

水工学シリーズ 21-A-8

河川・水防災におけるAI技術の活用

日本工営株式会社中央研究所 課長

一言 正之

土木学会

水工学委員会・海岸工学委員会

2021年8月

河川・水防災における AI 技術の活用

Application of AI technology in river and water disaster prevention

一言 正之

Masayuki HITOKOTO

1. はじめに

人工知能 (AI) の発展は著しく、社会実装も進んできている。特に深層学習 (ディープラーニング) をコアとした技術革新が起きており、いわゆる教師あり学習のみでなく、半教師あり学習 (強化学習)、画像生成など、より高度な技術の応用研究が進められている。また近年は、様々な分野での AI 応用が進められており、専門領域でのドメイン知識と組み合わせた AI の開発が進められている。

土木分野、水工学分野においても、AI 技術の活用に向けた研究が盛んである。著者らは、河川・水防災に対して AI 技術の活用に取り組んでおり、洪水災害の被害低減に向けて精度の高い洪水予測¹⁻¹⁰⁾や、効率的なダム操作¹¹⁻¹³⁾のための研究を進めてきている。近年は、洪水予測においては経験したことの無いような大洪水の予測⁵⁾や、予測が困難な都市中小河川での適用⁸⁾、画像認識技術とレーダ観測を組み合わせたより高度な予測⁷⁾など、有効性を高めるためにより困難な条件での適用性向上に取り組んでいる。またその他にも、水位観測データに含まれる異常値の検知¹⁴⁾、堤防からの越水が生じてしまった際の洪水氾濫域の推定¹⁵⁾、地形データから土砂災害の危険区域の抽出¹⁶⁾、といった様々な課題に対して AI 技術の活用を進めている。

本稿は、初めに AI 技術のごく簡単な概要を示したのちに、河川・水防災分野における AI 技術の活用事例を筆者らの取り組み (降雨-流出予測, ダム操作) を中心に紹介する。

2. AI 技術のエッセンス

AI・機械学習については数多くの参考書籍が出ているが¹⁷⁻¹⁹⁾、ごく大まかな概要を記す。

2.1. AI 技術の概観

近年、人工知能 (AI) の発展が著しい。最近では AI の囲碁ソフトがトッププロを破ったことで大きな話題になった。近年の AI のカギとなっているのが機械学習と呼ばれる手法であり、特にディープラーニング (深層学習) という新しい学習手法の登場により技術革新が急激に進んでいる。ディープラーニングの特徴として、学習モデル自らが、大量の入力データの中から本質的な情報の抽出を行うことが挙げられる。ディープラーニングは、画像認識や音声認識、自然言語処理など様々な分野で研究が進んでいる。

ディープラーニングとは、AI 技術の中で機械学習と呼ばれる分野の、さらにニューラルネットワークと呼ばれる一手法の中の一つである (図-1)。ディープラーニングの中でも、数値データ解析、画像解析、画像生成、自然言語処理、強化学習など様々なモデルがある。

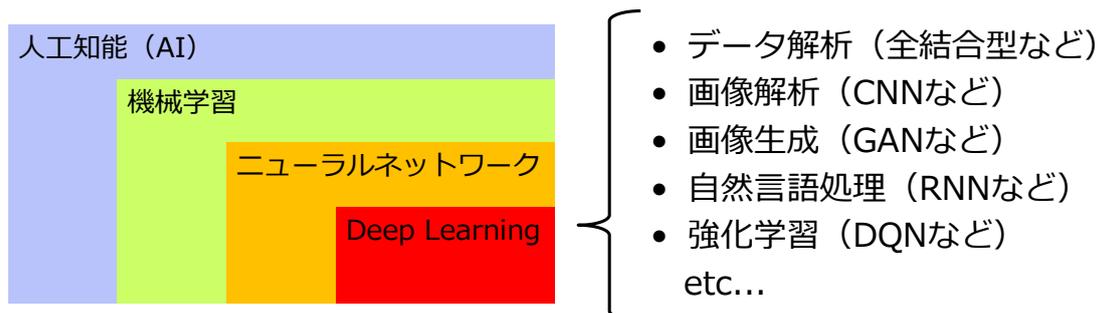


図-1 ディープラーニングと関連する AI 技術の包含関係

2.2. 機械学習の基礎

機械学習とは、数理的なモデルによってデータ間に潜む関係（ルール）を見つけ出す技術である。ごく大雑把に言えば、回帰+分類（図-2）を行う技術だと言える。回帰とは複数の因子から因果関係を求めるものである。例えば降雨から河川流量の関係を予測したり、経年数から構造物の劣化度合いを予測したり、といった使い方が考えられる。分類とは、データを複数のカテゴリーに分けることである。例えば、使用単語から迷惑メール/通常メールを分類する、累積雨量から土砂災害の発生/非発生を分類する、といった使い方がある。先に挙げた画像解析、画像生成、自然言語処理などの複雑なモデルにおいても、根幹では回帰・分類のテクニックが使われている。

回帰式による機械学習のシンプルな例として図-3を示す²⁰⁾。図は10個のデータに1次式、3次式、9次式を最小二乗法で当てはめた（学習させた）ものであり、赤線が学習結果、緑線が真の関係、青丸が観測データである。図中央の3次式の例では、赤線はデータの真の関係を表現できており、学習がまずまず成功した例とみなせる。1次式の例では、赤線はデータを近似できていない。一方、9次式の例では、赤線は観測データをピッタリ通っているが、データの真の関係を全く表現できていない。9次式の例のように、観測データに過度にフィッティングして汎化に失敗することを過学習と呼ぶ。モデルを学習データにあてはめつつ過学習を避けることがAIの学習の本質とも言え、過学習を避けるために様々なテクニックが考案されている。

その他の機械学習手法の分類を表-1に示す。教師なし学習は、データ構造やパターンを抽出する手法である。強化学習は、目的として設定された報酬を最大化するための行動を学習する手法である。

表-1 機械学習の模式図（六次の多項式を用いた例）

機械学習手法の分類	手法の役割
教師あり学習	分類 回帰
教師なし学習	クラスタリング 次元圧縮 など
強化学習	試行錯誤により、報酬を最大化する方策を学習する。

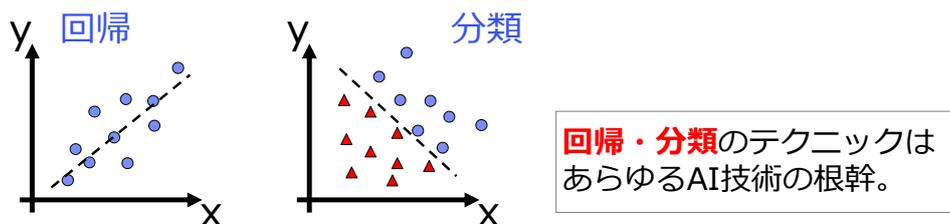


図-2 機械学習による回帰と分類の模式図

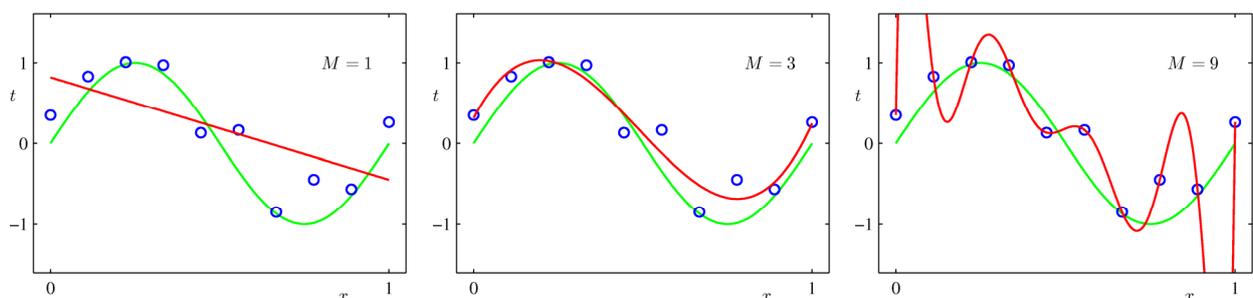


図-3 機械学習の模式図（左から1次式、3次式、9次式によるフィッティングの例）

3. AIによる洪水予測

3.1. 洪水予測の背景

洪水災害に対するソフト対策として、洪水予測技術の高度化が求められている。洪水予測の基本的な技術として、降雨から河川の水位・流量を計算する降雨-流出解析がある。降雨-流出解析手法の分類を表-2に示す³⁾。代表的な手法として、降雨-流出過程を物理的に表現した流出モデルを基盤とする手法、および過去の洪水データに基づき、気象・水文の観測データから直接水位を予測する手法がある²⁾。物理型の流出モデルは、実用的に全国の河川で適用されているが、予測の過程に様々な誤差が内在する。一方の直接水位予測手法は、実用例は限られるものの、有力な手法として研究が進められている。特に、ニューラルネットワーク (Artificial Neural Network: ANN) による洪水予測も、統計的手法の一種として古くから適用性が確認されている²²⁻²⁵⁾。ANNでは上流の水位や雨量を入力データとして下流の水位・水位変化を学習することで水位予測を行うことができる。

本章にて ANN を中心に AI による洪水予測手法の概要について述べる。

表-2 降雨-流出解析手法の分類³⁾

大分類	中分類	小分類	長所	短所
物理型 流出 モデル	概念 モデル	タンクモデル	計算が比較的簡単、様々な流出波形を表現できる	パラメータの物理性が弱い
		貯留関数法	計算が比較的簡単、全国の洪水予測システムで実績	パラメータの物理性が弱い
	物理 モデル	分布型モデル	降雨-流出の過程を詳細に表現、地形や降雨の分布を反映	モデル構築やパラメータチューニングの労力が大きい
	その他	概念モデルを分布させたモデルや、要素集合型などが提案されている。		
直接 水位 予測 手法	統計的 手法	時系列解析 (AR, ARMA, ARIMA など)	モデル構築が簡便、計算が簡易	降雨-流出の非線形性を表現できない
		機械学習 (線形回帰, ANN, SVM など)	非線形性を含めた高い表現能力、豊富な使用実績	計算過程がブラックボックス、データが多く必要
	その他	ファジィ、事例ベースなど、様々な手法が提案されている。		

