

ダム流入量予測における リザーバーコンピューティングの可能性

天方 匡純¹・石井 明¹・宮崎 利行¹

¹正会員 八千代エンジニアリング株式会社 技術開発研究所 (〒111-8648 東京都台東区浅草橋 5-20-8)

E-mail: amakata@yachiyo-eng.co.jp (Corresponding Author)

我が国においてもディープニューラルネットワークの社会適用が進み、社会資本インフラの分野でも様々な研究、そして、実用化を試みる業務例が見られる。一方で、ディープニューラルネットワークの学習に不可欠な大量データの整備は進まない。工場等の屋内一定条件下でのデータと異なり、屋外にある社会資本インフラに関わるデータは多様であり、その多様性を表現したデータベース整備は今後進んで行くものと思われる。本稿ではそのような現状を踏まえ、ディープニューラルネットワークよりもパラメータ数の少ないリザーバーコンピューティングをダム流入量予測に適用し、その実用可能性を確認した。ある程度の予測精度を確保できるが、ディープニューラルネットワークと比較すると精度が悪く、今後、ネットワーク等の工夫が必要であることが確認できた。

Key Words: reservoir computing, LSTM, prediction learning, dam inflow prediction, precipitation short-term forecast

1. はじめに

平成 25 年 10 月の大島町土石流災害、平成 26 年 8 月の広島土砂災害、平成 27 年 9 月の関東・東北豪雨、平成 29 年 7 月の九州北部豪雨、平成 30 年 7 月の西日本豪雨、令和元年 10 月の東日本台風、令和 2 年 7 月の熊本豪雨^{注 1}と、近年、計画を越える洪水や観測史上最大となる降雨の多発により多くの水災害・土砂災害が発生している。

降雨に関わる上記災害を低減する対策の一つとして、流出量を人工的に調節するダムが考えられる。ダムの規格的な貯水能力は柔軟に変えられないが、貯水池運用の工夫により目的毎の効果向上が期待できる。例えば、洪水時に貯水機能を最大限に活用するため、事前放流操作^{注 2}や異常洪水時防災操作^{注 3}といった現行運用規定がある。

これらは安心感のある確実な運用を目指し、原則として人主体の運用を想定したものであるが、団塊の世代の引退等に伴う人員不足とその後の人口減少、更には、冒頭の従来とは異なる外力の発生頻度の増加に伴い、適切な運用が困難となってきている。

洪水時にダム管理者の意思決定や適切なダム運用を支

援するツールとしてダム流入量予測モデルがある。ダム流入量予測に利用される従来手法は、物理現象を簡便化した現象説明性の高いモデルを主体とする。そして、既往洪水に対してモデル検証してモデルパラメータを最適化する。しかし、入力・モデル条件等には数多くの不確実性が含まれ、リアルタイムのダム流入量再現も難しい現実がある。そこで、昨今、その不確実性を解消する手法として、粒子フィルタ^{注 4}による状態方程式のデータ同化が適用され始めている。

一方、上下流の水文量の相関関係からダム流入量を予測する手法として、単相関、重相関、ニューラルネットワーク（以下、NN）といった手法が存在し、最近では、ディープニューラルネットワーク（以下、DNN）を活用した研究^{注 5}も見られる。また、自然言語に代表される前後の言葉（データ）の繋がりがあある時系列データ処理の代表的モデルとしてDNNの一種でもあるLSTM（Long Short-Term Memory）^{注 6}が挙げられ、これらを洪水に活用した事例^{注 7}も見られる。DNNはNNよりも遥かに多くのパラメータを有し、IO間のより複雑な非線形関係を構築することができる。そして、現在ではパラメータ量、データ量、計算処理能力をバランス良く拡大していくこ

とで特定のタスクに対して、際限なく精度と汎化性を拡大できる可能性も示されている^{9),10)}。

しかし、DNNを手軽に活用するに当たり、我が国の社会資本分野のデータは量も質も十分ではなく、最新のDNNの研究成果を反映する土壌にはない。一方で、2012年のDNN技術への注目^{注4)}以来、デジタル技術が現実社会における社会課題解決に貢献できるレベルは各段に上昇しており、DNNを始めとしたデジタル技術の応用は我が国においても徐々に進み始めている。このため、社会資本分野においてもQOL向上に繋がるデジタル技術適用を工夫しながら進めていきたいものである。

そのような状況を踏まえ、本稿ではDNNの周辺技術とも言えるリザーブコンピューティングをダム流入量予測のプロセスに適用する。リザーブコンピューティングは、学習パラメータ数が小さく、学習負荷も小さいため、データを十分に確保できない社会資本分野では精度も含めた総合的観点で活用が広がる可能性がある。しかし、本稿では、リザーブコンピューティング特性としてある程度自明である学習負荷が小さい等には着目せず、ダム流入量予測精度に着目し、リザーブコンピューティングの適用可能性を確認することを目的とする。

