習の結果

(1) 学習回数と報酬の推移

ケース 2 及びケース 3 の学習回数と報酬の推移の関係は図-5 に示すように、報酬（1 エピソード内の約 730 日の報酬の積算値）が右肩上がりであり学習が順調に進んでいることがわかる。ケース 3 では右肩上がりの傾向が緩やかとなり、概ね学習が収束していることが確認される。

(2) 操作シミュレーション結果と考察

学習済みのモデルにより 1991 年～1998 年の 8 ケ年の検証期間においてシミュレーションを実施した。検証では、実際の渇水時の取水制限に伴うダムの補給制限等も含まれたダム操作実績との比較が難しいため、本研究では、AI 操作による結果と、日々の貯水量比率見合いで決定

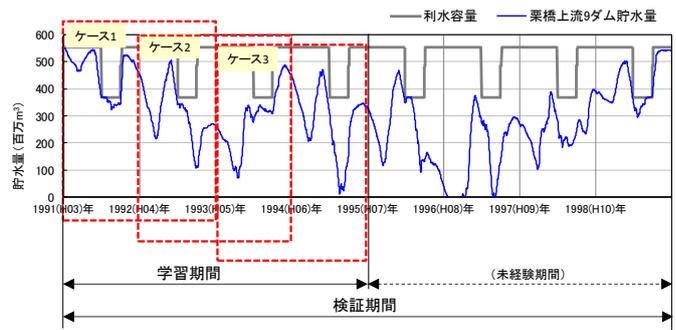


図-4 学習期間と検証期間

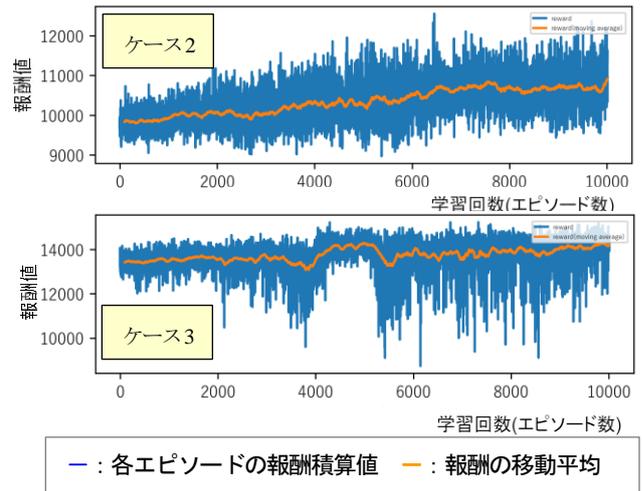


図-5 ケース 2 及び 3 の学習回数と報酬の推移

した補給配分率による水収支計算結果との比較を行い有意性を評価した。

a) 栗橋上流 9 ダム群の比較

栗橋上流 9 ダム群合計の貯水量、無効放流量および栗橋流量の比較結果を図-6 に示す。

栗橋地点の不足量に対してダムによる補給を行った後のダム貯水量回復時には、AI 操作の方が無効放流を抑えた結果、栗橋上流 9 ダム群の貯水量が大きく、貯水量の温存が図られていることが確認できる。（図-6 の赤点線枠内参照）

AI 操作による不足量の改善効果として、1995 年の貯水量の温存により、貯水量比率配分による結果と比べて、翌年の 1996 年のダム枯渇時に生じる不足量を約 6% にあたる 13.5 百万 m^3 減少できていることが確認できた。これは東京都約 1,400 万人の 4～5 日分の水使用量に当たる。

b) 個別ダムの比較

個別の各ダムの貯水量のうち、AI の行動空間においてグループ化を行っていない八ッ場、下久保、草木ダムの検討結果を図-7 に示す。

これより AI 操作による日々の運用において、日々の貯水量比率によるダム運用（各ダムの貯水量/有効貯水容量が等しくなるように運用される方式、図中の青線）と比べると、貯水量が回復しにくい傾向にある下久保ダムでは貯水量が温存される傾向が見られ、貯水量が回復