3.2. 機械学習による洪水予測の超基礎

機械学習による洪水予測では、気象・水文の観測データなどを入力条件として、河川の水位・流量を算出する。最もシンプルな例として、図-4左のような流域に2つの水位観測所がある場合を考える。上流B地点での水位変化は、流下時間の分だけ遅れて下流A地点に伝わるはずである。仮にBからAへの流下時間が1時間であれば、両地点の水位変化は1時間差で強い相関を持つ。出水時の水位データをプロットすれば、図-4右のような相関関係が見られるはずである。この時、式1のような相関式が書ける。

$$\Delta H_A^t = \alpha \Delta H_B^{t-1} + \beta \quad (1)$$

ここで、 ΔH は時間当たりの水位変化、 t は時刻、 α 、 β は相関式の係数、添え字のA、Bは観測所を表す。B地点での観測データから上式の ΔH_B に値を代入すれば、A地点の1時間後の水位を求めることができる。すなわち、式(1)は地点Aのシンプルな水位予測式となっている。

実際の河川では、河川の合流の影響や、広い流域ではエリアによって降雨分布や流出特性が異なる場合もあり、式(1)のような単回帰の式では十分な予測精度が得られない場合もある。そうした場合は、複数の入力データを扱える重回帰式や、ニューラルネットワークなど機械学習のモデルを使うことで、予測精度の向上が期待できる。

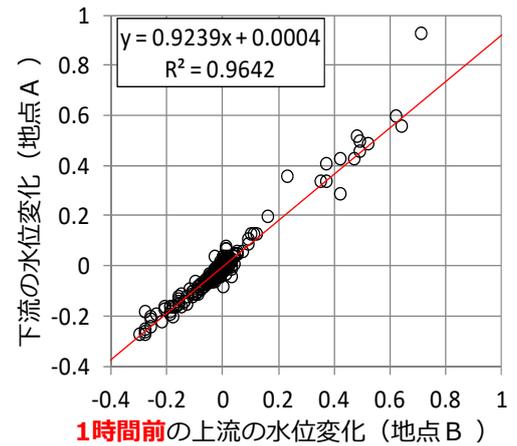
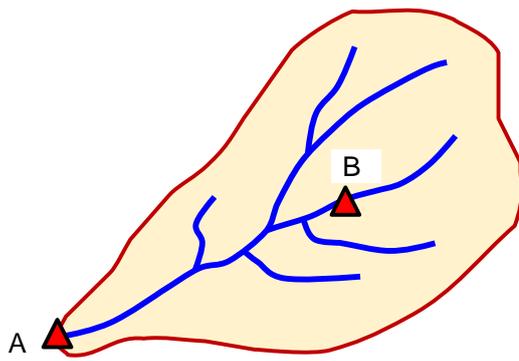


図-4 仮想流域における流域模式図と、上下流の時間あたり水位変化データのプロット

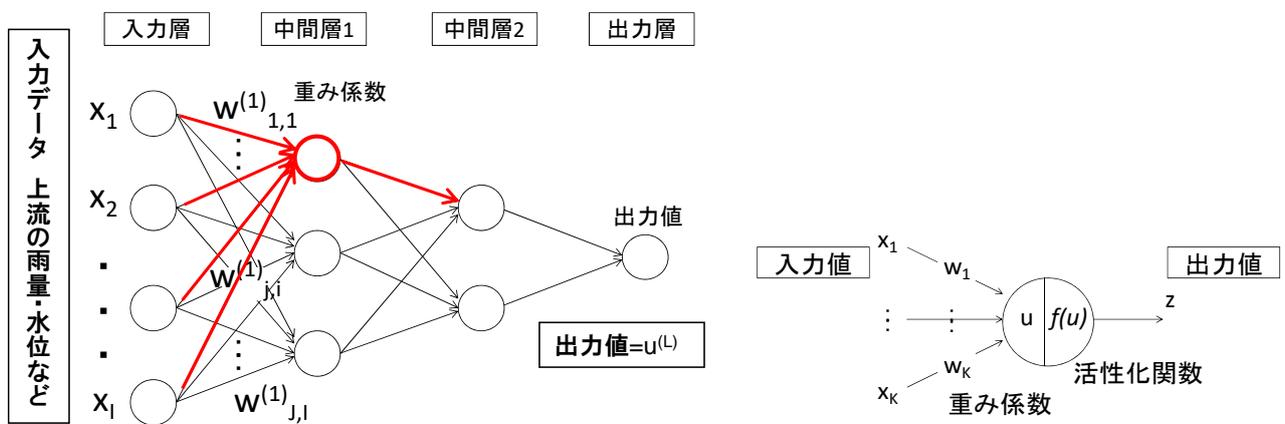


図-5 階層型の全結合ニューラルネットワークによる水位予測モデルと、ネットワーク構成素子の模式図

3.3. 全結合ニューラルネットワーク (FCNN) による予測

(1) ANN の構成

本検討で用いたモデルは、入力層・中間層・出力層から構成される階層型ネットワークとした (図-5 左)。ネットワークを構成する素子の模式図は図-5 右に示すとおりであり、各素子において以下のように計算を行う。

$$u = \theta_i + \sum_{i=1}^K w_i x_i \quad (2)$$

$$z = f(u) \quad (3)$$

ここで、 u は各素子の入力値、 x は入力値、 w は重み係数、 θ 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。本稿で以下はバイアスも含めたパラメータベクトル w を改めて重み係数と呼ぶ。なお入力層・中間層の活性化関数には、シグモイド関数や ReLU などが用いられる。

$$\text{シグモイド関数: } f(u) = 1/(1 + e^{-u}) \quad (4)$$

$$\text{ReLU: } f(u) = \max(u, 0) \quad (5)$$

また、出力層の活性化関数は恒等写像 ($f(u) = u$) を用いた。

(2) ANN の学習方法

ネットワークの学習は、出力層と目標出力（実績値）との誤差が最小化するように、各素子間の重み係数 w を最適化することで実現される。出力と実績の誤差は以下の二乗誤差 E で評価する。

$$E(w) = \frac{1}{2} \sum_{n=1}^N (d_n - y(x_n; w))^2 \quad (6)$$

ここで、 N はサンプルデータ数、 d は目標出力、 y はネットワークの出力値である。ランダムに初期化された重み係数 w に対して、学習データを用いて最適化手法を適用することで E を極小化する w を得る。本研究では、最適化手法に確率的勾配降下法¹⁸⁾を用いた。通常の勾配降下法では、全学習サンプルから誤差関数を求めるのに対し、確率的勾配降下法では学習データの一部（ミニバッチ）を取り出して誤差関数を評価する。通常の勾配降下法に比べ、学習の高速化や局所解への収束を避ける上でメリットを有する。 w の更新は次式のように行う。

$$w^{(t+1)} = w^{(t)} - \varepsilon \nabla E \quad (7)$$

ここで、 ε は学習係数であり、 w の更新量を決めるパラメータである。誤差関数の勾配 ∇E の算出には誤差逆伝搬法を用いる。学習係数の設定は、素早く安定して最適化計算を収束させるために重要である。近年は Adam などが用いられることが多い。

学習データの関連性を十分に学習し、かつ過学習（学習データ中のノイズ等に対する過度な適合）による精度低下を避けるため、ドロップアウト²⁰⁾を適用した。ドロップアウトは図-6のように、学習計算時にネットワークの素子を確率 p の割合で無効化することで、ネットワークの自由度を強制的に小さくし、過学習を避ける狙いがある。望ましい ANN モデルを構築するためには、過学習を避け、入出力データ間の一般的な関係性を学習することが重要である。

(3) ニューラルネットワークと深層学習

深層学習とは、複数の中間層を持ったニューラルネットワークの学習を指す言葉であるが、ネットワークそのものを指して言う場合も多い。深層学習の長所として、高い学習能力が挙げられる。従来の単一中間層の ANN による学習では、入力データが増大すると、同定すべき未知パラメータが膨大となり、学習効果が低下することが課題とされていた。そのため、ネットワークの目的とする出力に対して、できる限り重要な入力データを選定することでデータ数を絞り込み、パラメータ数を極力減らすことが必要とされてきた²³⁻²⁵⁾。一方で深層学習では、多数の入力データが多数であっても、学習過程において重要な情報が自動的に絞り込まれていく能力あるとされている²⁷⁾。流出解析においては、多数の水文・気象データを入力層に使うことで精度向上が報告されており（図-7）⁴⁾、従来型ニューラルネットワークに対する深層学習の大きなメリットだと言える。

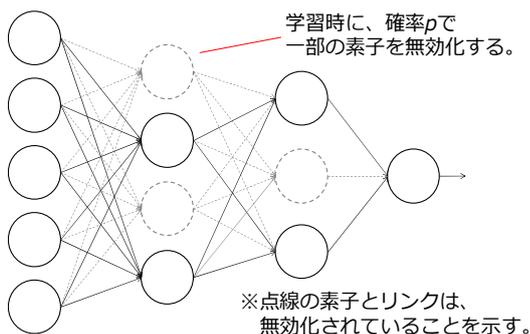


図-6 ドロップアウトの概念図

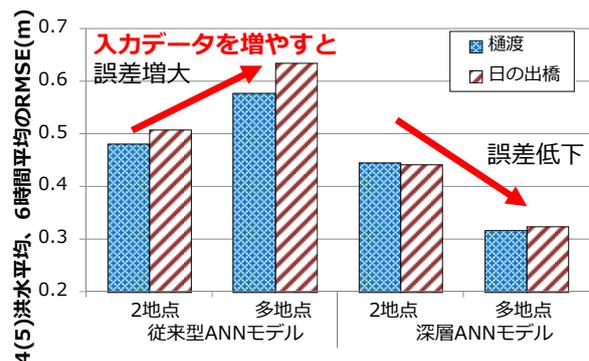


図-7 モデルとデータ数に応じた水位予測モデルの誤差⁴⁾

(4) 深層学習を用いた洪水予測の実流域での適用

開発した深層学習による水位予測モデルを、大淀川水系の樋渡（ひわたし）地点の上流域（図-8 左上）に適用した。流域面積は 861km²、幹川流路延長は 52km である。周辺に雨量観測所が 14 箇所、流域内に水位観測所が 5 箇所設置されている。検討に用いた観測データは水文水質データベース²⁸⁾から取得し、1982 年～2014 年の上位 24 洪水を抽出した。計算に用いたニューラルネットワークは、入力層、2 層の中間層および出力層からなる 4 層のモデルとした。入力データは 14 の雨量観測所における時間雨量（5 時間分）、5 つの水位観測所における 1 時間当たりの水位変化（3 時間分）、および樋渡水位観測所の水位（2 時間分）とした。出力データは樋渡の水位変化とした。1～6 時間の水位を予測するため、予測時間ごとにそれぞれニューラルネットワークを構築し、入出力データも予測時間に応じて設定した。なお設定の詳細は文献²⁹⁾に記されている。