2. ダム流入量予測のアプローチ

ダム流入量予測の精度向上は、これまで様々なアプローチで取り組まれている。ここではその系譜概要を示し、本稿の立ち位置を明確にする。

(1) ダム流入量予測モデル

ダム流入量予測は、ダム流域に関わる雨量をリードタイムを持ってダム地点流量に変換する行為である。雨量から流量に変換するモデルは、大きく2つの種類に分けられる。1つ目は物理現象を簡便化したモデルであり、代表的なモデルとしてタンクモデル、貯留関数モデル、分布型流出解析モデル等が挙げられる。2つ目は上流から下流に水が流れる、降雨後に流出する、といった大まかな地形特性や物理特性から経験的に裏付けされたデータ間の関係を活用してダム流入量を予測するモデルである。冒頭に記した通り、単相関、重相関、NN、DNN等が挙げられる。

(2) モデル学習の方法

上記で紹介したモデルはいずれも実現象と整合を取ったモデルパラメータを最適化し、現象再現性の高いモデルを構築する。すなわち、基本的にはモデル構築時点より過去の観測データを活用してモデルパラメータを設定し、過去の観測データに対してモデル精度検証を進める。

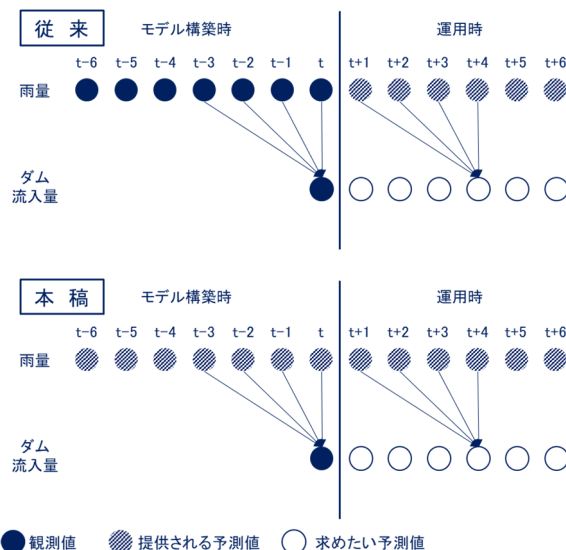


図-1 本稿で取り扱う予測学習の考え方

この結果、過去の観測データに対してはある程度の精度保証がなされる。しかし、ダム流入量予測の現場において求められるのはリードタイムの確保であり、洪水到達時間（流域最遠点に降った雨が該地点に到達するまでの時間）を十分に活用したとしても観測データのみで確保できるリードタイムには限界がある。そこで、リードタイムを確保するために予測データの活用が不可欠となる。ダム流入量予測で活用する主な予測データは、気象庁等が発信する予測雨量である。観測雨量は実現象の観測結果であり、予測雨量はシミュレーション結果であり、これらは出自の異なる特性の異なるデータである。従って、モデル構築で観測雨量を入力とし、実運用で予測雨量を入力とした場合、テスト環境と実運用環境でデータ整合、モデル整合が取れないこととなり、良好な予測精度を期待できない。実運用環境で用いる予測雨量が観測雨量と全く同じデータ（数値精度）となった場合は、良好な予測精度を期待できるが、合理的にその最高状態を想定することは難しい。ただ、現象再現性に拘った従来のダム流入量予測はこの手法に準じている。説明責任のあるダム計画を策定する場合には、現象再現性に拘ったモデルを基に議論を展開していく必要がある。しかし、不確実性のある未来を予測する場合には、「モデルの入力・境界条件に必要な観測データが無い」、「存在したとしても不確実性のあるデータ」といった過去とは異なるデータ環境での予測となることに留意する必要がある。そこで、ダム流入量予測が実運用環境での活用である点を重視し、予測雨量でモデル学習し、予測雨量でモデル運用するフレームワーク（本稿ではこれを予測学習¹¹⁾と呼ぶ、図-1参照）を考える。このフレームワークでは実現象との整合点をダム流入量とし、予測精度が高いとはt時間先の予測結果と観測結果との整合が高いことと考える。このため、教師データはt時間先の観測値であ

るダム流入量となる。この結果、このフレームワークでは、予測雨量（入力値）と観測値であるダム流入量（出力値）との間に物理的関係を期待できない。更に、その関係の非線形性が強い場合、DNNでも関係構築が難しいことになる。当然、従来の物理法則に基づくモデルでは予測雨量と観測ダム流入量の関係構築はできないことになる。幸い、予測学習を適用した一部事例を見るとDNNを活用することで関係構築でき、良好な結果を残している^{11),12)}。

