

CNN-GRU を用いたため池貯水量の予測

Prediction of Water Storage in Irrigation Ponds Using CNN-GRU Neural Network

○ 李 相潤*・吉迫 宏*・小嶋 創*

LEE Sangyoon・YOSHISAKO Hiroshi・KOJIMA Hajime

1. はじめに

ため池が持つ洪水調節機能の活用にあたっては、灌漑との両立の上で洪水調節機能を強化する手法の開発が必要である。ため池は、ダムと異なり貯水運用の検討に必要な水文観測データや放流に関わる記録データに制約があるものの、慣行的な水管理（例えば、灌漑のための取水期間、雨天時の扱いなど）に基づく貯水量は降雨を入力とした出力の関係であるため、データの間接関係を反復学習させる深層学習をツールとして利用すれば、貯水量を直接に予測できる可能性があると考えられる。そこで、深層学習アルゴリズムのうち、データの関係から特徴抽出を得意とする CNN (Convolutional Neural Network) と時系列データの処理を得意とする RNN (Recurrent Neural Network) 系 GRU (Gated Recurrent Unit) を利用して、ため池貯水量の予測を試行した。

2. 研究対象ため池および方法

研究対象ため池は兵庫県内の A 池とした。この池においては 2016 年 4 月 16 日から継続して 10 分ごとの水位・雨量の観測を実施している（欠測期間有：2017 年 6 月 7 日～11 月 22 日）。

モデルは、将来の電力消費量や株価の予測で良い結果が得られた^{1),2)}CNN と RNN 系モデルの結合アルゴリズムを用いて Keras で実装した。具体的には、李ら（2022）が予測遅れ（予測値において観測値より遅れを生じること）の改善策として検討した Lead Time（現時刻から予測しようとする時刻。以下、LT）期間に対応する入力変数（LT_Rsum）を含め 4 変数を入力データとし、短期間の 1 時間先、3 時間先、6 時間先（以下、LT1h, LT3h, LT6h）、ならびに長期間の 1 日先、2 日先、3 日先（以下、LT1d, LT2d, LT3d）それぞれに対応した将来の貯水量を予測するモデルを構築した（図 1）。加えて、このモデルの予測精度を評価するため、CNN と GRU についても上記と同様に LT ごとに生成（CNN, GRU1）し、モデルごとの予測精度を比較した。なお、LT 期間に関する変数の予測遅れへの影響を示すため、上記モデルと異なる変数 LT_Rsum 無のモデル（GRU2）も生成し、予測精度を求めた。

分析では、欠測期間を除き、観測データから作成した 2017 年 11 月 23 日～2021 年 12 月 31 日まで 1 時間別の水位・雨量データ（2021 年分：テスト、残りの分：訓練及び検証）を用いた。モデル評価の指標は RMSE (Root Mean Squared Error) と NSE (Nash-Sutcliffe Efficiency) とし、モ

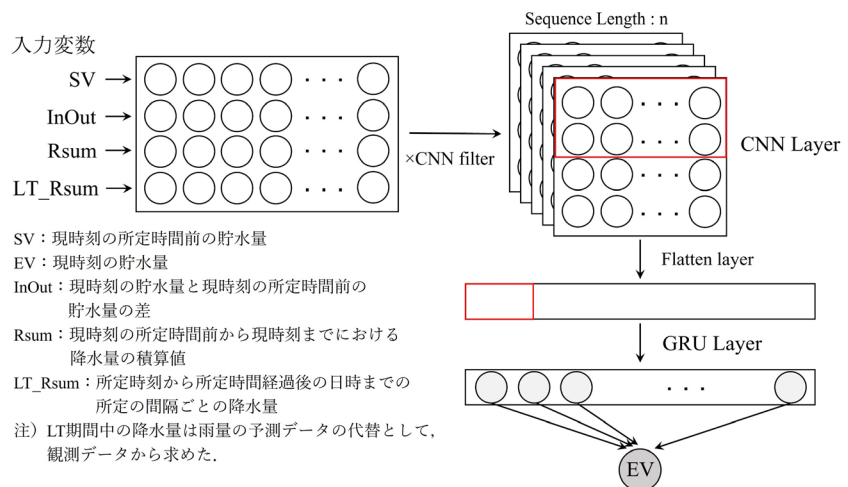


図 1 CNN-GRU の構造
Fig1 Basic structure of the CNN-GRU

* 農研機構 NARO キーワード：深層学習、ため池、貯水量予測

表1 モデルごとの入力変数の組合せと予測結果
Table1 Input combination and prediction results for each model