対象 24 洪水のうち、氾濫危険水位（9.2m）を超過した 4 洪水を対象として精度を評価した。深層学習モデルによる水位予測結果と、①分布型モデル+粒子フィルタ、②分布型モデル+スライド補正、③従来型ニューラルネットワーク、④線形回帰モデルについて、精度を比較した。ここで、①や②は物理的な水位予測のうち有力と考えられる手法である。また、従来型ニューラルネットワークは中間層が 1 層のみのモデルであり、また事前学習は行っていない。なお、ここではいずれの計算も予測雨量の代わりに実際に観測した雨量を用いている。

4 洪水平均での 1 時間～6 時間予測の RMSE を図-8 左下、各モデルの水位予測結果を図-8 右に示す。深層学習による水位予測モデルは、従来型のニューラルネットワークや物理型モデルなどを上回る予測精度を示す結果となった。

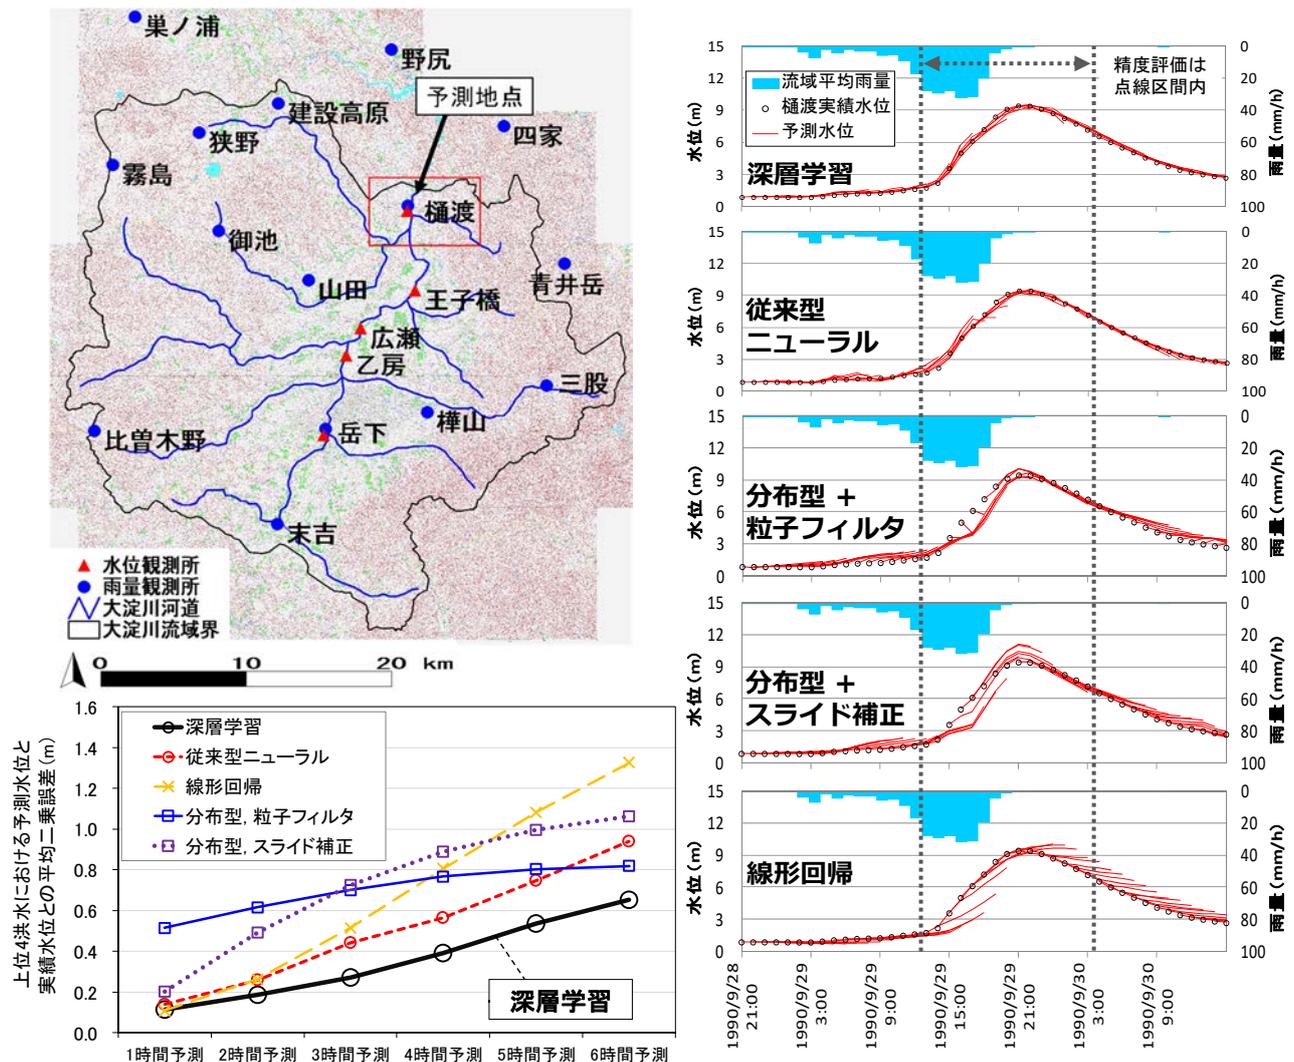


図-8 大淀川流域の位置図（左上）、深層学習モデルと他モデルとの精度比較（左下）および水位予測結果（右）

3.4. 畳み込みニューラルネットワーク (CNN) による予測⁷⁾

(1) 畳み込みニューラルネットワークによる画像認識技術の可能性

ディープラーニングとは深い階層構造を持ったニューラルネットワークの総称であり、いくつかの種類がある。前頁の洪水予測検討では「全結合型」と呼ばれるネットワーク (図-5) を用いたが、一般に画像認識などでは「畳み込みニューラルネットワーク (CNN)」により二次元的なデータを扱う。近年は CNN を始めとした画像解析 AI の性能が飛躍的に向上しており、様々な分野での応用が進んでいる。本検討では CNN を洪水予測用に改良する。地点雨量や平均雨量のデータを用いた予測に代えて、CNN により雨量レーダの面的な情報を取り込んだ予測手法を開発した。

(2) 畳み込みニューラルネットワークの概要

畳み込みニューラルネットワークは、畳み込み層とプーリング層という二つの層を含む構造のニューラルネットワークであり、深層学習の一種である。二次元データの扱いを得意としており、近年の画像認識 AI の発展を後押ししている。畳み込みニューラルネットワークでは、データの畳み込み、プーリングといった処理が行われる。計算手順の概要を以下に示す。

a) 畳み込み

畳み込みでは、一定領域の情報をもとに集約して接続し、空間情報 (隣り合うセル同士の関連) が維持された特徴マップを作成する (図-9)。畳み込みは式 (8) のように、画像データとフィルタとの積和計算で表わされ、画像内から線、輪郭、形状などといった特徴を抽出する役割を果たす。

$$u_{ij} = \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} x_{i+p,j+q} h_{pq} \quad (8)$$

ここで、 x は画像セルの値、 u は畳み込みの計算結果、 H はフィルタのセルサイズ、 h はフィルタセルの値、 ij は画像セルの id、 p,q はフィルタセルの id である。畳み込み処理の後では、フィルタの数だけ特徴マップが作成される。

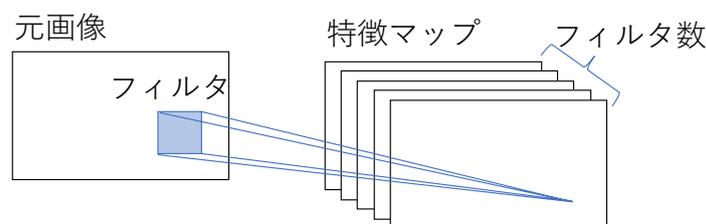


図-9 畳み込み処理の概念図

b) プーリング

プーリングでは、特徴マップの空間的な特徴を維持しながらサイズを圧縮する。一定領域内 (次式の P_{ij}) の最大値を取る MAX プーリングや、平均をとる Average プーリングなどの手順が考案されているが、本研究では広く用いられている MAX プーリングを用いた。

$$u_{ijk} = \max_{(p,q) \in P_{ij}} z_{pqk} \quad (9)$$

c) 配列の変換

最終的な予測値を出力するため、三次元のデータ (画像サイズ縦×画像サイズ横×フィルタ数) を一次元のデータに並べ替える。変換された一次元のデータは、前節で紹介したような全結合型のネットワークに接続し、最終的な予測値を出力する。