本稿では、この予測学習を前提としてDNNよりもパラメータ数を減らしたリザーバーコンピューティングの手法にてダム流入量予測への適用可能性を検討する。

3. リザーバーコンピューティングの概要^{注5)}

(1) リザーバーコンピューティングの概要

リザーバーコンピューティングは、時系列データを扱うリカレントニューラルネットワーク（以下、RNN）モデルの幾つかのモデルから派生して生まれた一般的な概念である^{13),14),15)}。冒頭で紹介したLSTMはRNNの一種でもある。RNNと同様にリザーバーコンピューティングも系列データや時系列データの分類や予測に適している。リザーバーコンピューティングモデルは、図-2に示すように、一般的にリザーバー（reservoir）とリードアウト（readout）から構成される。リザーバーは入力データの変換に、リードアウトはパターン解析にそれぞれ用いられる。リザーバーは学習せずに固定¹⁶⁾し、リードアウトには簡便な線形型の学習識別器を用いるため高速学習が可能となる。

リザーバーコンピューティングの考え方は、時系列入力のリザーバーによって基本的な時空間パターンに変換し、リードアウトでの簡便な学習アルゴリズムによる分類/予測を可能または容易にすることである。つまり、雨量入力に対して、流出機構における表面流、中間流、地下水流に代表される要素分解をリザーバーで暗黙的に実施し、それを該当地点の流量としてリードアウトで再構成できる可能性がある。

(2) リザーバーコンピューティングの理論

リザーバーは結合重みを固定したリカレントニューラルネットワークである。入力データの次元よりも十分大きい数の非線形ノードを介してリザーバーは時系列入力データを高次元の特徴空間に写像する。リードアウトは、その高次元の動的挙動から時系列入力データの特徴を読み出す。リードアウトの出力結合重みは線形学習器で最適化される。線形学習器のみの計算量は、リザーバーとリードアウトに関わる全結合重みの逐次更新を繰り返す勾配

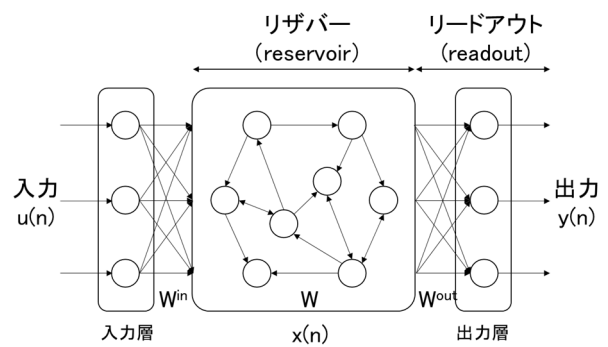


図-2 リザーバーコンピューティングの基本的モデル

法に基づく学習アルゴリズムの計算量に比べて、多くの場合圧倒的に小さい。ただし、この枠組みで高い計算性能を実現するためには「リザーバーを適切に設計する」必要がある。リザーバーネットワークは、一定の条件を満たす任意の離散時間フィルタを任意の精度で近似できることが理論的に示されている^{17),18)}。このため、DNNよりも

ローコストで観測値（入力値）に意味を持たせられる可能性があり、雨量から流出量のように体系的メカニズムが明らかな現象について変換過程を再現できる可能性がある。

リザーバーコンピューティングモデルの最も基本的なモデル（詳しくはエコーステートネットワークと呼ぶ）を図-2に示す。学習で調整されるのは出力層の重みである W^{out} のみである。入力層のノード数を N_u 、リザーバーのノード数を N_x 、出力層のノード数を N_y と表す。時刻 n における入力ベクトル $u(n)$ 、リザーバーのノード状態のベクトル $x(n)$ 、出力ベクトル $y(n)$ をそれぞれ、

$$u(n) = (u_1(n), \dots, u_{N_u}(n))^T \in R^{N_u} \quad (1)$$

$$x(n) = (x_1(n), \dots, x_{N_x}(n))^T \in R^{N_x} \quad (2)$$

$$y(n) = (y_1(n), \dots, y_{N_y}(n))^T \in R^{N_y} \quad (3)$$

と表す。また、入力層とリザーバーの間、リザーバー内、リザーバーと出力層の間の結合重み (ω_{ij}) 行列をそれぞれ、

$$W^{in} = (\omega_{ij}^{in}) \in R^{N_x \times N_u} \quad (4)$$

$$W = (\omega_{ij}) \in R^{N_x \times N_x} \quad (5)$$

$$W^{out} = (\omega_{ij}^{out}) \in R^{N_y \times N_x} \quad (6)$$

と表す。 W^{in} と W は予め与えられて固定されている。各時刻 n において、入力ベクトルが入力層に与えられると、その情報は変換されながら、出力層に向かって伝達される。時刻 n のリザーバー状態ベクトル $x(n)$ と時刻 $n+1$ の入力ベクトル $u(n+1)$ が与えられると、それぞれに重