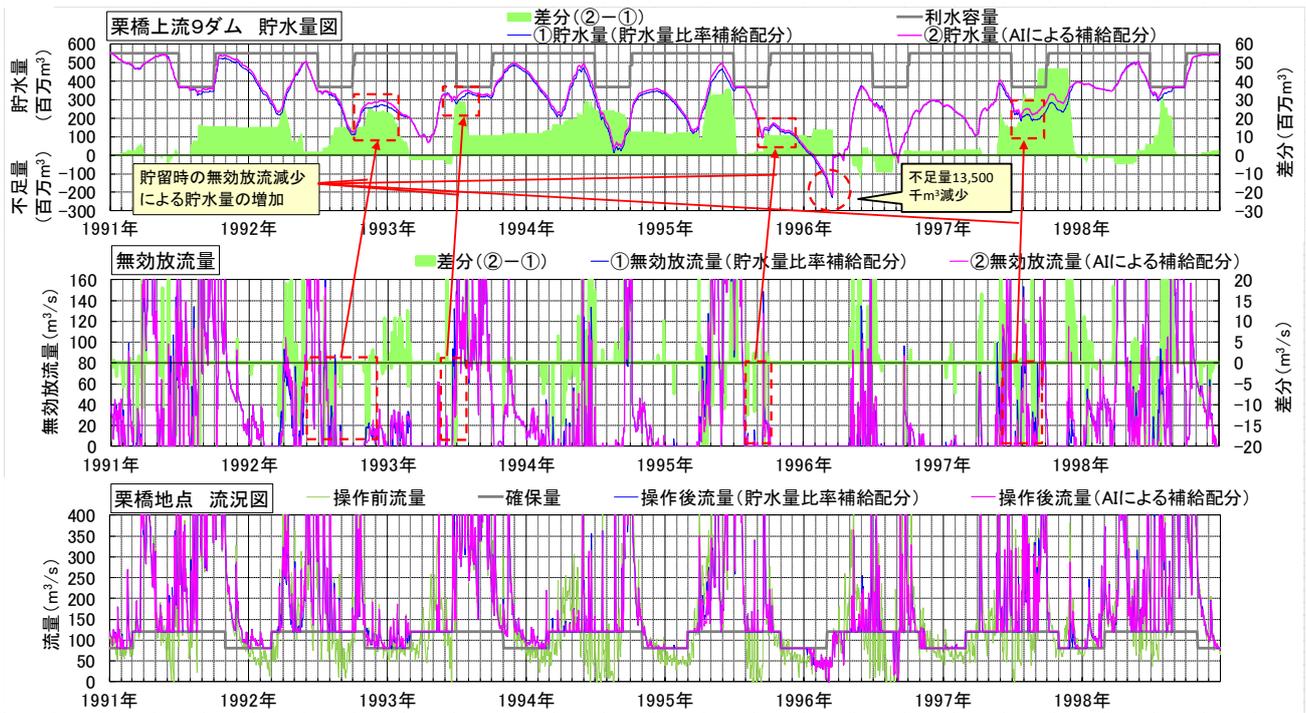


図-6 貯水量比率補給配分・AI 補給配分の比較 9ダム合計

しやすい傾向にあるハッ場ダム、草木ダム等では優先的に補給される傾向が確認できる。

また、下久保ダムは全体的に AI 操作による貯水量の温存傾向が見られる一方で、1992年9月、1995年9月に大きく補給している期間が見られるが、図-6 に示す栗橋上流9ダム群全体で評価すれば AI 操作により貯水量の温存が図られた効果が確認できる。

以上のことから個別のダムの特徴を踏まえて AI により効率的なダム補給が選択できており、本モデルの有効性が高いと評価できる。

5. 結論

本検討では、利根川上流ダム群を対象とした利水補給に強化学習を適用し、最適ダム放流操作方法の予測によりダム管理を支援するシステムを構築した。

構築したモデルによる予測結果は、ダム下流基準地点への利水補給を行いつつ、ダム群の容量を有効利用できていることが確認され、ダム運用を支援する手法として有効であると考えられる。

ただし、行動テーブル数が多い場合には学習が想定したように進まない場合があり、本検討では一部単純化した条件を設定している。今後は複雑な条件下においても学習が可能となるようなモデル上の工夫や報酬の設定方法等の検討が必要である。

また、今後このような AI による最適行動選択の技術を適用することで、治水・利水に関するダム管理だけでなく、自動運転や最適経路選択等の交通分野など多岐に渡るコンサルティングの高度化や領域拡大が期待できる。

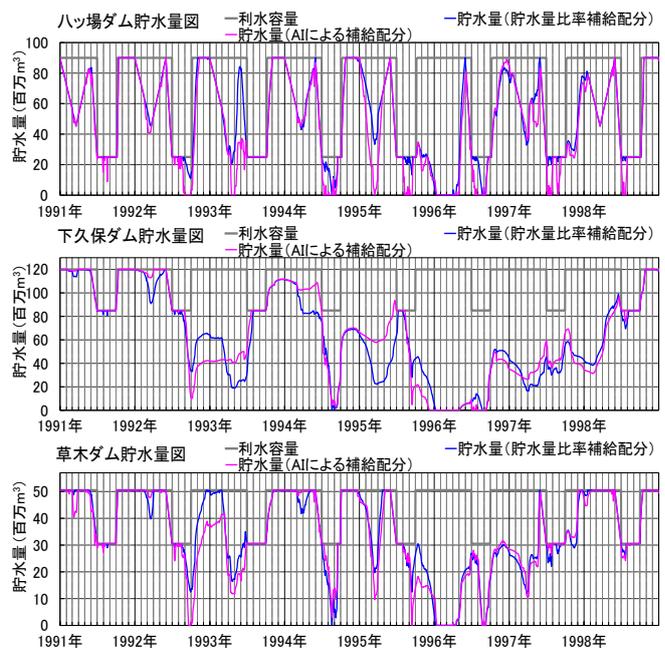


図-7 貯水量比率補給配分・AI 補給配分 個別ダム

参考文献

- 1) 古田島樹, 三浦心, 神瀬史雄, 金子拓史, 山脇正嗣: ダムにおけるAIを用いた低水流入量予測, 令和元年度建設コンサルタント業務研究発表会, 2019.
- 2) 赤塚洋介, 瀬戸里枝, 鼎信次郎: 深層強化学習を用いたダム操作モデルによる予測情報を活用した事前放流操作に関する検討, 土木学会論文集B1 (水工学), Vol.76, No.2, I_823-I_828, 2020.
- 3) Antonio Gulli, Sujit Pal: 直感 Deep Learning, オライリー・ジャパン, 2018