(3) 河川水位予測へのCNNの応用

予測地点上流の降雨分布を入力データ、現時刻から先までの水位変化を出力データとすることで、CNNによる水位予測を行った。CNNによる河川水位予測の入力データの模式図を図-10に示す。一般的な画像認識では、入力データはRGBの3チャンネルから構成される二次元データである(図-10左)。今回の水位予測では、複数のレーダ雨量データ(生の数値データ)の二次元データを用い、時系列に複数の雨量分布を複数チャンネルに対応させることで入力データとした(図-10右)。また予測地点上流の水位データを二次元に並べることで、入力データのチャンネルに加えた。なお、水位データは畳み込み処理の後の全結合層の部分に一次元データとして入力するようなモデル構造も考えられる。

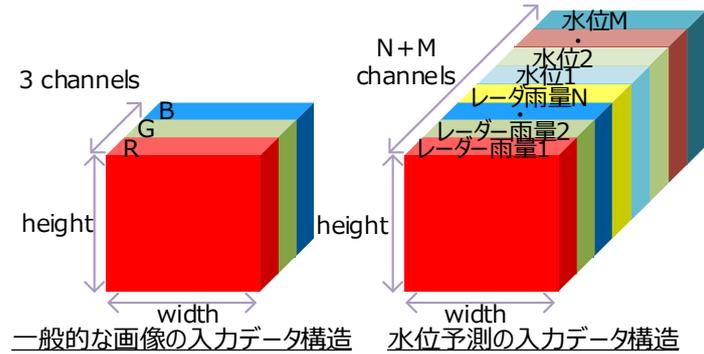


図-10 CNNによる水位予測モデルの入力データ模式図

(4) CNNを用いた水位予測モデルの実流域での適用

対象地点は、図-11左に示す筑後川水系城原川の日出来橋とした。流域面積は64.4km²、幹線流路延長は31.9kmである。中流域は天井川となっており、下流域はゼロメートル地帯のはん濫地形で、天井川が越水した際は周辺市街地が浸水するリスクを抱えている。レーダ雨量が入手できた2006年以降について、日出来橋の上位30出水を抽出し、26出水を学習に、4出水を精度検証に用いた。本検討では、時系列的な雨量情報を画像データの構造に見立て、60分後までの水位変化を出力とすることで水位予測モデルを構築した。予測結果の例を図-11右に示す。いずれの出水においても洪水の挙動を再現できた。予測がずれる箇所もあるが、学習データの蓄積などにより今後の精度向上の余地がある。

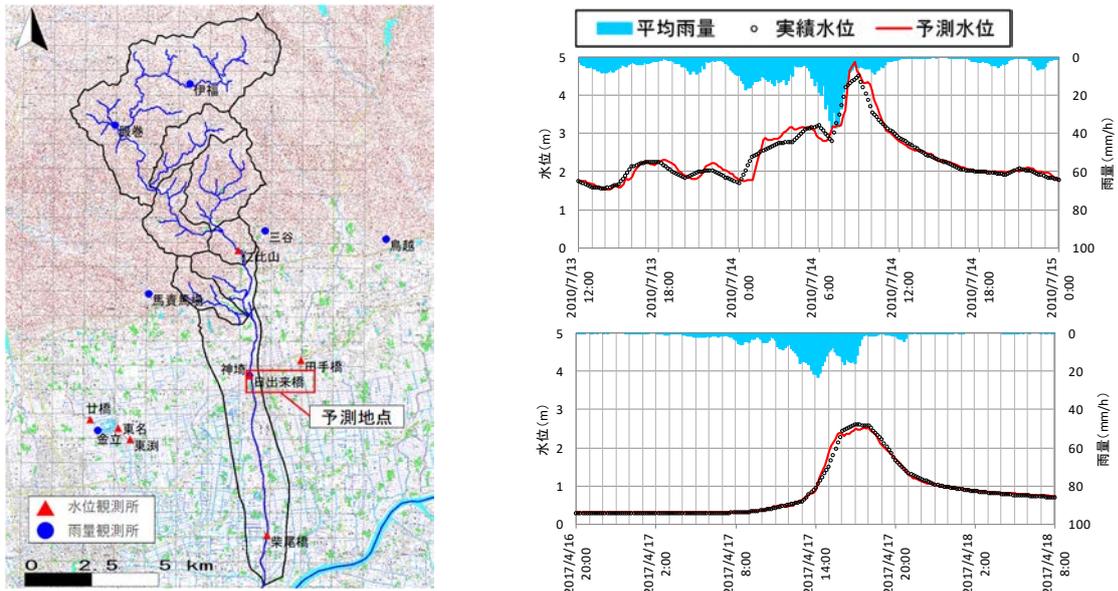


図-11 城原川流域と日出来橋の位置図(左)、およびCNNによる水位予測計算結果(右)

3.5. AIによる流出予測の様々な工夫

ここまでAIによる流出予測手法を紹介したが、ここで挙げたやり方以外にも様々な工夫の余地がある。

(1) 入力データの工夫

前節までは降雨・水位を入力データとして流出予測を行っていたが、入力を工夫することで精度向上や適用範囲の拡大が期待できる。

洪水発生メカニズムに立ち返って考えると、一般に山間部などに降った雨の大部分は地中へとしみこみ、地中流などを通じて谷底へ流れ集まる。雨が降り続けば、地中から溪流や河川への流れ込みは活発となる。逆に、先行降雨がない場合は少々の雨は地中などに貯留され、河川へは流出しない。このようなメカニズムは貯留関数法（式(10)）やタンクモデルにおいても表現されており、河道への流出量を規定するものは、降雨ではなく流域の水分貯留量だと定義されている。

$$\frac{dS}{dt} = R_{(t-T_L)} - q(t), \quad S = kq^p \quad (10)$$

ここで、 S は貯留量、 R は雨量、 k 、 p は流出パラメータ、 q は流出量、 t は時刻、 T_L は遅滞時間である。なお通常の貯留関数法では、損失雨量や流出成分の分離などが考慮されるが、ここでは議論しない。式(10)より、流出量 q は貯留量 S に依存する。したがって、現時刻から数時間後までの流量変化 Δq は、貯留量変化 ΔS と対応するものと考えられる。以上より、水位・流量変化を予測するための機械学習モデルの入力層には、雨量 R よりも貯留量変化 $\Delta S = R_{(t-T_L)} - q(t)$ が適していると考えられる。筆者らは、物理モデルとのハイブリッドにより貯留量変化を入力とした深層学習モデルを構築し、水位予測の精度向上を試みている³⁾。

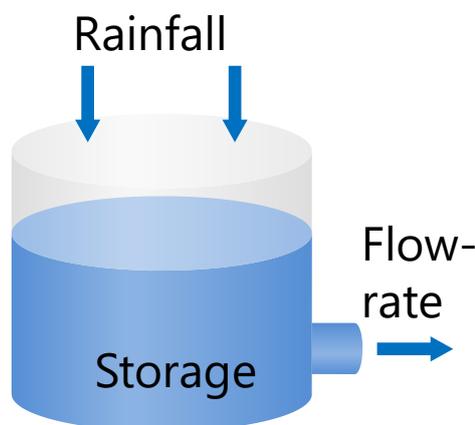


図-12 貯留関数モデルで表される流域貯留量

その他にも、土壌雨量指数を入力データに加えることでダム流入量予測の精度向上を図った研究^{29), 30)}、降雨量の時間減衰値により流域貯留量を表現し、それをディープラーニングの入力データに加えることで水位予測の精度向上を図った研究³¹⁾など、入力データに工夫を加えた研究が様々に見られる。また融雪出水を対象として、気温・積雪・風速・日照などの観測データをニューラルネットワークの入力に用いることで、融雪出水の予測を試みるとともに、重要因子の抽出を試みた研究³²⁾がある。堆砂が多い河川において、浮遊砂量を入力データに用いるとともに、洪水流量や浮遊砂量に応じて複数の回帰モデルを使い分けることで精度向上を図った研究がある³³⁾。このように対象とする流域や出水の条件によっても、様々な工夫の余地があると考えられる。

(2) 出力データの工夫

本稿で紹介した手順では、現時刻から予測時間後までの水位変化を算出している。リアルタイムに洪水予測を行う場面では、現時刻から水位がどれくらい上がるのか/下がるのかを知りたいので、このように水位変化を予測す

るのが自然だと思われる。学習データを上回る洪水を予測する際に、学習データのモデル外挿となってしまうのを避ける意味でも、水位変化を予測対象にすることが適切と考えられる²⁴⁾。

一方で、現時刻からの水位変化ではなく、水位そのものを算出するようなモデルも考えられる。長時間先を予測する場合には、現時刻の水位はあまり影響しなくなるため、水位そのものを予測するモデルが適していると思われる。また、現時刻の水位に誤差が含まれる可能性がある場合では、水位変化を予測するのは困難になるだろう。

その他にも、ダム流入量を対象に年成分・季節成分・ノイズ成分など分離し、各成分を求めることで精度向上を図った研究がある³⁴⁾。このように、出力データの設定にも状況に応じた工夫の余地がある。

(3) モデルの工夫

本稿では深層学習（全結合型、CNN）による予測モデルを紹介したが、それ以外にも LSTM（Long Short Term Memory）³⁵⁾、SVR（Support Vector Regression）、回帰木や、複数のモデルのアンサンブルによる予測など、様々な機械学習モデルの適用が研究されている³⁶⁾。また、他河川を学習したのちに転移学習により対象河川の予測精度向上を図った研究^{37),38)}、複数流域のデータをまとめて学習することでモデルの汎化性能向上を図った研究³⁹⁾など、様々な興味深い取り組みがなされている。

(4) AI による洪水予測の今後の課題

機械学習を用いた洪水予測モデルの欠点として、学習事例を上回るような大洪水に対する適用性が指摘される。すなわち、学習事例の内挿となるような問題に対しては適切なアウトプットを出すことができるが、外挿問題では適用性が低いと言われている。防災上の観点からは、規模の大きな洪水こそが予測したい事象であるため、このことは大きな課題として残っている。前項で述べたような入力・出力の工夫により適用性を高める方法などが提案されている⁹⁾が、今後も様々な視点からの研究が期待される。