みが掛け合わされ、リザーバー状態ベクトルの時間発展は

$$x(n+1) = f(W^{in}u(n+1) + Wx(n)) \quad (n = 0, 1, 2, \dots) \quad (7)$$

と記述される。これをリザーバーのノード $i(i = 1, \dots, N_x)$ について書き下せば、

$$x_i(n+1) = f\left(\sum_{j=1}^{N_u} \omega_{ij}^{in} u_j(n+1) + \sum_{j=1}^{N_x} \omega_{ij} x_j(n)\right) \quad (8)$$

となる。ここで $f(\cdot)$ は活性化関数を示す。本稿では $f = \tanh$ としている。出力層の出力ベクトルは、リザーバーの全てのノード状態の加重和として

$$y(n+1) = W^{out}x(n+1) \quad (n = 0, 1, 2, \dots) \quad (9)$$

と与えられる。これを出力ノード $k(k = 1, \dots, N_y)$ について書き下せば、

$$y_k(n+1) = \sum_{i=1}^{N_x} \omega_{ki}^{out} x_i(n+1) \quad (10)$$

となる。

図3に示すように、リザーバー状態ベクトルの初期条件 $x(0)$ と入力ベクトル $u(1)$ が与えられると、式(7)及び式(9)から、リザーバー状態ベクトル $x(1)$ と出力ベクトル $y(1)$ が計算される。同様の状態更新により、リザーバー状態の時間発展 $x(n)$ とモデル出力の時系列 $y(n)$ が生成される。リザーバー状態ベクトル $x(n)$ は、それまでの状態更新の過程から、過去の入力の影響を受けている(図3の矢印付きの破線)。その影響の大小は、リザーバーが蓄積する過去の入力の「記憶」の長さに関係する。

(3) モデルパラメータ

リザーバーコンピューティングモデルに含まれるパラメータ一覧を表1に示す。入力層、リザーバー、出力層のノード数(N_u, N_x, N_y)は $[-1, 1]$ の一様分布に従う乱数からランダムに与えられる固定パラメータである。全ての結合重みを学習パラメータとするRNNとは異なり、リザーバーコンピューティングでは出力結合重み行列 W^{out} のみが学習パラメータとなり、それ以外の結合重み行列(W^{in}, W)は固定パラメータである。出力結合重み行列 W^{out} は、線形回帰などのアルゴリズムで決定される。また、リザーバーのノード間の結合密度 $p = 0.2$ 、重みのスケール $\gamma = 0.5$ とした。

結合密度はリザーバーのネットワーク構造のリカレント結合重み行列 W の非ゼロ要素の配置に対応する。すなわち、リザーバーのリカレント結合重み行列 W の各要素 ω_{ij} について確率 p で $\omega_{ij} \neq 0$ (非ゼロ要素)とし、それ以外は $\omega_{ij} = 0$ とする。結合をスパースとするために、


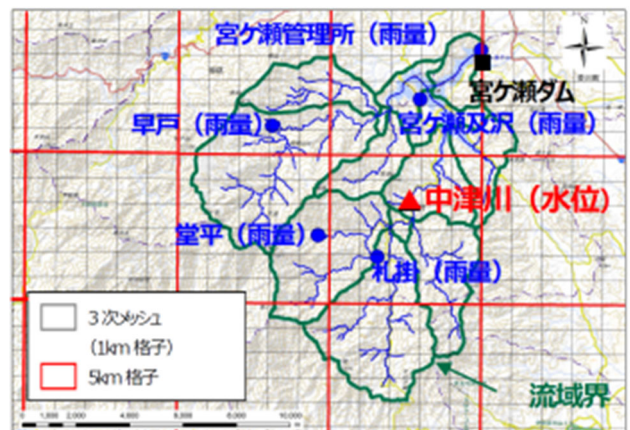


図3 リザーバーコンピューティングの状態発展

表-1 リザーバーコンピューティングのモデルパラメータ

固定パラメータ	意味
N_u	入力層のノード数
N_x	リザーバーのノード数
N_y	出力層のノード数
W^{in}	入力結合重み行列
W	リザーバーのリカレント結合重み行列
学習パラメータ	意味
W^{out}	出力結合重み行列



