

深層強化学習を用いたダム操作モデルによる 洪水調節

FLOOD CONTROL BY THE DAM OPERATION MODEL USING DEEP REINFORCEMENT LEARNING

石尾将大¹・一言正之²・島本卓三³・房前和朋³

Shota ISHIO, Masayuki HITOKOTO, Takuzo SHIMAMOTO and Kazutomo FUSAMAE

¹正会員 工修 元日本工営株式会社 中央研究所 (〒300-1259 茨城県つくば市稲荷原2304)

²正会員 博(工) 日本工営株式会社 技術本部 (〒300-1259 茨城県つくば市稲荷原2304)

³正会員 元国土交通省九州地方整備局 九州技術事務所 (〒830-8570 福岡県久留米市高野1-3-1)

We developed the deep neural network model of dam operation for flood control. The input of the model was observed and predicted dam inflow, current dam discharge and dam water level. The output of the model was the dam discharge at the next time step. Deep reinforcement learning was applied to train the network. First, lots of virtual floods were prepared by flood simulation model. Then, the network was trained so as to appropriately control the floods. Developed model was applied to the Matsubara dam in Chikugo River. The model result was compared with the operation rules, and consequently validity was confirmed.

Key Words : flood control, dam-operation model, deep learning, reinforcement learning

1. はじめに

2018年の西日本豪雨災害など、近年の洪水の激甚化に伴い、ダムの重要性が高まってきている。一般に、ダム操作は操作規則・細則、ただし書き操作規則などをもとに行われる。しかし、異常洪水時などには、下流の被害を軽減するために柔軟な操作が求められる場合がある。ダム管理者は時々刻々と変化していく状況に応じて操作判断を行う必要に迫られるが、最適なダム操作を継続することは容易ではないと考えられる。

洪水時の適切なダム操作を支援するため、AIの活用が期待される。小尻ら¹⁾はファジィ理論を用いて、長谷部ら²⁾はファジィ・ニューラルネットワークシステムを用いて、それぞれ適切なダム操作を試みているが、これらの検討では限られた洪水事例での検証にとどまっている。筆者らは、深層ニューラルネットワークを用いたダム操作AIの構築を試みた。具体的には、強化学習により多数の仮想洪水を学習することで、多様な洪水に対して柔軟に洪水調節操作を行うように学習を行った。構築したダム操作AIと操作規則とを比較し、予測流入量などが適切に与えられた一定の条件下において、ダム操作AIの

有用性を検証した。

2. 対象ダムおよびダム操作AIの検討手順

(1) 対象ダムの概要

筑後川水系上流域の松原ダムを検討対象とした。松原ダムの流域面積は491km²で、上流には下釜ダム（流域面積185km²）が含まれる（図-1）。




図-1 松原ダム流域




図-2 松原ダム諸元図




図-3 松原ダム操作規則模式図

松原ダムの洪水調節容量は4,580万 m^3 で、コンジットゲートの最大放流量は1,700 m^3/s 、クレストゲートの最大放流量は2,680 m^3/s である(図-2)。図-3に松原ダムの操作規則模式図を示す。ダム流入量が700 m^3/s 以上になると洪水調節を開始し、異常洪水時防災操作開始水位に達するまで最大2,070 m^3/s の放流を行う。

3. ダム操作AIモデルの構築

(1) ダム操作AIの検討手順

本研究の実施手順を図-4および下記に示す。

- **仮想降雨データの作成**：松原ダムを対象に過去の洪水事例を選定し、異常洪水時防災操作が発生するような洪水規模となるように降雨強度を引き伸ばした降雨パターンを作成する。また、近隣の豪雨事例(H24九州北部豪雨、H29九州北部豪雨)が松原ダム流域で発生した場合を仮定した降雨パターンも作成する。
- **仮想ハイドログラフの作成**：作成した降雨データを用いて、貯留関数モデルによりダム流入ハイドログラフを作成する。
- **ダム操作AIの学習・検証**：仮想ハイドログラフを用いて、ダム操作AIの学習・検証を行う。学習条件に応じたダム操作AIの挙動を確認し、モデルを調整する。
- **操作規則との比較・考察**：操作規則・細則に基づくダム操作シミュレーションを行い、ダム操作AIとの比較・考察を行う。