また物理型の流出モデルにおいても、一般には過去の洪水でパラメータを調整するため、やはり未経験規模の洪水に対しては適用性が落ちるはずである。未経験規模の洪水に限らず、物理型モデルと機械学習モデルの比較はまだ十分には進んでいないように感じられる。様々なケースで両者の得意な点・苦手な点の洗い出しを行うとともに、状況に応じて使い分けたり、相互に組み合わせて使うような新しい研究が期待される。

4. AIによるダム操作

4.1. ダム操作の概要

2018年の西日本豪雨や、2019年の令和元年東日本台風など、降雨による水害リスクが顕在化している。河川の洪水災害への対策の一つとして、ダムによる洪水調節の機能を最大限に活用することが期待される。

ダムによる洪水調節の仕組みを図-13に示す。通常の洪水調節では、図-13左のように河川からダムへの流入を貯留し、放流量を少なくすることで下流の洪水を防いでいる。しかしながら、洪水中に下流への放流量を減らせば、まもなくダムは満杯になってしまう（図-13右）。逆に満杯にならないように放流量を増やせば、洪水調節の効果は少なくなってしまい、ダム下流での水害リスクが高くなる。したがって、ダム容量の余裕や洪水流量、ダム下流河川の危険度などを踏まえて、ちょうどよい放流量を決めなければならない。洪水調節を行うダムでは、ダム上流で想定される降雨や、下流河川の安全性を見込んで、ダム操作のためのルール（操作規則・操作細則、ただし書き操作規則など）が定められている。ダム管理者は、これらに基づいて放流操作を行うことが義務付けられている（図-14）。しかしながら、想定以上の洪水時や、実際に下流が危険にさらされている場合、一つの河川の上流域で複数のダムが同時に放流を行う場合など、ダム操作には難しい判断が求められる。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。

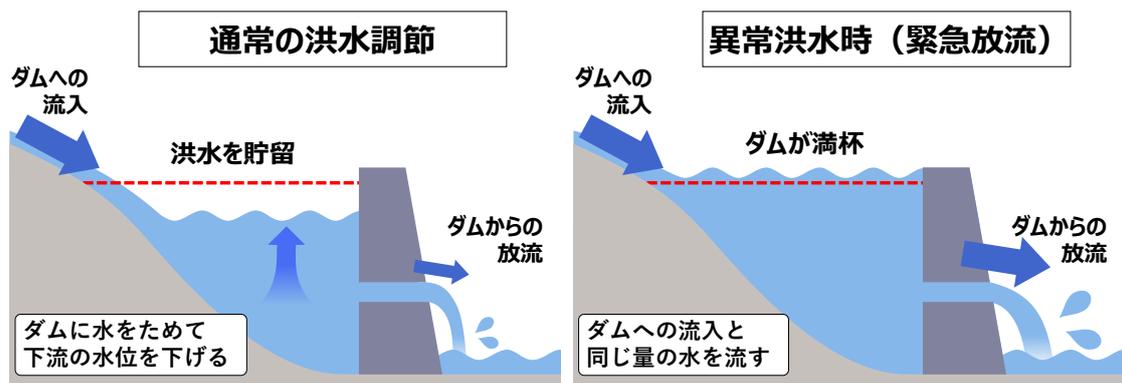


図-13 ダムによる洪水調節の仕組み

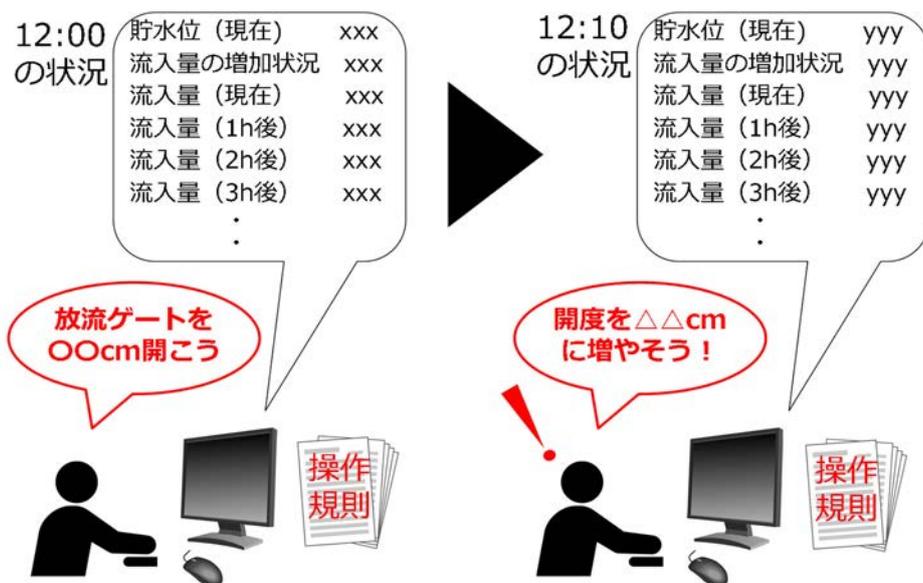


図-14 ダムのゲート操作判断の模式図

4.2. AIによるダム運用の効率化の検討

洪水時のダム操作をより効率的に行うため、ダム流入量の正確な予測、ダム放流に伴う下流河川の危険度の把握、利水・治水のバランスを踏まえた柔軟な放流操作、といった研究が進められている。洪水時のダム操作効率化のため様々な検討が行われており、以前からAIを用いたダム放流操作も検討されている。ファジィ理論を用いた例⁴⁰⁾や、ファジィ・ニューラルネットワークシステムを用いた例⁴¹⁾などがある。近年では、深層強化学習を用いたダム・貯水池の運用効率化が検討されている^{11-13,42-45)}。筆者らは、洪水時のダム操作に着目して、深層強化学習を用いたダム操作AIの構築を試みている¹¹⁻¹³⁾。

なお、ダムを有効活用する方法として、洪水の数日前から放流（事前放流）を行い、一時的に容量を大きくして洪水に備える運用が行われるようになってきている。降雨予測の精度などによる難しい面もあり、より良い運用のための研究が進められているが、本稿では扱わない。

4.3. 深層強化学習による洪水時のダム操作モデルの構築手順

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、上流には下笠ダム（流域面積185km²）が含まれる（図-15）。ダム流入量が700m³/s以上になると洪水調節を開始し、計画高水流量は2770m³/s、調節後流量は1100m³/sである。ダム貯水位が洪水調節容量のおよそ8割に相当する貯水位（268.1m）に達した後は異常洪水時防災操作を実施し、放流量が流入量と等しくなるまで徐々にゲートからの放流量を増加させるものとしている。洪水調節容量は4580万m³で、洪水時最高水位は273.0mであり、その上に上限水位（設計洪水水位）が定められている。洪水時の放流はコンジットゲート3門、クレストゲート4門により行う。

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。具体的な検討手順を図-16に示す。まず、AIの学習に用いる仮想降雨データ、仮想流入量データを作成する。仮想流入量データを用いて、ダム操作を行うAIモデルの学習を行う。学習済みのダム操作AIモデルについて、筑後川水系の松原ダムを対象に精度検証を行う。10分に1回、AIによりダムの放流量を決定するものとし、仮想洪水に対する操作シミュレーションを行った。AIの結果と、現行の操作規則と比べた差異についても考察を行った。

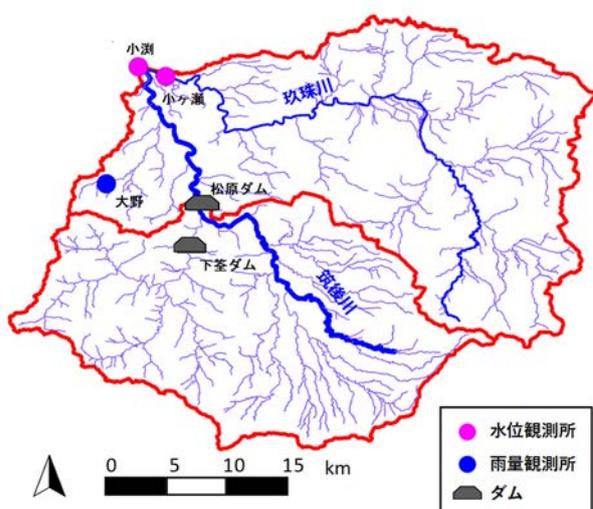


図-15 松原ダム流域

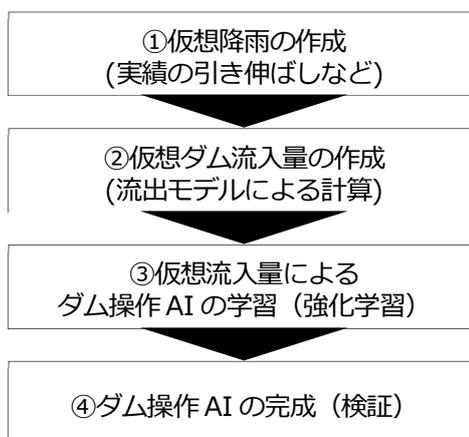


図-16 ダム操作AIの構築手順

4.4. 深層強化学習のための学習データの作成

(1) 仮想降雨データの作成

2006年～2018年における松原ダムにおける主な出水データを整理した。期間中で最大の出水（2016年6月23日）は、ピーク流入量が1382.4m³/sであり計画高水流量（2770m³/s）よりも大幅に小さい。操作の実績についても、異常洪水時防災操作に移行することなく、問題なく洪水調節が行われている。

多様な洪水に対して柔軟なダム操作を身につけさせるため、様々なパターンの学習用の仮想降雨を作成した。まず、降雨の元データとして、国土交通省によるレーダ雨量（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洪水を選定した。ただし、これらの過去の洪水は計画洪水よりも大幅に小さく、異常洪水時防災操作などに移行することなく洪水調節が行われている。従って、実績のデータのみでは大規模な洪水に対するAIの学習が十分にできない。大規模出水に対するAIの適用性を確認するため、既存の操作規則では対応が難しいような大規模降雨データを仮想に作成した。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、実績の降雨強度に倍率をかけて引き伸ばした降雨パターンを作成した。また、平成24年、平成29年の九州北部豪雨の最も強い雨域を松原ダム流域にスライドさせることで、仮想降雨データを作成した。以上により、合計20以上の仮想降雨事例を作成した。

