

# 中小規模出水に対するエンコーダ付き RNN ダム流入量予測モデルの構築とその精度評価

曾田 康秀<sup>1</sup>・成 岱蔚<sup>2</sup>・小島 崇<sup>3</sup>・渡邊 明英<sup>2</sup>  
若松 聡<sup>4</sup>・錦織 俊之<sup>5</sup>

<sup>1</sup> (株) 東京建設コンサルタント 環境防災研究所 (〒170-0004 東京都豊島区北大塚 1-15-6)  
E-mail: sota-y@tokencon.co.jp (Corresponding Author)

<sup>2</sup> 正会員 (株) 東京建設コンサルタント 環境防災研究所 (〒170-0004 東京都豊島区北大塚 1-15-6)

<sup>3</sup> (株) 東京建設コンサルタント 環境防災研究所 (〒170-0004 東京都豊島区北大塚 1-15-6)

<sup>4</sup> (株) 東京建設コンサルタント 環境防災事業本部 (〒170-0004 東京都豊島区北大塚 1-15-6)

<sup>5</sup> 正会員 (株) 東京建設コンサルタント 環境防災事業本部 (〒170-0004 東京都豊島区北大塚 1-15-6)

中小規模出水に対するダム流入量予測では、貯水位変化方式により得られるダム流入量データの振動の影響が大きくなる。深層学習予測モデルの一つである再帰型ニューラルネットワーク(RNN)は、対象とする降雨イベント以前の流域状態を表現するのが困難である。その二点に対し、本研究では非定常な信号の周波数解析に有効な Wavelet 変換を用いて、出水期でのダム流入量データのノイズ除去を行った。また、流域の事前状態の影響を表現するため、エンコーダを RNN と連結するダム流入量予測モデルを構築した。最後にエンコーダ付き RNN と多層パーセプトロン(MLP)との 24 時間後の予測の精度の比較および検証を行った。

**Key Words:** wavelet transform, encoder, dam inflow, rainfall-runoff analysis, deep learning

## 1. はじめに

近年、ダム操作による事前放流の必要性からダム流入量の予測精度向上が必要とされている。河川の水位やダムへの流入量の評価には周辺の地形を考慮した物理的な流出モデルが広く使われているが、河川への流出は周辺地形・地質や蒸発散量などの気象状況に依存しており、適切なパラメータを決めるのが困難である。一方、地形や地質が不変である場合は、大規模洪水の降雨パターンと河川水位やダムへの流入量はある程度の相関を持っていることから、統計回帰モデルやその流出モデルとのハイブリッドモデルが考察されている<sup>1)2)</sup>。

河川の水位予測に対する統計回帰モデルとしては、近年 ANN や DNN などの多層パーセプトロン(MLP)が広く適用されている<sup>1)2)</sup>。MLP では目的変数と説明変数の間を全層結合できるため、容易にモデルを構築できるという利点がある。一方、隠れマルコフモデル<sup>3)</sup>に基づく再帰型ニューラルネットワーク(RNN)は、各時刻の状態量が現在

および過去の状態量のみ依存しており、時系列データの予測に適している。実際、これまで MLP や RNN を用いた降雨完全予測の下でのダム流入量予測がなされている<sup>4)5)6)</sup>。

中小規模出水に対するダム流入量の予測精度向上については、予測降雨の不確実性<sup>7)</sup>に加え、ダム流入量のノイズによる不確実性を考慮する必要がある。ダム流入量は、貯水位の変化量および流入、放流量三者の保存関係により得られるが、この貯水位変化方式では観測される貯水位の微小な振動が増幅され流入量のノイズとして観測される<sup>8)</sup>。LSTM による先行研究では、観測時に想定されるノイズを入れて学習させても予測精度が上がる訳ではなく、ノイズ除去の前処理が重要であることが示されている<sup>9)</sup>。Fourier 変換を拡張した Wavelet 変換は、観測データを時間(または空間)ごとに周波数成分に分け、それぞれの成分に対する解像度で解析する手法であり<sup>9)</sup>、ダム流入量のような非定常な信号のノイズ振動を除去するのに有効である。

一方、中小規模の出水では、ノイズに加え先行降雨などによる土壌の状態も降雨イベントに対するダム流入量の振る舞いに影響を及ぼす。これらは長時間前からの降雨の影響によるが、既往の流出解析で用いられている RNN モデル<sup>9)</sup>では単一の帰還路を展開して過去に遡る為、過去に長時間遡るほど、隠れ層の重みが勾配消失や無降雨期間などの影響を受け予測精度が下がる可能性がある。