図-4 ダム操作AIの検討手順




図-5 引き伸ばし後の各対象洪水の累積雨量

(2) 仮想ハイドロの作成

a) 引き伸ばし降雨の作成

対象洪水として、Cバンドレーダ雨量(同時刻合成レーダ)が存在している2006年以降で、松原ダムへの流入量が比較的多い17洪水を選定した。選定した洪水の累積雨量(1~48hr)が幅広い分布を持つように留意し、引き伸ばし率を設定した。引き伸ばし後の各洪水の累積雨量を図-5に示す。

b) 九州北部豪雨のスライドによる仮想降雨の作成

H24, H29の九州北部豪雨を松原ダム流域にスライドさせ、仮想降雨データを作成した。具体的には、図-6に示すようにCバンドレーダ雨量データを1メッシュ(約1km×1km)ずつ移動させ、松原ダム流域の流域平均累積雨量が最大となるような位置を探索することで、降雨データを作成した。なお、H29の九州北部豪雨は7/11~12と7/13~14の2度に分かれて強い降雨が生じているため、2つに分けてデータを作成した。

以上のa), b)により、合計20の仮想降雨事例を作成した。

c) 貯留関数モデルを用いた流入ハイドログラフの作成

ダム流入ハイドログラフ作成を目的とし、河川整備基本方針・整備計画で使用されている貯留関数モデルを構築した。貯留関数モデルは松原ダムに加え、上流の下笠




図-6 降雨分布のスライド手順と結果
(H29九州北部豪雨)

表-1 貯留関数モデルの流域定数・河道定数

流域名		流域面積 (km ²)	K	P	遅滞 時間 (分)	損失雨量定数			基底 流量 (m ³ /s)
						f		Rsa (mm)	
						f ₁	f ₂		
1	杖立川上流域	126.3	15.0	0.6	20	0.40	1.0	300	5.2
2	杖立川下流域	156.3	18.0	0.6	10	0.40	1.0	300	6.4
3	下笠ダム上流域	185.0	14.0	0.6	10	0.40	1.0	250	7.6
4	杖立～松原流域	23.4	12.3	0.6	0	0.40	1.0	300	1.0

河川名	区間名	流路長 (km)	K	P	遅滞 時間 (分)	摘要
杖立川	杖立ダム上流	6.4	—	—	30	遅滞時間のみ

ダムについても構築した。松原ダム・下笠ダムに関する流域定数・河道定数を表-1に示す。

貯留関数モデルの妥当性を確認するために、構築した貯留関数モデルを用いて、引き伸ばし前の実績洪水を対象として再現計算を実施した。再現計算においては、洪水毎に再現性が高くなるようにRsaを設定した。また松原ダムの計算においては、下笠ダムの実績放流量を与えた。再現計算結果の一部を図-7に示す。図に示す通り一定の再現性を確認した。この貯留関数モデルに引き伸ばし降雨およびスライドした九州北部豪雨を与え、仮想ハイドログラフを作成した(図-8)。

(3) ダム操作AIの学習

a) モデルの基本構成

ダム操作AIの基本構成は、階層型のニューラルネットワークとした。図-9にダム操作AIの模式図を示す。ニューラルネットワークの各ノードでは次のように計算を行う。

$$u = \theta_i + \sum_{i=1}^K w_i x_i \quad (1)$$

$$z = f(u) \quad (2)$$

ここで、 u は各素子の入力値、 x_i は入力値、 w_i は重み係数、




図-7 貯留関数モデルによる実績洪水の再現結果




図-8 引き伸ばし降雨での仮想ハイドロ (赤線)