(2) 仮想流入量データの作成

仮想降雨に基づき、降雨-流出モデルを用いて仮想ハイドログラフ（ダム流入量の時系列）を算出した。降雨-流出モデルには貯留関数モデルを用いた。貯留関数モデルは上流の下笠ダム流域を含めて構築し、河川整備基本方針・整備計画で使用されているモデルと同様とした。

4.5. 深層強化学習によるダム操作モデル

(1) モデルの役割

ダム操作モデルは、時々刻々と変化する状況に応じて、適切なダム放流量を決定することを目標とした。10分ごとに入手できる情報（現時刻までのダムの実績水位、実績流入量、数時間先までの予測流入量など）を判断材料として、10分ごとの放流量を出力するモデルとした。

(2) ダム操作モデルの構造

深層ニューラルネットワークとダムモデルを組み合わせて、ダム操作を判断するAIを構築した。図-17にダム操作AIの模式図を示す。ニューラルネットワークは一般的な階層型ネットワークである。入力データはダムの操作判断を行うための諸量とし、具体的には現時刻～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。出力データはダム放流量を決定するためのパラメータとし、1～15の離散値で表すようにした。表-3に、ダム操作モデルの入出力データの一覧を示す。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。

- 実測値として与えられるダム貯水位、流入量、放流量や、入力されるダム流入量予測を取り込む。これらの値と、計算される放流量から、貯水位の変化を計算する。
- ゲートを全開にした場合の設計値に基づき、ダム貯水位に応じて放流可能な最大流量を計算する。
- ゲート全開にした場合の放流量を上限として、ニューラルネットワークから出力された値に応じた15段階の放流量を計算する。具体的には、ニューラルネットワークの出力が15であれば最大限の放流量、出力が1であれば最小限の放流量となるようにする。
- ただし、機械的なゲートの開閉速度の限界を上回らないように制約を与えた。
- また、流入量が決められた洪水流量以下の場合には、ニューラルネットワークの出力に関わらず放流量＝流入量とした。

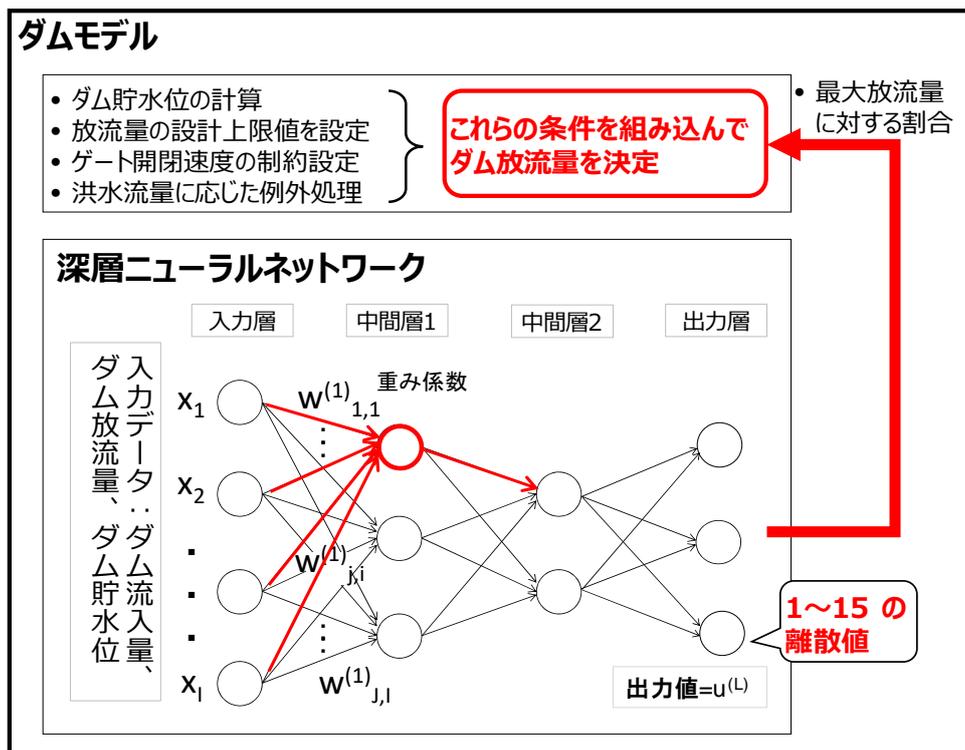


図-17 ダム操作 AI の模式図

表-3 ダム操作 AI のためのニューラルネットワークの入出力データ

設定項目	設定内容
入力データ	<ul style="list-style-type: none"> ・ 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	<ul style="list-style-type: none"> ・ 1～15 までの離散値

(3) ダム操作モデルの学習

モデルの学習には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。ニューラルネットワークを含めた様々な AI モデルの学習に適用することができる。強化学習の仕組みを図化すると図-18 になる。AI モデル (エージェント) は、環境に応じて何か行動を起こし、その結果に応じて報酬あるいは罰則を受ける。できるだけ高い報酬が得られるように、無数の試行錯誤を繰り返すことで、AI は高い性能を獲得していく。人間をはじめとした生物も環境に応じた最適な行動を学習しており、強化学習はこうした生物の学習過程を模倣したものであるともいえる。強化学習の代表的な事例として、2013 年にビデオゲームへの適用^{46), 47)}で注目を集め、その後 2016 年のアルファ碁⁴⁸⁾がプロのトップ棋士を破ったことで大きな話題となった。

学習を効果的に進めるためには、行動の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。本検討では、学習過程において仮想出水によるダム操作シミュレーションを繰り返した。人間が設定した洪水調節のための条件 (放流量の低減, 上限水位超過の回避など) を実現した際に加点, 不適切な操作を行った場合に減点するものとし、報酬を最大化させるようにモデルの最適化を行った。表-4 に報酬の設定条件を示す。

学習を進めるためにはモデルにどのような行動選択をさせるかの設定も重要である。基本的には高い報酬が得られそうな行動をとれば良いが、いつも同じ行動を取っているだけでは学習が進まなくなってしまう。そのため、時には未知の行動をランダムに選択して、よりよい報酬を得るための探索を行う必要がある。

例として、ダム操作の学習を始めたばかりの初心者 AI を考える。はじめは滅茶苦茶な操作しかできないが、学習していくうちにまともな操作ができるようになってくる。例えば、学習初期段階で「流入量よりも少しだけ小さい量を放流する」という戦略を発見したとしよう。この戦略であれば、常に下流への放流量を減らすことができ、また貯水位が上がりすぎてしまう心配も少ないため、安定した報酬を得られるだろう。しかし、同じ方法ばかりでは成長がないので、時にはより大胆なピークカットを試みるなど、より効果的な操作をチャレンジすることが必要である。その結果、時には急激な放流を余儀なくされたり、貯水位が天端を超えてしまったりして、報酬をまったく得られないこともあるだろう。しかし、失敗と成功を繰り返しながらも、徐々に効率的な操作のための戦略を学習していくはずである。

このような狙いを実現するために、本検討では、行動選択に ϵ -greedy-annealed 法を用いた。この方法では、予備知識がない学習開始時には、ランダム行動の割合を大きくして様々な可能性を探索させる。ある程度大まかな操作方法を学習してきたら、徐々にランダム行動の割合を小さくしていき、行動選択をより洗練させる狙いとなっている。本検討では、学習開始時にはランダム行動が 50%、学習が 200 エポック終わった段階でランダム行動が 0.1% となるようにした。最終的に、250 エポックの学習が終わった段階で学習終了とした。なお 250 エポックとは、学習データを 250 回繰り返し学習することを意味する。

このように、強化学習では学習データの作成、報酬や行動選択などチューニングする部分が多い。表-3, 4 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。

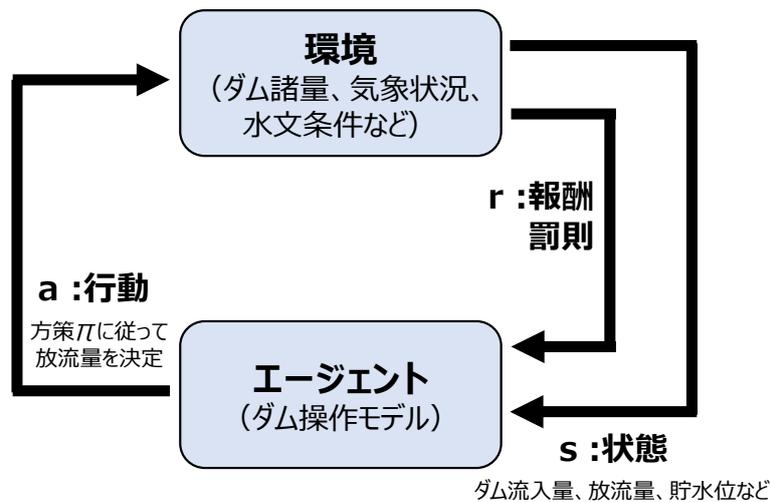


図-18 強化学習の概念図

表-4 強化学習の報酬関数の概要

条件	報酬
洪水調節を行った (流入量 > 放流量となった)	調整流量に応じて加点
異常洪水時防災操作開始水位を超過	超過水位に応じて減点
上限水位 (=設計洪水位) を超過	越流量に応じて大幅減点
10 分間での放流量変化が大きい	放流量変化に応じて減点

4.6. ダム操作 AI の適用事例

仮想洪水に対するダム操作の結果（ダム流入量、放流量、ダム貯水位）を図-19 に示す。図-19 上が既存の操作規則によるシミュレーション、図-19 下が学習済みの AI によるシミュレーションである。AI のシミュレーションでは、6 時間後までの流入量が完全に予測できているものと仮定し、10 分ごとに放流量を決定させた。