以上から、本論文ではダム流入量のノイズ振動に Wavelet ノイズ除去を行い、それを説明変数に用いることによる予測精度の向上を検証する。また RNN にエンコーダを付与することで長時間前からの降雨による影響を考慮するモデルを構築する。まず 2 章では中小規模の出水を含めたイベントデータの構築について説明し、3 章でそれぞれのイベントごとにダム流入量の Wavelet 変換によるノイズ除去の手法について示す。4 章、5 章では、深層学習を用いた予測モデルの構築および学習手法について説明する。6 章では MLP および RNN による最適モデルの予測精度について比較および考察を行う。

## 2. 教師データの構築

ダム流入量予測の検討にあたり、流域面積約 130 km<sup>2</sup>、総貯水容量約  $2 \times 10^8$  m<sup>3</sup> で県内用水の大部分を賄っている A ダムを対象とする。A ダムの上流には流量を調整する施設がなく、上流域の降雨で流入量が決まる。過去の中小規模を含めた出水のデータを活用するため、1981 年から 2020 年までの 1 時間(1h)ピッチの A ダム流入量および A ダム上流域の流域平均雨量を用いる。

降雨期におけるダム流入量予測を行うために、上記期間内の年 S での年最大 24 時間累積降雨期間を求め、その前後 48 h を合わせた計 120 h を年 S の「年最大 24 時間降雨イベント」S<sub>1</sub> とする。次に、そのイベントを除いた期間での年最大 24 時間降雨イベントを抽出し、S<sub>2</sub> とする。以下、イベント期間外での年最大 24 時間累積降雨が 30 mm を下回るまでこの操作を繰り返し、年 S の K 番目「年最大 24 時間降雨イベント」を S<sub>K</sub> と表記する。

以下ではこの手続きを 1981 年から 2020 年までの全ての年に適用して 239 のイベントを取得し、それらを以下

の手続きで 5 つのグループに分類する。

- 各年をダム流入量の年最大値で降順に順序付けし、順序 L を 5 で割った余り+1 をその年のラベル w とする (w=1,2,3,4,5).
- ラベル値で年を 5 つのグループに分類し、各イベント S<sub>K</sub> を S 年の属するグループに振り分ける。

以下ではラベル w のグループを検証用、残り 4 つのグループを学習用とする教師データのラベル値を w とする。これにより、グループ w のイベントは、教師データ w では検証用、残りの 4 つの教師データでは学習用となる。本来は学習用、検証用の他にテスト用を用意して精度評価に用いるべきであるが、学習モデルの統計的性質を調べるのに十分なテスト用イベントを確保するのが難しいため、以下では各教師データに対する検証用イベントを精度評価に用いる。

## 3. ダム流入量データの Wavelet ノイズ除去

以下では、2 章で示した 239 イベントのイベント開始時刻を基準とした時刻 t でのダム流入量 Q(t) に対して、間隔  $\Delta T = 1h$ 、期間  $T_w = 2^Z \Delta T$  での離散 Wavelet 変換を行う。ただし、Z は  $T_w$  が 1 イベント幅  $T_w = 120 h$  を含むような最小の整数 Z=7 とし、 $T_w = 128 h$  とする (1 イベントの始点  $t_s$  の前 4 h に  $Q(t_s)$ 、終点  $t_e$  の後 4 h に  $Q(t_e)$  を付与し、 $Q(t)$  を  $T_w$  内に拡張する)。m を 0 以上の整数とし、各イベントの時刻 t を  $t_m = m\Delta T$  で離散化すると、離散 Wavelet 変換での時刻  $t_m$  での実績ダム流入量  $Q_m \equiv Q(t_m)$  は、正規直交基底を成す離散 Wavelet 関数  $\psi_{j,k}(t_m)$  による変換係数  $\omega_{j,k}$  の線形重ね合わせで、次式のように復元できる<sup>9)</sup>。

$$\hat{Q}_m \approx \sum_{j,k} \omega_{j,k} \psi_{j,k}(t_m) \quad (1)$$

ただし、j, k は、それぞれ周波数成分および時間成分を表す。Wavelet ノイズ除去手法の一つである hard ノイズ除去では、式(1)に対してある決められた閾値以下の  $\omega_{j,k}$  をゼロとして除去する<sup>10)</sup>。ただし閾値が小さいとノイズが残り (variance 大)、大きいと形がノイズのない真の波形からずれる (bias 大)。したがって、閾値の値には variance + bias が極小になる最適解を適用するのが望ましい。