図-9 ダム操作AIの模式図

θ_i はバイアス、 K は各階層の構成素子数、 $f(u)$ は活性化関数、 z は素子の出力である。

流入量や水位などダムの操作判断に関連した諸量をインプットとして、ニューラルネットワークにより適切な放流量を算出するモデルとした。具体的には、モデルの入力データは、現時刻～6時間後までの予測流入量データ、現時刻の流入量データ、10分前の放流量、10分前の貯水位とした。モデルの出力データは放流量とした。以上の設定により、各場面での状況に応じた放流量を出力するモデルを構築した。また現実的なダム操作の条件を反映させるため、下記の諸条件を組み込んだ。

- ダム管理者へのヒアリングから、松原ダムのダム操作は10分間隔で行うことが基本となっている。ダム操作AIについても10分ごとに最適なゲート操作(放流量の操作)の計算を行った。
- 現実的な放流量とするため、計算時の貯水位に

表-2 強化学習の基本設定

設定項目	設定内容
ネットワーク構造：素子数 (活性化関数)	入力層：11 中間層1：30 (シグモイド) 中間層2：30 (シグモイド) 出力層：15 (線形)
入力データ	・流入量 (現時刻) ・放流量 (10 分前) ・貯水位 (10 分前) ・上限水位と貯水位との差 (10 分前) ・10 分前からの放流量変化 ・予測流入量 (1 時間後～6 時間後)
出力データ	・0～最大可能放流量を 15 段階に区分した値

表-3 ダム操作AIの設定条件

入出力の設定	設定データ
学習率の設定方法	Adam (初期値 0.001)
学習エポック数	250
学習アルゴリズム	DQN (Deep Q NetWork)
行動選択	ϵ -greedy-annealed 法 $\epsilon = 0.5$ (開始時)、 $\epsilon = 0.001$ (200 エポック以降)
学習における 加減点方式	・洪水調節を行った (流入量>放流量) 際に調整流量に応じて加減点 ・異常洪水時防災操作開始水位を超えた場合に、超えた水位に応じて減点 ・上限水位 (=設計洪水水位) を超えた場合に、越流量に応じて大幅な減点 ・1 ステップの放流量変化が大きい場合に前ステップとの流量差に応じて減点

応じたゲート全開の場合の放流量を算出し、モデルの出力の上限として設定した。

- ・放流量の上限から15段階に区分した値をモデルの出力とした。
- ・実際のゲートの開閉速度を制約条件として、10分間での放流量変化の上限値をモデル上で計算し、10分ごとの放流量変化幅を制御させた。
- ・操作規則に基づき、流入量が洪水流量 (700m³/s) 以下の場合は、放流量=流入量とした。

b) 学習方法

前節で作成した仮想洪水 (仮想の流入量ハイドログラフ) を用いて、ダム操作AIの学習を行った。学習手法として、電力ダムの操作における既往の検討事例^{3), 4), 5)}を参考に、強化学習を適用した。強化学習とは、モデル自らが試行錯誤を行い、より良い結果を得られるように逐次的に学習を行う手法である。強化学習を適用するためには、結果に応じて与えられる報酬を適切に設定する必要がある。

本研究では、洪水調節を行った際に加点し、ダム天端から越流してしまった場合には大幅に減点するように報酬を設定した。また、非現実的な放流量変化が生じないように、放流量の変化量に応じて減点するように設定した。