モデル名	入力変数				30回の 平均値	Lead Time (LT)					
	SV	InOut	Rsum	LT		Rsum	1h	3h	6h	1d	2d
CNN	○	○	○	○	RMSE	0.0038	0.0062	0.0086	0.0221	0.0316	0.0398
					NSE	0.9995	0.9989	0.9981	0.9876	0.9749	0.9604
GRU1	○	○	○	○	RMSE	0.0021	0.0049	0.0074	0.0203	0.0319	0.0395
					NSE	0.9998	0.9993	0.9986	0.9896	0.9745	0.9610
CNN-GRU	○	○	○	○	RMSE	0.0031	0.0051	0.0081	0.0201	0.0311	0.0393
					改善率	-37.5 %	-4.5 %	-9.6 %	1.1 %	2.5 %	0.4 %
GRU2	○	○	○	○	RMSE	0.0032	0.0060	0.0095	0.0250	0.0384	0.0498
					NSE	0.9996	0.9991	0.9977	0.9843	0.9632	0.9382

改善率 = $100 \times (\text{GRU1のRMSE} - \text{CNN-GRUのRMSE}) / \text{GRU1のRMSE}$

モデルごとに30回の平均値を求めて評価に用いた。

3. 結果及び考察

モデルごとの予測結果を表1と図2に示す。短期間の貯水量予測結果(LT1h~3h)については、GRU1の方がCNN-GRUに比べて良好であるものの、長期間(LT1d~3d)の予測については

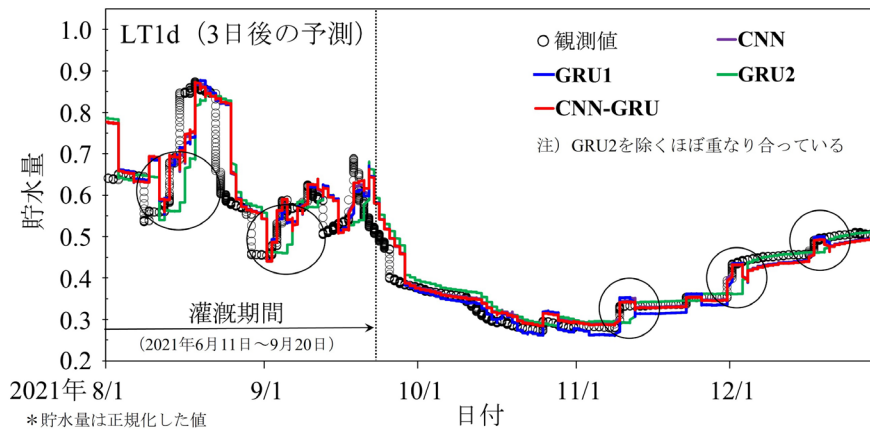


図2 モデルごとの予測結果 (3日後の予測)
Fig2 Prediction results for each model

CNN-GRUの方がGRU1より若干良いことがわかる(改善率0.4~2.5%)。図2ではCNN-GRUとGRU1の予測結果はほぼ重なり合っており、CNN-GRUを用いることによる予測精度や予測遅れの改善には目立つ効果は見られない。これは学習データの個数が少なかったため、慣行的な水管理、すなわち入力と出力データの関係が十分に学習されなかったことにより、CNNによる入力データからの特徴抽出が十分にできなかった可能性があると考えられる。また、これは水文観測データの観測期間が短いため池においてはCNN-GRUのような複雑なモデルより単純なモデルが良い(少なくとも同様な)結果が得られる可能性があることを示唆する。また、GRUは設定に経験を要するハイパーパラメータ数も少ないため、モデルの最適化が容易である。

図2中に○囲みで示した箇所を見ると、GRU2を除き観測値と予測値の差である予測遅れは小さい。GRU2以外のモデルでは、入力変数としてLT期間の雨量データを用いている。この結果は、予測遅れの改善については、モデルの構造よりLT期間に対応する入力変数の抽出・活用が重要であることを示すものと考えられる。

4. おわりに

CNN-GRUを用いてため池の貯水量予測を試行した。水文観測データなどの観測期間が短いため池においては、複雑なモデルより単純なRNN系モデルの実用性があることが示唆された。今後はLT期間に対応する入力変数を検討し、モデルを改善する予定である。

謝辞：本報告は文部科学省気候変動予測先端研究プログラム「領域課題4 ハザード統合予測モデルの開発(JPMXD0722678534)」の補助を受けたものである。

参考文献：1) Kim et al. (2019) : Energy, Vol 182, 72-81, 2) Lu et al. (2020) : Complexity, vol 2020, <https://doi.org/10.1155/2020/6622927>, 3) 李ら (2022) : AI・データサイエンス論文集3 (J2), 693-703