図-1 Wavelet ノイズ除去されたダム流入量の復元波形




図-2 239 イベントに対する Wavelet ノイズ除去されたピーク流入量相対誤差( $J_{pe}$ )の絶対値




図-3 239 イベントに対する Wavelet ノイズ除去された流出ボリューム相対誤差( $E_v$ )の絶対値

bias を実測値 $Q_m$ とノイズなしの値との平均 2 乗誤差 (MSE)で表すと、 $Q_m$ が $N$ 個のデータ点の区分多項式で近似できる場合、閾値の最適解は  $N \gg 1$  の極限で、 $\lambda \approx \sqrt{2 \log N} \sigma$  (universal threshold)の形で近似できる<sup>10)</sup>。ただし $\sigma$ は $\omega_{j,k}$ の分布の標準偏差である。以下では、非ガウス型の分布に対し、 $\sigma$ を中央値からのずれに置き換えた以下の Visu Shrink を用いる<sup>11)</sup>。

$$\lambda \approx \frac{MAD(\omega_{j,k})}{0.6745} \sqrt{\log N} \quad (2)$$

ただし、 $MAD(\omega_{j,k})$ は $\omega_{j,k}$ の分布の中央絶対偏差である。以下では、Python のモジュールである PyWavelets<sup>12)</sup>を用い、各イベントのダム流入量に対して Daubechies Wavelet<sup>10)</sup>を用いた離散 Wavelet 変換を行う。定義から $Q_m$ のピーク付近での Wavelet 係数 $\omega_{j,k}$ の値は、それ以外の時刻での値よりも大きくなる。これより各イベント期間のダム流入量に対して Wavelet 変換を行うと、出水ピーク付近での Wavelet 係数の中央値からのズレが大きくなる。したがって出水規模が大きくなるほどピーク付近の値を中心に式(2)の閾値を超える係数の割合が増え、復元波形のピーク流量低減が抑制される。ただし閾値未満の低周波成分を全て除去すると、bias が大きくなり波形を大きく変えてしまう可能性があるため、以下では式(2)の閾値以下で、最大周波数 $\omega_{max} = 2.0/\Delta T$ に相当する周波数成分 $J_{max}$ のみを除去するものとし、以下のノイズ除去条件を用いる。

$$\omega_{j,k}^* = \begin{cases} 0 & (|\omega_{j,k}| < \lambda, j = J_{max}) \\ \omega_{j,k} & (Otherwise) \end{cases} \quad (3)$$

ノイズ除去条件式(3)で示される $\omega_{j,k}^*$ の値を式(1)の $\omega_{j,k}$ に代入して得られるノイズ除去後の波形を規模の異なる 3 つのイベントに対して図-1 に示す。これより、全体としての波形は出水規模に依らずほぼ保存していることが分かる。

次に各イベントの時刻 $t_m$ での Wavelet ノイズ除去後のダム流入量を $q_m$ 、実績流入量 $Q_m$ のピーク時刻の $m$ を $m = p$ で表す。ピーク流入量の相対誤差 $J_{pe} \equiv (q_p - Q_p)/Q_p$ および流出ボリュームの相対誤差 $E_v \equiv (\sum q_m - \sum Q_m)/\sum Q_m$ の絶対値を各イベントをグループラベル  $w$

ごとに色分けして示すと、それぞれ図-2, 3 のようになる。 $J_{pe}$ の絶対値(図-2)から、Wavelet ノイズ除去では、ダム流入量のピーク値が大きいほど、ピーク誤差は小さくなるのが分かる。また 400 m³/s 以上のイベントでは、ピーク相対誤差はほぼ 5%未満となることが確認できる。一方、 $E_v$ の絶対値の分布(図-3)では、ほぼ全ての出水に対して相対誤差は 1%未満になっており、Wavelet ノイズ除去では流出ボリュームを保ちながら、ノイズ成分を除去していることが分かる。