注)降水短時間予報の5kmメッシュは3次メッシュが縦6つ、横5つと定義。

図4 対象流域概要図

p は1より十分に小さい値($p = 0.05 \sim 0.2$)とする。また、スケール γ はリザーバー状態の時間発展が十分時間が経つと時系列入力のみ依存する特性をリザーバーが有するための条件である。スケール γ 前のリザーバーのリカレント結合重み行列 W のスペクトル半径 ρ_0 を計算し、正の実数パラメータ $\gamma < \frac{1}{\rho_0}$ を設定して、 $W \leftarrow \gamma W$ とスケール γ する。スケール γ 後の W は $\rho(W) < 1$ を満たす。

4. 実流域への適用

(1) 対象流域

本稿で取り扱う流域は、神奈川県を流れる一級水系である相模川水系中津川に位置する宮ヶ瀬ダムの上流域である(図4)。宮ヶ瀬ダムの貯水池は同一水系内の相模

表-2 本稿で活用した水位・雨量データ

	データ名称	データ種類	空間解像度	観測/予測	時間単位	本稿でのデータ利用期間
1	ダム流入量	流量	ポイント	観測	時間	2010/01/01~2019/12/31
2	降水短時間予報	雨量	5kmメッシュ	予測	時間	2010/01/01~2019/12/31

表-3 29洪水の概要

洪水 No.	ダム流入量が100m ³ /sを超えている出水			備考
	出水開始日時	ピーク流入量 (m ³ /s)	順位	
1	2010/9/23 12:00	139.80	23	学習洪水
2	2010/11/1 4:00	137.19	24	
3	2011/7/19 19:00	348.73	9	
4	2011/9/3 5:00	152.71	22	
5	2011/9/3 20:00	163.37	19	
6	2011/9/21 12:00	655.16	4	
7	2012/6/19 20:00	576.24	5	
8	2012/7/14 4:00	283.18	10	
9	2012/9/30 23:00	115.97	28	
10	2013/4/6 23:00	242.05	13	
11	2013/9/15 10:00	136.71	25	
12	2013/9/16 6:00	278.98	11	
13	2013/10/16 2:00	387.11	7	
14	2014/6/6 20:00	234.32	15	
15	2014/10/6 3:00	373.63	8	
16	2014/10/14 0:00	168.08	18	
17	2015/7/16 8:00	156.54	20	
18	2015/7/17 0:00	174.01	17	
19	2015/9/9 6:00	467.70	6	
20	2015/12/11 9:00	153.09	21	
21	2016/8/22 11:00	765.87	2	
22	2016/9/20 19:00	122.33	27	
23	2017/8/8 1:00	133.53	26	
24	2017/10/22 12:00	702.28	3	
25	2017/10/29 21:00	109.19	29	
26	2018/3/9 0:00	178.35	16	
27	2019/5/21 8:00	274.10	12	
28	2019/8/15 21:00	236.26	14	
29	2019/10/12 6:00	1749.78	1	

川、道志川と相模導水で連携接続されているがこれらを含まない宮ヶ瀬ダム単独流域面積は101.4km²である。図-4に示す通り、対象流域はほぼ円形の放射状流域であり、流域内には水位観測所が1箇所、雨量観測所が5箇所ある。ダム地点までの洪水到達時間は既往データ整理より約1時間程度である。

(2) 利用データ

本稿で活用するデータ諸元を表-2に示す。2010年1月～2019年12月までを本稿の検討対象期間とする。現時刻 t 以前の確定性のある観測データはダム流入量データである。一方、不確定性を持つ予測データとして、予測雨量（降水短時間予報^{注6}）を用いる。降水短時間予報は、1kmメッシュ単位の毎正時00分および30分を初期時刻とする6時間先までの1時間雨量予測値である。本稿では、これらの毎正時00分のみ1kmメッシュ雨量値を平均して図-4に示す5kmメッシュ単位として用いる。対象とする洪水は宮ヶ瀬ダムの洪水量100m³/sを超

過し、かつ、データ欠測等を考慮した29出水とした（表-3）。なお、洪水量100m³/s超過期間の前12時間と後6時間を加えた期間を1洪水期間とした。

(3) 計算フレーム

入力値をダム流入量（現時刻 t 以前）、降水短時間予報（t+1～t+6）とし、出力値をダム流入量（t+1～t+6）とする。また、実運用では既往洪水の学習を経てリアルタイムの予測を迎える現実を踏まえ、ダム流入量予測モデル構築には表-3に記す2010～2018年の26洪水（学習洪水）を用い、検証には表-3のデータセット上の最新年データ扱いとなる2019年の3洪水（27番：2019年5月洪水、28番：2019年8月洪水、29番：2019年10月洪水）を用いた。また、リザーバーのノード数はノード数を1～1000の範囲内で試行し、ベイズ最適化にて決定した。試行により決定したノード数N_xは、1時間先が387、2時間先が464、3時間先が451、4時間先が379、5時間先が446、6時間先が437となり、リードタイムの違いによるリザーバーのノード数の大きな違いは無かった。

