

## 灌溉期間を通じたため池貯水量の深層学習による予測

### Prediction of Water Storage in Agricultural Irrigation Ponds Using Deep Learning

○ 李 相潤\*・吉迫 宏\*・松田 周\*・小嶋 創\*  
 LEE Sangyoon · YOSHISAKO Hiroshi · MATSUDA Shuh · KOJIMA Hajime

#### 1. はじめに

洪水調節機能を持つため池の活用にあたっては、利用容量を確保した上で洪水調節機能を強化する最適な貯水運用方法の開発が必要である。タンクモデルのような長期間の流出予測が可能な物理モデルでは、一般に10年程度の水文観測データが必要となるものの、大多数のため池ではダムと異なり、水文観測や取水量に関わる記録がなされていない。このため、水文観測データに制約があるため池において、灌溉期間を通じた貯水量を妥当な精度で予測するため、深層学習モデルを用いたため池貯水量の予測を試行した。

#### 2. 分析対象ため池および方法

(1) 分析対象ため池 水文観測データに制約（比較的短期間の水文観測データが存在）がある兵庫県内のA池を対象とした。A池においては2016年度から継続して10分ごとの水位・雨量の観測を実施している。

(2) 方法 本報では、深層学習を用いて株価の4変数（始値、高値、安値、出来高）を入力データとして1日先の終値を予測するモデルに参考（DeepLearing, 2022）に、n日間前までの5変数の入力変数データを用いて1日間先の貯水量を予測するモデルを構築した（図1）。

分析では、まず収集した観測時系列データから入力変数・出力変数を生成した。また、観測時系列データの連続性を担保するため、水位・雨量の欠損及び欠損以前のデータを除いて2018年1月1日から2020年12月31日までの日別データ（1,095箇所）を用いた。モデル生成アプローチは、データ読み込み（データセット構成、データ正規化など）、モデル構築に必要なハイパーパラメータ設定（バッチのサイズ、重みの学習率、層の数、ニューロンの数、エポック数など）、モデル構築、モデルの学習（損失関数や学習アルゴリズムの設定）、モデル評価の順で行った（DeepLearing, 2022）。nを30と設定し、生成した入力・出力変数のデータ（1,056セット）は、トレーニングデータ（730セット）とテストデータ（326セット）に分割し、モデルの学習にはトレーニング

データを評価にはテストデータを用いた。モデルは時系列データの予測を得意とするRNN（Recurrent Neural Network）系のGRU（Gated Recurrent Unit）を用いてPyTorchで実装した。この時、6種類の入力変数を設定（表




図1 モデルの構造  
 Fig1 Basic structure of the model

\* 農研機構 NARO キーワード：深層学習、ため池、貯水量予測

1) し、予測精度に影響を与える変数を検討した。モデルの評価は RMSE (Root Mean Squared Error) を基準として Case ごとに 50 回の平均値を求めた。

### 3. 結果及び考察

Case ごとの予測結果を図 2、表 1 に示す。各 Case の平均 RMSE は Case 6 を除くと 0.024~0.032 で、全体として日別貯水量をよく予測しているように見えるが、貯水量の立ち上がりや座り込みの部分で、予測値が実測値より少し遅れて 1 日程度後追

していることがわかる。これは RNN 系モデルの特徴による。このモデルは学習の時、実測値と予測値の差が最小になるようにモデル内パラメータの係数を調整するため、モデルは「当日貯水量との差が最も小さい予測値は、前日の貯水量」と判断する傾向が強いからである。

貯水量に関する変数 (SV, Max, Min) を用いた Case 1~5 の予測精度が Case 6 より良いことは、この RNN 系モデルの特徴によるものと考えられる。図 2 において Case 3 と Case 1~2, Case 4~5 を比較すると、Case 1~2 と Case 4~5 は InOut を変数に利用しなかった Case 3 より遅れが少し改善されていることがわかる。また、Case 1 と 2 の比較から、変数 Rsum は予測精度に影響を及ぼさないことがわかる。

これら変数の違いは、InOut は貯水量から求めた変数であるのに対し、Rsum は 1 日の降水量で貯水量との関係はデータに反映されていないことである。この結果より降水量の情報は、降水量のデータとしてそのまま入力変数として与えるのではなく、降水量に関わる変数に変換した上で入力した方が予測遅れの改善につながる可能性があるものと示唆された。

### 4. おわりに

水文観測データに制約があるため池を対象に、灌漑期間を通じた貯水量を深層学習モデルにより予測し、モデルの改善点などについて検討した。この結果、予測遅れが深層学習モデルの重要な問題点であり、これは入力変数により改善される可能性があることが推察された。今後は予測遅れを解消する方法を検討し、モデルを改善する予定である。

**謝辞**：本報告は農林水産省委託プロジェクト研究「ため池の適正な維持管理に向けた機能診断及び補修・補強評価技術の開発」JPJ009839 の補助を受けたものである。

### 参考文献

- 1) DeepLearnng.H.H. (2022) : PyTorch for DeepLearning, YoungJin.com, pp.98-159

表 1 入力変数の組合せと平均 RMSE  
Table1 Input combination and average RMSE for each case

ケース名	入力変数					50回平均RMSE
	SV	Max	Min	InOut	Rsum	
Case1	○	○	○	○	○	0.025
Case2	○	○	○	○	○	0.024
Case3	○	○	○		○	0.032
Case4	○				○	0.024
Case5	○	○	○	○	○	0.024
Case6				○	○	0.209

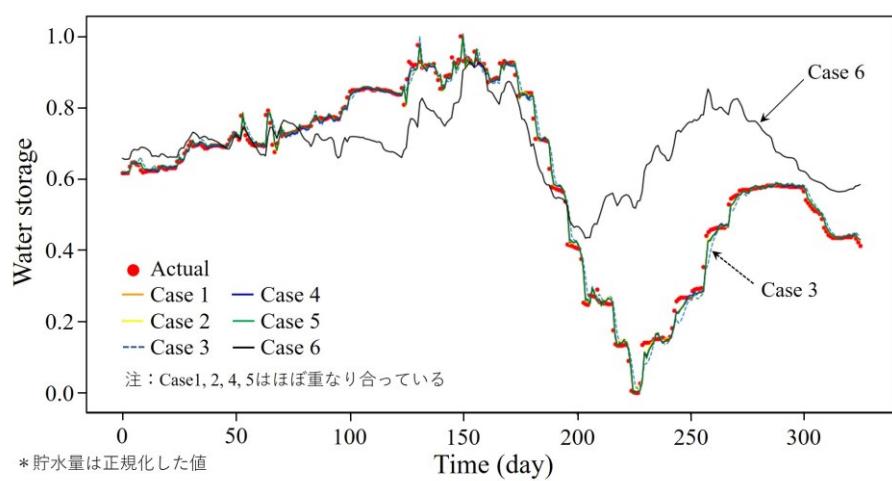


図 2 ケースごとの予測結果 (50 回の平均値)

Fig2 Prediction results for each case