#### 4. RNN 深層学習モデルの説明

まず、図-4(a)のように現時刻を基準に未来方向 (LeadTime)と過去方向(UsageTime)に展開した window(図-4(a)オレンジ枠)を用いて、単一RNNダム流入量予測モデルを構築する。windowへの展開は 1 時間間隔で、目的変数 (ラベル) は現時刻以降の 1 時間後のダム流入量、説明変数は window 区間のダム流入量と流域平均された時間雨量とする。ただし LeadTime のダム流入量は予測時には未定なので、学習時の入力値にも 1 時刻前の出力値を与えるもとする (図-4(a)破線青矢印)。学習時には 239 イベントのそれぞれに対して、イベント開始時刻と window 出発時刻を一致させ。イベント期間が重複し、同一の window が複数得られる場合は、一つの window のみを残し残りは排除する。対象流域での表面流出による降雨との時間相関は 1~2 時間であるが、中小規模洪水への長時間の流出の影響を考慮して、以下では UsageTime を過去に 6 時間まで延ばし、LeadTime を 24 時間とする。ただし単一の RNN では各 window の出発時刻の隠れ層(RNN Unit)への入力値(図-4破線赤矢印)がゼロになり、6 時間前からの流出の影響が含まれない。したがって 6 時間以上前の降雨などの影響を、図-4(b)中緑枠で示す別の RNN モデル(エンコーダ)で表現し、単一 RNN モデルの window の初期時刻(UsageTime 6 時間)の RNN Unit に連結したモデルを構築する。これにより、図-4(b)

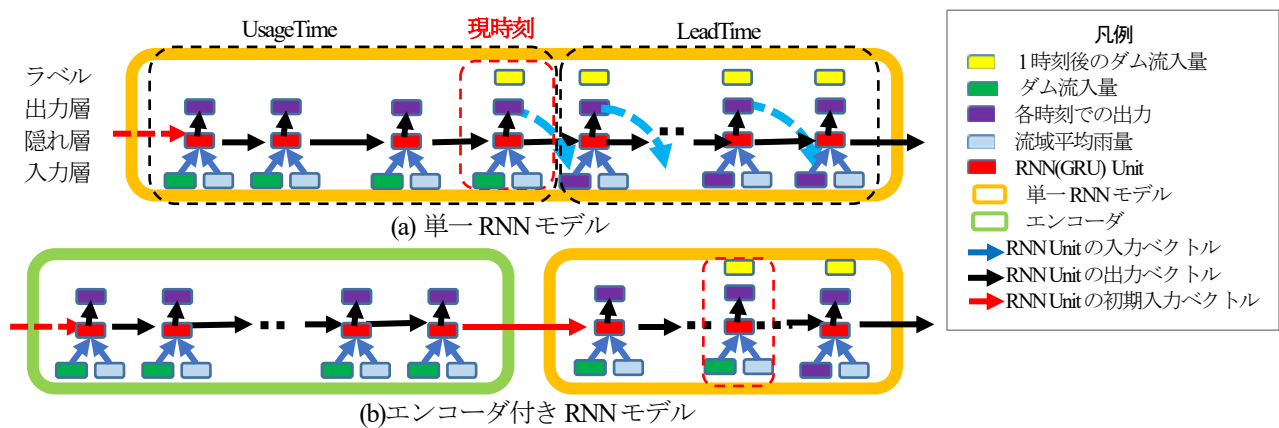


図4 RNNのwindow (a)単一 RNNモデル, (b)エンコーダ付き RNNモデル.

(単一 RNNモデルでは、同じ型のネットワークが現時刻を基準に未来方向[LeadTime]と過去方向[UsageTime]に1時間間隔で展開されている。ラベルは1時刻後のダム流入量とし、LeadTime では1時刻前の出力(紫).)