(4) 計算結果

図-5、表-4に計算結果を示す。図-5は検証洪水である2019年5月、2019年8月、2019年10月の3洪水を断続的に一連で並べて示したものである。3洪水の中では2019年10月の洪水が最も大きく、また、観測史上最大規模である。凡例は灰色のobsが観測値であり、青色のprdが計算値である。縦軸はダム流入量（m³/s）を示し、横軸は1時間毎の時間経過を示す（グラフ内の合計経過時間は約180時間）。グラフ中の四角囲いの部分には、最適化したリザーバーのノード数とRMSE値を示した。表-4は、図-5と同じ3洪水に対して、これまで筆者らが手法を変えてダム流入量予測を検討してきた結果を整理したものである。ネットワーク名の列は、各検討で用いたAIネットワークモデル概要を示し、学習方法の列は、過去データを用いた学習か予測データを用いた学習かを示している。モデル性能（RMSEによる評価）に示す数値は、図-5に示す断続的一連期間において各モデルの予測結果と観測結果との誤差をRMSEで整理したものある。

表-4の6番目の結果、すなわち、図-5の結果より本検討のリザーバーコンピューティングの手法は6時間先予測もある程度の予測精度を確保できることが分かる。更に、表-4の過去学習の結果を示す1番目と2番目の2時間先～6時間先の予測結果と比較するとリザーバーコンピューティングによる6番目の結果は予測精度が高いことを確認できる。一方、3洪水のうち既往最大規模となる2019年10月洪水に対する3時間以上先のピーク流入量の予測精度が大きく低下する。学習洪水の最大規模が765m³/s（表-3の21番洪水）であるため入力値である予

測雨量の不確かさが大きくなる3時間以上先予測では予測精度の確保が難しい結果となると考えられる。同様に、2019年8月洪水の3時間以上先の波形再現性も悪く、不確か性の大きい入力値と確定性のある出力値（ダム流入量）との関係構築に当たり、リザーバー状態ベクトルの基本情報が十分でないと考えられる。すなわち、入力値を高次元空間の特徴量に変換するリザーバーのネットワーク条件が不適切と考えられる。

本稿では、リザーバーコンピューティングの一般的な考え方に準じ、入力値とリザーバー間、リザーバー内の重み W^{in} と W をランダムに設定し、その後固定化したため、出力値であるダム流入量から流出機構に関する情報を取得できてない。この結果、当然、 W^{in} と W 、そして、そもそものリザーバーのネットワーク構造は、ダム流入量予測精度向上をサポートすると思われる一般的な流出機構等の知見が取り入れられていない。上記を踏まえると、本稿で取り組んだリザーバーコンピューティングの初歩的アプローチでは、ダム流入量予測精度向上に一定の限界があることは容易に推測できる。

リザーバーコンピューティングの特徴は DNN に比較して学習パラメータ数が小さく、学習負荷も小さい所である。当然、モデル表現力は小さい。しかし、ランダム設定されたリザーバーのノード間の繋がりを流出特性等が反

映された繋がりに再構築できればモデル表現力は向上する。リザーバーは構造上、RNN である必要は無く、物理モデルでも構わない。データ科学と土木工学の接点を見出し、有用なモデル構築を進めていく必要がある。

6. おわりに

予測雨量（降水短時間予報）とダム流入量（観測値）との関係を構築するに当たり、リザーバーコンピューティングモデルを活用した。リザーバーコンピューティングモデルは DNN よりも表現能力は低下するが、雨量波形から流出素過程を適切に表現した基本波形群に分解できれば表現能力は問題にならない。しかし、本稿の初歩的なリザーバーコンピューティング適用では DNN の予測精度を超えることは出来なかった。闇雲に単なるデータ間関係として雨量とダム流入量の関係を捉えるのではなく、土木知見の制約を与えてデータ間関係を構築できれば、少ないパラメータ数で精度の良いモデルが成立すると考えられる。