操作規則に基づくシミュレーションでは、2 回目の流入ピーク時（6/23 0:00 ごろ）に放流量がほぼ流入量と等しくなり、洪水貯留の能力を失っている。一方、ダム操作 AI では、ピーク時においても放流量の低減ができており、洪水全体で見ると AI の方がピーク放流量を減らすことができています。

なお、この結果は計画を大きく上回る仮想洪水に対するシミュレーションであり、現実的には過大な条件設定となっている可能性がある。例えば、図-19 で一つ目の洪水ピークまでを見ると、操作規則の方が放流量を減らすことができています。操作規則では、ある基準水位（異常洪水時防災操作開始水位）を超えるまでは、放流量を $1100\text{m}^3/\text{s}$ 以下とするように定めている。この放流量は下流河川の安全度を考慮して設定された値である。本検討の AI ではこのような設定は設けていないため、洪水前半では必ずしも下流の安全を考慮した放流とはなっていない。今後 AI の実用を考える上では、治水計画や既存のルールに沿った操作を学習させ、実際の運用の中でどのように活用するかを検討していく必要がある。

より発展的な試みの一つとして、筆者らはダム操作 AI に下流河川の洪水危険度を予測・評価する仕組みを組み込んだ。これにより、ダム放流量のみでなく、下流の降雨状況・合流する支川の状況も踏まえて、危険度を減らすような AI の開発に取り組んでいる⁴¹⁾。図-20 に、計画流量を上回るような仮想洪水 2 事例に対して、ダム操作 AI を適用した場合の下流の水位計算結果を示す。図では下流の計画高水流量を超えたら減点するような条件を追加してテストしたものである。下流の危険度評価を加えた AI モデルでは、より下流の流量を抑えることができています。今後も様々な条件でのテストが必要ではあるが、下流河川の危険度を下げつつ、ダム貯水位もうまく制御するようなダム操作 AI を目指している。

4.7. ダム操作 AI の今後の課題

ダム操作による洪水調節には重い責任がかかるため、AI 技術の導入には慎重な検証が必要である。本文中で述べた通り、様々な状況でのテスト・調整を繰り返すことで実用可能性を見極めていく必要がある。人間の現実世界の制約の中で操作を行っていく中で、どのような場面で AI による判断支援を目指していくか、活用の位置づけを整理していくことも必要である。

また、ダムの「最適な操作」は洪水の規模や下流の状況によっても異なる。どのような操作を目指すのかは、人間が定義しなければならない。これまでの治水計画や、下流の整備状況、リアルタイム運用時の下流のリスク状況、住民などの避難状況、気象の予測状況など、現実的な条件を学習させられるかどうかは課題である。逆に言えば、条件さえ定義できれば、AI はそれに応じた適切な操作を学習することができる。つまるところ、AI に頼って何とかするという発想ではなく、人間が知恵を絞って AI を設定してやらなければ、役に立つ AI を作ることは不可能であろう。

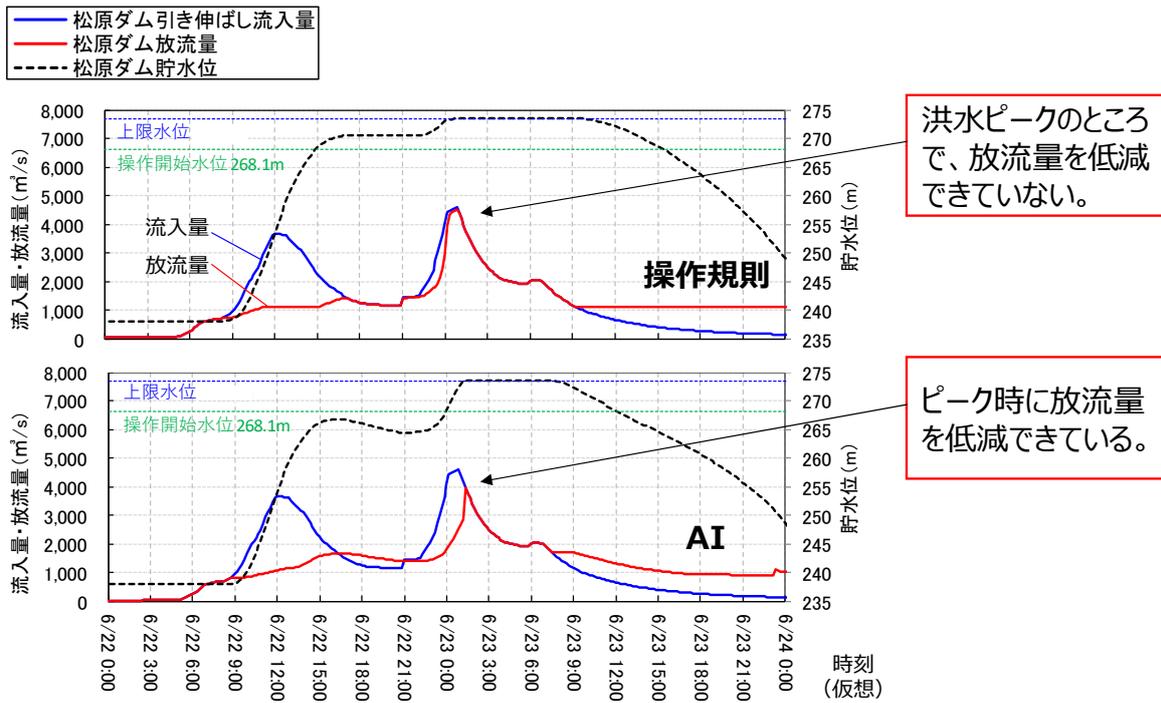


図-19 仮想洪水におけるダム放流シミュレーション結果 (上：操作規則, 下：ダム操作 AI)

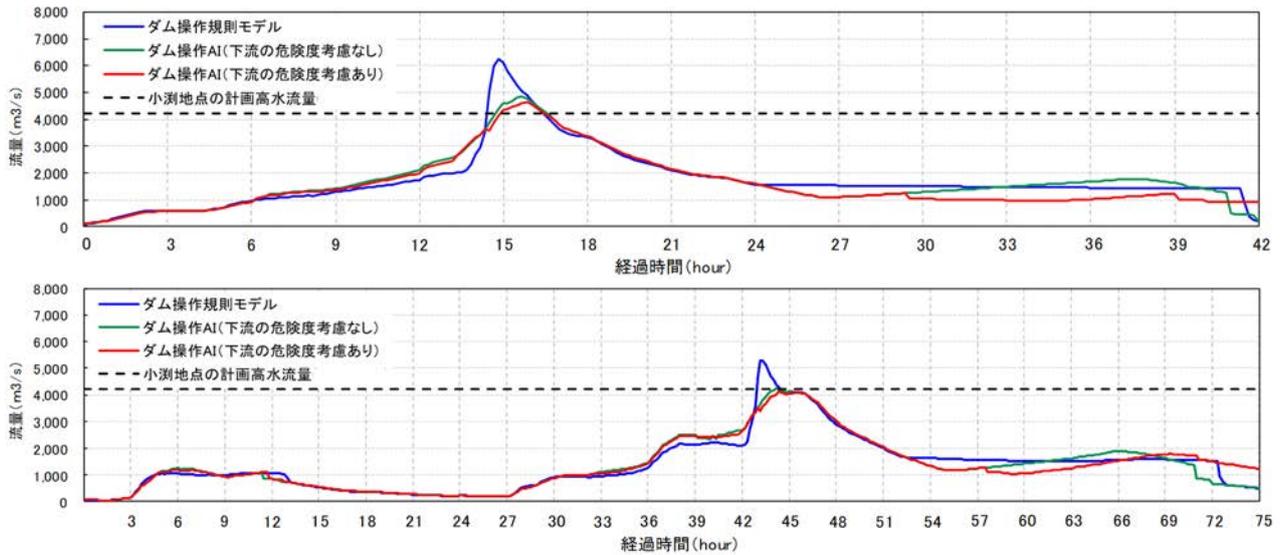


図-20 仮想洪水における小淵地点の 60 分後流量予測の時系列

5. その他の AI 技術の活用事例

本稿では洪水予測・ダム操作の事例を紹介したが、それ以外にも河川・水防災において様々な AI の活用研究が進められている。その一つに、浸水予測における取組がある。事前に物理型の氾濫解析モデルによる浸水シミュレーションを多数行い、計算結果を機械学習モデルで学習することにより、浸水範囲を瞬時に把握しようとする試みがなされている。AutoEncoder を用いて降雨分布予測から外水氾濫域を予測する研究や⁴⁹⁾、CGAN により仮想の浸水深の観測点情報から浸水分布を推定する研究¹⁵⁾、ランダムフォレストにより氾濫流量から氾濫域を推定する研究⁵⁰⁾などが行われている。

また降雨予測に AI を活用する研究も行われており、数値気象モデルの結果を AI により補正する方法や、直近の気象観測データから直接 AI モデルにより降雨予測を行う方法など、複数のアプローチによる研究が進められている。もし AI による降雨予測の精度向上があれば、河川・水防災分野において大きなインパクトがあるだろう。他にも AI の活用事例として、画像や衛星データなどを用いた技術が数多く研究されている。例えば、水位や水害危険度の判定、コンクリート護岸の劣化域の抽出、河川域の植生の判別、水害後の被災箇所特定、積雪状況の推定などである。画像解析以外にも、水質の予測、魚類や生態系の調査、土砂災害の予測など様々な場面での AI 活用が研究されている。

6. おわりに

本稿では、河川・水防災分野での AI 技術の活用事例として、洪水予測とダム操作の研究を中心に紹介した。同分野における AI 技術の研究は進んでいるものの、広く実用化されている事例はまだ少ない。今後は、従来からの技術と、AI 技術との比較を進めていくことが必要だと考える。研究が進み、AI 技術の限界が見えてくる場合もあるだろうし、逆に従来からの工学技術の価値が改めて問われる場面もあると思われる⁵¹⁾。将来的には、相互の足りない部分を補い合うような形で研究・活用が進んでいくことを期待したい。