表-1 ハイパーパラメータの指定

	MLP	RNN
最適化手法	Adam	RMSprop
活性化関数	Leaky ReLU	Sigmoid, Tanh
ミニバッチサイズ	8, 16, 32	8, 16, 32
隠れ層の数	1, 2	1
各隠れ層のノード数	40, 60, 80	40, 60, 80

表-2 精度検証のケース命名規則

ダム流入量	モデル	UsageTime (単一 RNN)	UsageTime (エンコーダ)
N = 実績	M=MLP	3=3時間	無印= エンコーダ無し
W=ノイズ除去	R=RNN	6=6時間	en6 = 6時間
		12=12時間	en9 = 9時間

の単一 RNN モデルへの初期入力値 (赤矢印) にエンコーダによって過去の状態量に基づいた値が受け渡される。

異なる RNN の連結は、これまで seq2seq のような時系列エンコーダ・デコーダモデルに適用されている<sup>13)</sup>。Seq2seq では、エンコーダ部分が隠れ層を通してデコーダモデルで連結されている。以下ではエンコーダ部分を長時間流出用 RNN(図-4(b)緑枠)、デコーダ部分を短時間流出用 RNN(図-4(b)オレンジ枠)とした連結 RNN モデルを用いる。ただし長時間流出用 RNN の展開を 3 時間間隔、短時間流出用 RNN の展開を 1 時間間隔とする。また 3 時間間隔モデルでの雨量は 3 時間の累加雨量とする。また隠れ層の RNN Unit としては、計算負荷が少なく、LSTM と同等の性能を持つ GRU を用いる<sup>14)</sup>。

## 5. 学習手法とハイパーパラメータの最適化

以下では RNN に加え、単一 RNN と同じ説明変数、目的変数から成る MLP モデルを構築し予測精度の比較検証を行う。RNN, MLP のいずれも 5 つの教師データグループに対してデータを正規化し、複数の window をまとめたミニバッチを用い、各 window の現時刻以降の出力とラベルの間の MSE を誤差関数として確率的勾配降下法での学習を行う。学習の際のハイパーパラメータとしては、MLP, RNN のそれぞれに事前検証から表-1 の値を候補値として選び、複数の組み合わせの中から最適なものを見つける。また dropout 率を大きくすると MSE が

高止まりとなることから、以下では dropout 率ゼロとして早期終了を行い、検証用イベントに対する MSE の 5 エポックの移動平均値が最小になったエポック数でのモデルを用いる。モデルの構築および学習には python3, Tensorflow2.6 および CUDA 11.5 のライブラリを用いる。

## 6. エンコーダ付き RNN モデルの予測の精度評価

以下では、単一 RNN にエンコーダ部を連結した効果を見るために、LeadTime 24 時間のダム流入量予測を MLP, 単一 RNN, エンコーダ付き RNN それぞれについて、学習・推論を実施し、予測精度を評価する。検討ケースは表-2 に示す項目の組み合わせを実施した。予測の精度評価には、ラベル値 w(1~5)の教師データを用いた学習後モデルに、そのラベル値での検証用データを適用する。誤差評価の指標には、検証用データの 24 時間後予測に対する二乗平均平方根誤差 (RMSE) および流出ボリューム相対誤差を用いる。

図-5 に正規化における規格化定数  $\Delta Q = 65.35 \text{ (m}^3/\text{s)}$  で無次元化された検証データに対する RMSE を示す。実績ダム流入量を用いた MLP モデルでは、UsageTime 3 時間(NM3)より 6, 12 時間(NM6, NM12)がわずかに良い程度であった(図-5(a))。また、実績ダム流入量を用いた RNN モデル(図-5(b))では、MLP モデル(図-5(a))よりも高い精度が得られており、単一 RNN(NR6)に比べて、エンコーダ付き RNN モデル(NR6\_en6, R6\_en9)が RMSE で 0.02~0.03

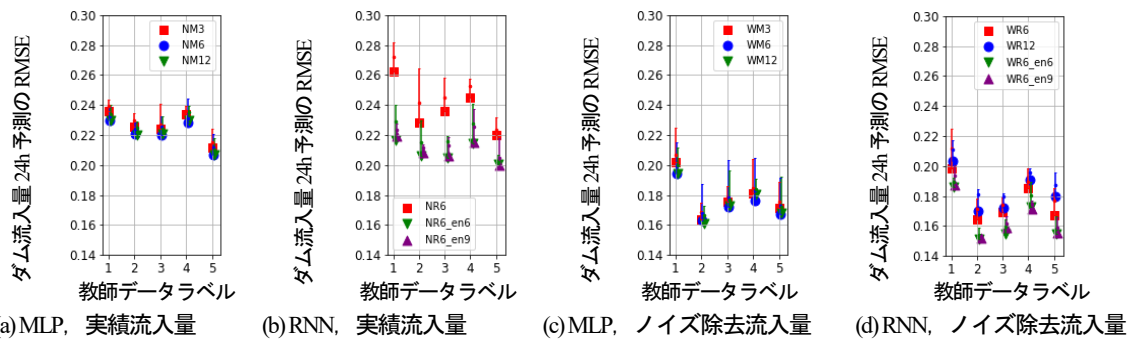


図-5 5種類の教師データに対するダム流入量24時間予測のRMSE比較

(縦棒は表-1のハイパーパラメータでの学習モデルによるRMSEの範囲, □, ○などの記号はRMSEの最小値.)