今後は、リザーバーへの流出機構特性の反映方法を追求し、ダム流入量予測が抱える未学習洪水への対応やデータが少ない流域への対応等を実現していきたい。

表-4 既往検討と本稿の検討結果の比較

番号	I/O関係					学習方法	モデル性能 (RMSEによる評価)						出典
	入力値	入力値	入力値	出力値	ネットワーク名		1時間先	2時間先	3時間先	4時間先	5時間先	6時間先	
1	観測雨量	観測水位	ダム流入量	ダム流入量	NN	過去学習	79.4	122.9	164.2	188.9	204.5	213.8	12)
2	観測雨量	観測水位	ダム流入量	ダム流入量	LSTM	過去学習	61.9	110.1	132.4	149.1	192.3	197.0	12)
3	予測雨量		ダム流入量	ダム流入量	LSTM	予測学習	52.3	62.5	61.3	61.2	67.3	72.9	12)
4	土壌雨量指数		ダム流入量	ダム流入量	LSTM	予測学習	57.2	83.3	67.4	74.0	88.4	88.6	11)
5	予測雨量		ダム流入量	ダム流入量	LSTM	予測学習	54.5	82.2	92.3	64.3	68.0	76.6	11)
6	予測雨量		ダム流入量	ダム流入量	リザーバーコンピューティング	予測学習	73.8	89.1	93.1	88.1	83.6	107.6	本稿




図-5 リザーバーコンピューティングによる計算結果（黒色：観測値，青色：予測値）（横軸は1時間ピッチ，縦軸は m^3/s ）

NOTES

- 注1) 国土交通省水管理・国土保全局『水害レポート2020』, 2020.
- 注2) 国土交通省水管理・国土保全局『事前放流ガイドライン』, 2020.
- 注3) 『計画規模を超える洪水時におけるただし書き操作の運用の改訂について』昭和59年6月河川局長通達, 1984.
- 注4) Ian Goodfellow, Yoshua Bengio, and Aaron Courville『DEEP LEARNING』, p.23-24, 2016
- 注5) 田中剛平, 中根了昌, 広瀬明『リザバーコンピューティング』, 2021.
- 注6) 降水短時間予報とは
https://www.jma.go.jp/jma/kishou/now/kurashi/kotan_nowcast.html