参考文献

- 1) 一言正之, 桜庭雅明, 清雄一: 深層学習を用いた河川水位予測手法の開発, 土木学会論文集 B1 (水工学), Vol. 72, No. 4, pp. 187-192, 2016.
- 2) 一言正之, 桜庭雅明: 深層学習の適用によるニューラルネットワーク洪水予測の精度向上, 河川技術論文集, Vol. 22, pp. 1-6, 2016.
- 3) 一言正之, 桜庭雅明: 深層ニューラルネットワークと分布型モデルを組み合わせたハイブリッド河川水位予測手法, 土木学会論文集 B1 (水工学), Vol. 73, No. 1, pp. 22-33, 2017.
- 4) 一言正之, 桜庭雅明: 多地点観測情報を活用した深層ニューラルネットワークによる河川水位予測の精度向上, 河川技術論文集, Vol. 23, pp. 287-292, 2017.
- 5) 一言正之, 桜庭雅明: 学習事例を上回る大洪水に対する深層学習水位予測モデルの検証, 2018 年度人工知能学会全国大会論文集, 2018.
- 6) 一言正之, 遠藤優斗, 島本卓三, 房前和朋: レーダ雨量を用いた深層学習によるダム流入予測, 河川技術論文集, Vol. 23, pp. 287-292, 2018.
- 7) 荒木健, 箱石健太, 一言正之, 島本卓三, 房前和朋: 畳み込みニューラルネットワークによるレーダ雨量を用いた河川水位予測, 河川技術論文集, Vol. 25, pp. 297-302, 2019.
- 8) Masayuki HITOKOTO and Masaaki SAKURABA: River-stage prediction for urban small rivers with deep learning model by using x-band radar rainfall, *EGU General Assembly*, 2019.
- 9) 古田均, 野村泰稔, 広兼道幸, 一言正之, 小田和広, 秋山孝正, 宇津木慎司: AI のインフラ分野への応用, 電気書院, 2019.
- 10) 箱石 健太, 荒木 健, 一言 正之: スタッキングの適用による河川水位の時系列予測, AI・データサイエ

ンス論文集, Vol. 1, 2020.

- 11) 石尾将大, 一言正之, 島本卓三, 房前和朋: 深層強化学習を用いたダム操作モデルによる洪水調節, 河川技術論文集, Vol.25, 2019.
- 12) 一言正之, 澤谷拓海, 植西清: 深層強化学習を用いたダム操作モデルのダム流入量予測誤差に対する影響評価, AI・データサイエンス論文集, Vol. 1, No. 1, pp. 459-464, 2020.
- 13) 澤谷拓海, 一言正之, 植西清: 下流河川の危険度を考慮した深層強化学習によるダム操作モデルの構築, 土木学会論文集 B1 (水工学), Vol. 76, No. 2, pp. 817-822, 2020.
- 14) 一言正之, 川越典子, 橋田創, 房前和朋: 水位推定誤差の確率分布に基づく河川水位観測データのリアルタイム異常検知, 土木学会論文集 B1 (水工学), Vol.74, No.4, pp.193-198, 2019.
- 15) 一言正之, 荒木光一, 古木宏和: 敵対的生成ネットワークによる洪水氾濫浸水域の推定, 2019 年度人工知能学会全国大会, 2019.
- 16) 古木宏和, 稲垣裕, 一言正之, 藤平大, 櫻本智美: ディープラーニングによる地すべり地形の自動抽出精度と教師データの関係, 地盤工学会誌, Vol.67(6), pp.20-23, 2019.
- 17) 松尾豊: 人工知能は人間を超えるか, 角川選書, 2015.
- 18) 岡谷貴之: 深層学習, 講談社サイエンティフィック, 2015.
- 19) 斉藤康毅: ゼロから作るディープラーニング, オライリージャパン, 2016.
- 20) C.M.ビショップ: パターン認識と機械学習 上, 丸善出版, 2012.
- 21) 椿涼太, 小林健一郎, 内藤正彦, 谷口丞: 洪水予測技術の現状と課題について, 河川技術論文集, Vol. 19, pp. 1-6, 2013.
- 22) ASCE Task Committee on Application of Artificial Neural Networks in Hydrology: Artificial neural networks in hydrology. II: Hydrologic Applications, *Journal of Hydrologic Engineering*, Vol. 5, No. 2, pp. 124-137, 2000.
- 23) Maier, H. R. and Dandy, G. C.: Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, *Environmental Modelling & Software*, Vol. 15, pp. 101-124, 2000.
- 24) Dawson, C. W. and Wilby, R. L.: Hydrological modeling using artificial neural networks, *Progress in Physical Geography*, Vol. 25, No. 1, pp. 80-108, 2001.
- 25) Maier, H. R., Jain, A., Dandy, G. C. and Sudheer, K. P.: Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions, *Environmental Modelling & Software*, Vol. 25, pp. 891-909, 2010.
- 26) Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.: Dropout: A simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, Vol. 15, pp. 1929-1958, 2014.
- 27) LeCun, Y., Bengio, Y. and Hinton, G.: Deep learning, *Nature*, Vol. 521, pp. 436-444, 2015.
- 28) 国土交通省, 水文水質データベース, <http://www1.river.go.jp/> (最終閲覧日: 2020年7月11日)
- 29) 坂本莉子, 小林洋介, 中津川誠: 異常洪水時のダム貯水位予測に用いる機械学習手法の比較. 土木学会論文集 B1 (水工学), Vol. 75(2), pp. 85-90, 2019.
- 30) 山洞智弘, 中津川誠, 小林洋介, 坂本莉子: 未経験洪水事例に適用できる Elastic Net による 24 時間先までのダム流入量予測手法の提案, 土木学会論文集 B1 (水工学), Vol.76(2), pp.835-840, 2020.
- 31) 徳田大輔, and 金炯俊. "深層学習を用いた河川水位予測モデルにおけるネットワーク構造と入力データ量の依存性." 土木学会論文集 B1 (水工学) 74.5 (2018): I_169-I_174.
- 32) 滝口修司, キムスンミン, 立川康人, 市川温, 萬和明: ニューラルネットワークを用いた積雪地域の河川流量予測における重要入力因子の抽出, 土木学会論文集 B1 (水工学), Vol. 74(4), pp.877-882, 2018

- 33) Zhao, G., Pang, B., Xu, Z., and Xu, L.: A hybrid machine learning framework for real-time water level prediction in high sediment load reaches, *Journal of Hydrology*, Vol. 581, 2020.
- 34) Bai, Y., Chen, Z., Xie, J. and Li, C. : Daily reservoir inflow forecasting using multiscale deep feature learning with hybrid models, *Journal of Hydrology*, Vol. 532, pp. 193-206, 2016.
- 35) Kratzert, F., Klotz, D., Brenner, C., Schulz, K. and Herrnegger, M. : Rainfall-runoff modelling using long short-term memory (LSTM) networks, *Hydrology and Earth System Sciences*, Vol. 22(11), pp. 6005-6022, 2018.
- 36) Mosavi, A., Ozturk, P., and Chau, K. W.: Flood prediction using machine learning models: Literature review, *Water*, Vol. 10, 2018.
- 37) Kimura, N., Yoshinaga, I., Sekijima, K., Azechi, I., and Baba, D.: Convolutional neural network coupled with a transfer-learning approach for time-series flood predictions, *Water*, Vol. 12(1), 2020.
- 38) 木村延明, 吉永育夫, 関島建志, 安瀬地一作, 馬場大地 : 転移学習とカップリングした LSTM による洪水予測モデルの開発, 河川技術論文集, Vol. 26, pp. 187-292, 2020.
- 39) Kratzert, F., Klotz, D., Shalev, G., Klambauer, G., Hochreiter, S., and Nearing, G.: Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets, *Hydrology and Earth System Sciences*, Vol. 23(12), pp. 5089-5110, 2020.
- 40) 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.
- 41) 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.
- 42) 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.
- 43) Abhiram Mullapudi, Branko Kerkez: Autonomous control of urban storm water networks using reinforcement learning, *13th International Conference on Hydroinformatics*, 2018.
- 44) Hooshyar, M., Mousavi, S. J., Mahootchi, M., and Ponnambalam, K.: Aggregation-Decomposition-Based Multi-Agent Reinforcement Learning for Multi-Reservoir Operations Optimization, *Water*, Vol. 12(10), 2020.
- 45) Wang, X., Nair, T., Li, H., Wong, Y. S. R., Kelkar, N., Vaidyanathan, S., Nayak, R., An, B., Krishnaswamy, J. and Tambe, M.: Efficient Reservoir Management through Deep Reinforcement Learning, *arXiv preprint arXiv:2012.03822*, 2020.
- 46) 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.
- 47) Mnih, V., Kavukcuoglu, K., Silver, D., et al.: Human-level control through deep reinforcement learning, *Nature*, Vol.518, pp. 529-533, 2015.
- 48) Silver, D., Huang, A., et al: Mastering the game of Go with deep neural networks and tree search, *Nature*, Vol. 529, pp.484-489, 2016.
- 49) 関本大晟, 渡部哲史, 小槻峻司, 山田真史, 阿部紫織, 綿貫翔 : 降雨流出氾濫モデル・エミュレータによる浸水範囲予測, 土木学会論文集 B1 (水工学) , Vol.76(2), pp.547-552, 2020.
- 50) 菅原巧, 三谷泰浩, 川野浩平, 谷口寿俊, 本田博之, 堀真輝也, 佐藤辰郎 : ランダムフォレストを用いた洪水氾濫動態の推定に関する研究, 河川技術論文集, Vol.27, 2021.
- 51) Nearing, G. S., Kratzert, F., Sampson, A. K., Pelissier, C. S., Klotz, D., Frame, J. M., Prieto, H and Gupta, H. V.: What role does hydrological science play in the age of machine learning?, *Water Resources Research*, Vol. 57(3), 2020.