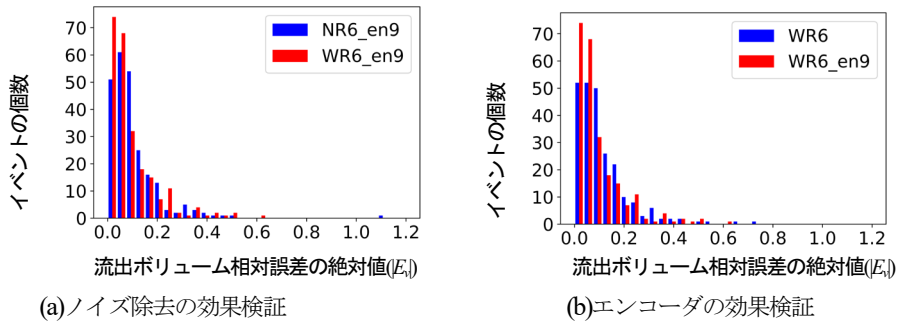


図-6 239の検証イベントの24時間後の予測波形の流出ボリューム相対誤差の頻度分布の比較




図-7 イベント2001\_04の24時間後のダム流入量予測結果

程度向上している。

次に、ノイズ除去したダム流入量を説明変数および目的変数として学習を行い、上述と同様の検討を実施した。この場合、MLPおよびRNNでのノイズ除去されたラベルに対するRMSEをそれぞれ図-5(c), (d)に示す。MLPの場合には、WM3よりもWM6, WM12の方がわずかに良くなるという実績流入量の結果図-5(a)と同様の傾向を保ちつつ、全体的に精度が上がっている(図-5(c))。一方、RNNの場合には、UsageTime 6時間(WR6)と12時間(WR12)の比較から、安易にUsageTimeを長くすると精度が低下する可能性がある事が示された。ただし、エンコーダを付けた場合には、付け無の場合よりも精度向上している事から、エンコーダを用いたRNNモデルは長期的な影響を考慮する方法として有用であると考えられる(図-5(d))。

図-6に、239の検証イベントの24時間後の予測波形から求めた流出ボリューム相対誤差の絶対値 $|E_t|$ の頻度分

布を示す。図-6(a)からWaveletノイズ除去の結果(赤棒:WR6\_en9)は実績流入量の結果(青棒:NR6\_en9)と比べ、 $|E_t|$ が低い値に分布しており、ダム流入量の収支を扱う場合には有効であると考えられる。図-6(b)からエンコーダを用いたRNNモデルでは、単一RNNモデルに比べて $|E_t|$ を低減させることが可能と考えられた。

最後にMLPおよびRNNでの予測波形を、1ピークの典型的な波形でピーク値が200(m<sup>3</sup>/s)程度のイベント(2001\_04)を選び比較した。MLPによる24時間後の予測波形(図-7(a))は、減衰期に波形が振動しており、ピークも低く予測されている。これに対して、RNNを用いた予測(図-7(b))では、ノイズ除去されたダム流入量波形と概ね一致している。ただし、このイベントではエンコーダの有無でピーク値に大きく差は出ない結果となっている。他のイベントについても、エンコーダ付与によりピーク値の精度に顕著な優位性が見られなかった。

## 7. 終わりに

本研究では、Wavelet ノイズ除去が、流出ボリュームの大きな出水でのピーク流量を保存するという点で、ダム流入量のノイズ除去に適していることを示した。また Wavelet ノイズ除去されたダム流入量を目的変数とすることにより、RNN ダム流入量予測精度におけるノイズの影響を考察した。今回は、小規模の一流域による検討を行い、エンコーダ付き RNN で予測波形の精度の統計的優位性が示された。ただし、エンコーダの付与は個々のイベントのピーク値の予測精度には強く反映されなかった。これについては、長期降雨の影響の特徴量が全てエンコーダーに反映されていないなどの可能性もあり。他の流域での検討も含め今後の検討課題としたい。