REFERENCES

- 1) 工藤亮治, 近森秀高, 永井明博: 粒子フィルタを用いた河川流域における実時間洪水予測, 農業農村工学会論文, 77巻, 1号, pp. 17-25, 2009.[Kudo, R. and Chikamori, H. and Nagai, A.: Real-Time Flood Forecasting System Based on Simple Lumped Rainfall-Runoff Models Combined with Channel Flow Routing Model Using Particle Filter, Trans. Of JSIDRE, Vol. 77, Issue 1, pp. 17-25, 2009.]
- 2) 立川康人, 須藤純一, 椎葉充晴, 萬和明, キムスンミン: 粒子フィルタを用いた河川水位の実時間予測手法の開発, 水工学論文集, 67巻, 4号, pp. I-511-I-516, 2011.[Tachikawa, Y. and Sudo, J. and Shiiba, M. and Yorozu, K. and Kim, S.: Development of A Real-Time River Stage Forecasting Method Using A Particle Filter, Journal of Japan Society of Civil Engineers. Ser. B1, PROCEEDINGS OF HYDRAULIC ENGINEERING, Vol. 67, Issue 4, pp. I-511-I-516, 2011.]
- 3) 一言正之, 櫻庭雅明, 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, 2016.[Hitokoto, M. and Sakuraba, M. and Sei, y.: Development of The Real-Time River Stage Prediction Method Using Deep Learning, Journal of Japan Society of Civil Engineers. Ser. B1, PROCEEDINGS OF HYDRAULIC ENGINEERING, Vol.72, Issue 4, pp. I-187-I-192, 2016.]
- 4) Hochreiter, S. and Schmidhuber, J. : Long short-term memory, Technical Report FKI-207-95, Fakultät für Informatik, Technische Universität München, 1995.
- 5) Hochreiter, S. and Schmidhuber, J. : Long Short-Term Memory, Neural Computation, 9(8), 1997.
- 6) 天方匡純, 梁田信河, 藤井純一郎: LSTM (Long Short-Term Memory) を活用したダム流入量予測に関する研究, 電力士木, No.405, 2020.[Amakata, M. and Yanada, N. and Fujii, J. : Study about Dam Inflow Prediction Using Long Short-Term Memory, Electric Power Civil Engineering, No.405, 2020.]
- 7) 天方匡純, 安野貴人, 藤井純一郎, 島本ゆり, 大久保純一: IoT を想定したダム流入量予測精度向上に関する研究, 水文・水資源学会誌, 第32巻, 第6号, 2019.[Amakata, M. and Yasuno, T. and Fujii, J. and Shimamoto, Y. : Real-Time Dam Inflow Forecasting Accuracy Improved by Internet of Things, J. Japan Soc. Hydrol. and Water Resour., Vol. 32, No. 6, pp. 287-300, 2019.]
- 8) Jared Kaplan, Sam McCandish, Tom Henighan, Tom B. Brown, Benjamin Chess, Rewon Child, Scott Gray, Alec Radford, Jeffrey Wu, Dario Amodei : Scaling Laws for Neural Language Models, arXiv, <https://arxiv.org/abs/2001.08361>, 2020.
- 9) Tom Henighan, Jared Kaplan, Mor Katz, Mark Chen, Christopher Hesse, Jacob Jackson, Heewoo Jun, Tom B. Brown, Prafulla Dhariwal, Scott Gray, Chris Hallacy, Benjamin Mann, Alec Radford, Aditya Ramesh, Nick Ryder, Daniel M. Ziegler, John Schulman, Dario Amodei, Sam McCandish : Scaling Laws for Autoregressive Generative Modeling, arXiv, <https://arxiv.org/abs/2010.14701>, 2020.
- 10) Tom B. Brown, Benjamin Mann, Nick Ryder, Melanie Subbiah, Jared Kaplan, Prafulla Dhariwal, Arvind Neelakantan, Pranav Shyam, Girish Sastry, Amanda Askell, Sandhini Agarwal, Ariel Herbert-Voss, Gretchen Krueger, Tom Henighan, Rewon Child, Aditya Ramesh, Daniel M. Ziegler, Jeffrey Wu, Clemens Winter, Christopher Hesse, Mark Chen, Eric Sigler, Mateusz Litwin, Scott Gray, Benjamin Chess, Jack Clark, Christopher Berner, Sam McCandish, Alec Radford, Ilya Sutskever, Dario Amodei : Language Models are Few-Shot Learners, arXiv, <https://arxiv.org/abs/2005.14165>, 2020.
- 11) 天方匡純, 石井明, 宮崎利行, 宮本崇: ダム流入量予測の精度向上を実現する予測学習, AI・データサイエンス論文集, 2巻, J2号, p. 128-139, 2021.[Amakata, M., Ishii, A., Miyazaki, T. and Miyamoto, T. : Prediction Learning Realizing The Improvement of Dam Inflow Prediction Precision, Intelligence, Informatics and Infrastructure, Vol. 2, Issue J2, p. 128-139, 2021.]
- 12) 天方匡純, 石井明, 宮崎利行, 梁田信河: 予測学習と深層学習によるダム流入量予測の精度向上, ダム工学, 32巻, 1号, 2022.[Amakata, M., Ishii, A., Miyazaki, T. and Yanada, N. : Precision Improvement of Dam Inflow Prediction by Prediction Learning and Deep Learning, Japan Society of Dam Engineers, Vol. 32, Issue 1, 2022.]
- 13) Herbert Jaeger : The “echo state” approach to analysing and training recurrent neural networks – with an erratum note, German National Research Center for Information Technology GMD Technical Report, 148(34):13, 2001.
- 14) Herbert Jaeger and Harald Haas : Harnessing nonlinearity, Predicting chaotic systems and saving energy in wireless communication, Science, 304(5667), pp. 78-80, 2004.
- 15) Herbert Jaeger : Echo state network, Scholarpedia, 2(9) : 2330, 2009.
- 16) Mantas Lukosevicius and Herbert Jaeger : Reservoir computing approaches to recurrent neural network training, Computer Science Review, 3(3), p. 127-149, 2009.
- 17) Lyudmila Grigoryeva and Juan-Pablo Ortega : Echo state networks are universal, Neural Networks, 108, p. 495-508, 2018.
- 18) Lukas Gonon and Juan-Pablo Ortega : Reservoir computing universality with stochastic inputs, IEEE Transactions on Neural Networks and Learning Systems, 31, p. 100-112,

2020.

(Received June 30, 2022)
(Accepted August 31, 2022)**POSSIBILITY of RESERVOIR COMPUTING in DAM INFLOW PREDICTION****Masazumi AMAKATA, Akira Ishii and Toshiyuki MIYAZAKI**

Our country also increases many practical application examples of deep neural networks. Many research and application examples exist in the social capital infrastructure field. On the other side, we cannot improve to prepare the big data, which is indispensable for deep Learning. Unlike data under certain indoor conditions such as factories, data related to social capital infrastructure outdoors is diverse, and it is expected that database development that expresses that diversity will progress in the future. In this paper, based on such a situation, we applied reservoir computing, which has fewer parameters than deep neural networks, to dam inflow prediction and confirmed its practicality. Although it is possible to secure a certain degree of prediction accuracy, the accuracy is inferior to that of deep neural networks. It was found that it is necessary to devise networks in the future.