強化学習のアルゴリズムについては、実装が比較的容易で研究事例の多いDQN (Deep Q-Network)^{6), 7)}を用い




図-10 操作規則モデルによる放流量計算結果




図-11 ダム操作AIモデルによる放流量計算結果




図-12 放流量の振動が確認されたケース

た。モデルの実装には、ディープラーニング用のソフトウェアライブラリであるTensorFlowを用い、ラッパーライブラリとしてKerasを用いた。強化学習の設定には、Kerasによって書かれた強化学習用のライブラリであるKeras-RLを用い、ダム操作や必要な学習条件の設定は、これらのソースコードに書き加えることで実装した。強化学習の基本構造は表-2の通りとした。

c) 学習条件の設定

学習条件を表-3に示す。モデルの行動選択は、学習開始時はランダム性を強くし、様々な操作を試行錯誤させる狙いとした。学習が進むにしたがってランダム性を小さくし、モデルの精度を上げる狙いとした。学習対象の20洪水を250回繰り返し学習した時点で学習終了とした。なお、本研究では洪水数は試行錯誤的に設定した。学習回数 (エポック数) は、学習時の報酬が概ね向上しなくなる回数で設定した。これらの設定は求める性能に応じて決める必要があると考えられる。表-2, 3に示した他の設定条件とあわせて、モデルの設計や学習方法、学習パラメータについては今後の検討の余地を残している。

(4) 学習結果

ダム操作AIモデルおよびダム操作規則モデルでの計算結果を図-10、図-11に示す。図に示すように、ダム操作規則モデルと同等の洪水調節機能が確認された。また、ダム操作規則モデルで上限水位を超過してしまうような洪水では、上限水位超過は回避できていないものの、超過時間を減少し、かつピーク放流量を減少させることができた。この結果から、評価関数の工夫により、ダム操作規則とおおよそ同等の操作を学習することができることが確認された。しかし、一部の計算結果において放流量の振動が確認され、学習が収束していない部分が見受けられた(図-12)。これは学習アルゴリズムの影響による可能性があるため、最適な学習アルゴリズムを検討する必要がある。

なお、ここでは6時間後までの予測流入量に仮想ハイドロの実データをそのまま与えている。すなわち、流入量予測が完璧にできたものという仮定でダム操作AIの計算を行っている。実際は予測流入量と実流入量には誤差が生じるため、ダム操作AIの精度も低下する可能性があり、今後の課題となっている。

4. モデルの感度分析の実施

(1) 評価関数を変化させた場合の結果の比較

前節の学習モデル(基本モデル)をベースとして、評価基準を調整し、学習結果を比較した。学習洪水等の基本的な条件は前項のモデルと同様とし、評価基準のみを表-4に示す条件に変更して学習を行った。Aモデルでは、洪水調節を行った際の加点および放流量変化に応じた減点の影響を大きくし、相対的に上限水位に近づくことによる減点の影響を小さくなるような条件に設定した。Bモデルでは、洪水調節を行った際の加点および放流量変化に応じた減点の影響を小さくし、相対的に上限水位に近づくことによる減点の影響が大きくなるような条件に設定した。計算結果を図-13に示す。

Aモデルでは、異常洪水時防災操作開始水位・上限水位超過による減点の影響が小さくなっているため、ほぼすべてのケースで上限水位を超過するまで、700m³/s(洪水調節時の最低放流量)を維持するような結果となった。また、基本モデルに比べ小規模出水でもある程度貯留ができていたのが確認された。

Bモデルでは、異常洪水時防災操作開始水位・上限水位超過による減点の影響が大きくなっているため、基本モデルよりもピーク水位が小さくなるような結果となった。また、基本モデルに比べ、小規模出水での貯留量がさらに小さくなっているのが確認された。

以上の結果より、目的に応じて評価基準を変更させることで、学習結果をある程度調整できることが示唆された。また、1つのモデルで様々な規模の出水に対する最

表-4 評価関数を変化させた場合の計算ケース

評価項目	基本モデルを1とした場合の 加点減点率	
	Aモデル	Bモデル
洪水調節を行った(流入量>放流量)際に調節流量に応じて加点	100倍	0.01倍
異常洪水時防災操作開始水位を超えた場合に、超えた水位に応じて減点	1倍	1倍
上限水位を超えた場合に、越流量に応じて大幅な減点	1倍	1倍
1ステップの放流量変化が大きい場合に前ステップとの流量差に応じて減点	100倍	0.01倍