### 参考文献

- 1) 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.
- 2) 中村要介, 関本大晟, 阿部紫織, 新井章珣: RRI モデルとディープニューラルネットワークによる河川水位予測, 土木学会論文集 B1 (水工学), Vol.77, No.2, pp.I\_313-I\_318, 2021.
- 3) C.M.ビショップ(元田浩(監訳), 栗田多喜夫(監訳), 樋口知之(監訳), 松本裕治(監訳), 村田昇(監訳)): パターン認識と機械学習 (下), 丸善出版, pp.328-353, 2008.
- 4) 田村和則, 加納茂紀, 三浦心, 山脇正嗣, 金子拓史: ダム流入量長時間予測への深層学習の適用ーダム防災操作の効率化を目指してー, 土木学会論文集 B1 (水工学), Vol.74, No.5, pp.I\_1327-I\_1332, 2018.
- 5) 天方 匡純, 安野 貴人, 藤井 純一郎, 嶋本 ゆり, 大久保 順一: データ非線形性とダム流入量予測精度に関する研究, 第 33 回人工知能学会全国大会論文集, 2Q1-J-2-03, 2019.
- 6) 谷口 純一, 小島 崇, 曾田 康秀, 福元 秀一郎, 佐藤 尚, 町田 佳隆, 見上 哲章, 永山 正典, 錦織 俊之, 渡邊 明英: Recurrent Neural Network によるダム流入量の予測, 河川技術論文集, Vol.25, pp.321-326, 2019.
- 7) 三浦 奈都, 宮本 崇, 天方 匡純, 安野 貴人, 石井 明: ベイズ深層学習を用いた予報雨量の不確実性を考慮したダム流入量の確率的予測, AI・データサイエンス論文集, Vol.2, No.2, pp.933-943, 2021.
- 8) 中村 興一, 藤間 聡, 中村 篤史: ダム貯水池振動特性と貯水位平滑化について, 水工学論文集, Vol.48, pp.1387-1392, 2004.
- 9) I.ドヴシー, ウェーブレット 10 講, 山田道夫, 佐々木文夫 訳, Springer, 2003.
- 10) Jansen, M.: Noise reduction by wavelet thresholding. Lecture Notes in Statistics Vol. 161. Springer, 2001.
- 11) Anutam and Rajni: Performance Analysis of Image Denoising with Wavelet Thresholding Methods for Different Levels of Decomposition, The International journal of Multimedia & Its Applications(IJMA), Vol.6, No.3, pp. 35-46, 2014.
- 12) Lee, G. R., Gommers, R., Wasilewski, F., Wohlfahrt, K. and O'Leary, A.: PyWavelets: A Python package for wavelet analysis, Journal of Open Source Software, 4(36), 1237, <https://doi.org/10.21105/joss.01237>.
- 13) Sutskever, I., Vinyals, O. and Le, Q.V.: Sequence to Sequence Learning with Neural Networks, <https://arxiv.org/abs/1409.3215v3>, 2014.
- 14) Pan, M., Zhou, H., Cao, J., Liu, Y., Hao, J., Li, S. and Chen, C.: Water Level Prediction Model Based on GRU and CNN, IEEE Access, Vol.8, pp. 60090-60100, 2020.

(Received May 31, 2022)

(Accepted September 1, 2022)

## MODELLING AND EVALUATION OF ENCODER ATTACHED RNN FOR THE PREDICTION OF DAM INFLOW DURING SMALL AND MEDIUM-SIZED RAINFALL EVENTS

Yasuhide SOTA, Daiwei CHENG, Takashi KOJIMA, Akihide WATANABE  
Satoshi WAKAMATSU and Toshiyuki NISHIKORI

Prediction of dam inflow for small and medium-sized rainfall events is strongly affected by the noise of dam inflow, caused by the fluctuations of the reservoir's water level. In addition, recurrent neural network (RNN), which is one of the prevailing deep learning models, have difficulty in adapting the condition of the basin preceding the target rainfall events. From these viewpoints, firstly, we applied Wavelet transforms to reduce the noise of dam inflow during the flood period. Secondly, we proposed encoder attached RNN to adapt the prior condition of the basin. Finally we compared it with multi-layer perceptron (MLP) to verify the accuracy of the predictions up to 24 hours.