図-13 各ケースの計算結果

(上: 基本モデル, 中: Aモデル, 下: Bモデル)

適解を算出するには、評価基準をより複雑にすることや、複数のモデルを並行して使用するなどの修正が必要であることが示唆された。

(2) 未学習の洪水の操作

前章の結果は学習済みの洪水に対する適用結果であったが、本来のAIの精度を検証するためには、未学習のデータで挙動をテストする必要がある。そこで、本検討では未学習洪水に対する検証計算を行った。具体的には、引き伸ばし降雨による17洪水を用いて、14洪水を学習データとしてダム操作AIモデルを学習した。学習済みのAIに残りの3洪水を与えたときの計算結果と、17洪水全てを学習データとしたAIでの計算結果を比較した。AI構




図-14 学習の有無による計算結果の比較 (1)
(上：学習済の事例，下：未学習の事例)




図-15 学習の有無による計算結果の比較 (2)
(上：学習済の事例，下：未学習の事例)

築時のパラメータは前節の基本モデルと同様である。計算結果を図-14、図-15に示す。図に示すように、上限水位を超過するような洪水や、ピーク水位が異常洪水時防災操作開始水位と同程度の洪水においても、未学習事例に対する計算結果は、前章の学習済み事例に対する計算結果とおおよそ同様であり、未学習の洪水に対しても大きな精度の低下は発生しないことが確認された。

5. おわりに

洪水時のダム操作支援を目的として深層強化学習を用

いたダム操作AIモデルを構築し、以下の成果を得た。

- ダム操作規則モデルと比較した結果、ダム操作規則に沿った操作よりも一部うまく洪水調節をする場合が確認できるなど、ダム操作AIの有用性が確認された。
- 強化学習の報酬の配点を工夫することで、操作規則を学習させなくとも、操作規則に沿ったダム操作に近づけられることが確認された。
- 目的に応じて評価基準を変更させることで、学習結果をある程度調整できることが示唆された。
- 未学習の洪水を与えた場合でも、学習済と同様の洪水調節結果が得られることが確認された。

一方、現実ではありえないような放流量の急激な変化（値の振動）が発生するなどの課題が確認された。また、本検討は6時間後までの正確なダム流入量が入力されているが、実際には実測との誤差が生まれるため、ダム操作AIの操作にも誤差が発生することが考えられる。ダム操作支援ツールとしての実用化に向けては、流入量の予測精度を考慮した精度検証、過放流の制御等のより現実的なダム操作の実現など、多くの課題が残されている。

今後はこれらの課題に対する検討を進め、ダム操作支援に資する技術開発を進めて行きたい。

参考文献

- 1) 小尻利治，池淵周一，十合貴弘：ファジィ制御によるダム貯水池の実時間操作に関する研究，京都大学防災研究年報，Vol.30, pp. 323-339, 1987.
- 2) 長谷部正彦，長山八州稔，糸川高德：治水用貯水池操作へのファジィ・ニューラルネットワークシステムの適用について，水工学論文集，Vol.40, pp. 133-138, 1996.
- 3) 大東真利茂，小槻俊司，三好健正：機械学習を用いたダム操作最適化システムの開発への取り組み，水文・水資源学会2018年度研究成果発表会，2018.
- 4) 田中友紀子，平岡拓也ら：電力ダム操作における強化学習型シンボルグラウディングによる意思決定支援に関する検討，第32回人工知能学会全国大会，2018.
- 5) Abhiram Mullapudi, Branko Kerkez: Autonomous control of urban storm water networks using reinforcement learning, 13th International Conference on Hydroinformatics, 2018.
- 6) Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D., and Riedmiller, M.: Playing atari with deep reinforcement learning, *arXiv preprint arXiv:1312.5602*, 2013.
- 7) Mnih, V., Kavukcuoglu, K., Silver, D., et al.: Human-level control through deep reinforcement learning, *Nature*, Vol.518, pp. 529-533, 2015.

(2019. 4. 2受付)