

深層学習を用いたため池水位予測モデルの構築とその評価 Development and Evaluation of Reservoir Water Level Prediction Model by Deep Learning

○楠堂紡*, 山本純之*, 木村匡臣*, 松野裕*

○Tsumugu KUSUDO, Atsushi YAMAMOTO, Masaomi KIMURA, and Yutaka MATSUNO

【はじめに】近年、治水対策として豪雨時における農業用ため池への一時的貯留を見越した事前放流が有効と考えられているが、その実施のためには予測される降雨下でのため池の水位変化を的確に予測する事が求められる。ところが、流出量や水位の予測手法は過去に多数研究されているものの、モデル構築には集水域や河道網を特徴付ける複数のパラメータや流出量の経年観測を必要としており、管理者の多くが農家であるため池への利用は進んでいない。一方、比較的少数のパラメータでも予測可能である深層学習を活用した研究が近年着目されており、中でも長短期記憶(LSTM)を用いた再帰型ニューラルネットワークは過去の重み付けを次のタイムステップの重み付けへ伝達できるため、連続的な流量の解析に有効であることが報告されている¹⁾。LSTM は連続したデータを入力し単一の出力を行う LSTM-Single Output (SO モデル) を基本としているが、流出解析においては入力に用いる水位データだけでなく予測する水位も連続的である理由から、出力においても連続性を持たせることが望ましいと報告されている²⁾。時系列の出力に対応したモデルを代表するものとして LSTM-Encoder Decoder (ED) があるが、これを用いた流出解析の事例は少なく、ため池での活用事例も見られない。そこで本研究では、観測・記録が容易な水位、降雨、放流操作の記録を入力パラメータとして SO モデルおよび 24 時間後までの連続的な水位を予測する ED モデルを構築し、それらの比較と評価を行った。最後に事前放流への活用に向け、放流操作の有無による予測結果の違いをシミュレートした。

【研究対象地】奈良県生駒市に位置する高山溜池は大和川水系にある富雄川の水源の一つであり、満水面積約 9ha、受益面積約 530ha、集水面積 230ha、貯水容量約 58 万 m³、堤高約 23m の農業用ため池である。この高山溜池の堤体付近に雨量計と水位計を設置し学習および検証データを 1 時間ごとに取得した。放流の記録は管理団体である北倭土地改良区より提供いただいた。

【モデルの概要】ED モデルは、入力した時系列データを固定長ベクトルに変換する Encoder と、固定長ベクトルを時系列データに変換する Decoder の構造を併せ持っている(図 1)。本研究では、Encoder 部分に $t-24$

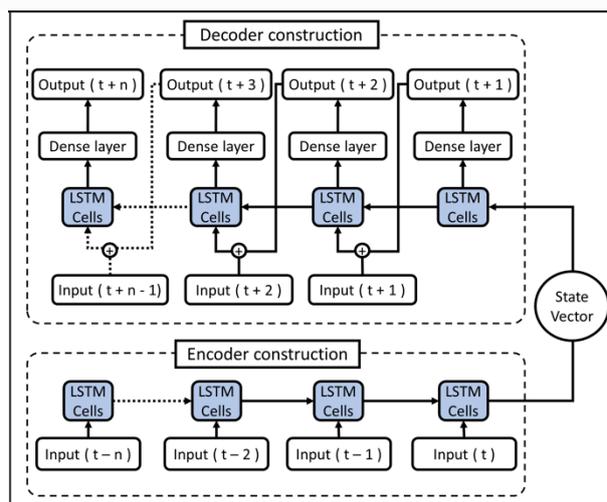


図 1. LSTM-Encoder Decoder によるため池水位予測モデル
Fig1. Reservoir water level prediction model by LSTM-Encoder Decoder

*近畿大学農学部 Faculty of Agriculture, Kindai University

キーワード：ため池 深層学習 LSTM

～ t 時間の 1 時間毎水位, 降雨量, 現在時刻との水位差, 放流操作の有無を, Decoder 部分に Encoder から抽出した固定長ベクトルと将来降雨量, 出力された予測水位を入力して $t+1$ ～ $t+24$ 時間の水位を出力した. SO モデルには $t-24$ ～ t 時間の水位, 降雨量, 現在時刻との水位差を入力し, $t+1$ 時間の水位変化量を出力した. 出力した予測値を入力データとして次の時刻の予測を行うことを繰り返し, $t+24$ 時間までの水位予測を行った. 両モデルともに, 出力された水位差を t 時の水位に加算し, 実測した水位変化と比較した. 初期重み付けや GPU による学習のばらつきを平滑化するため, 未学習の状態からの学習を 30 反復し, その平均値を予測値とし評価を行った. 評価関数には二乗平均平方誤差 (RMSE) を用いた. 使用するデータ取得期間を 2018/7/1～2020/7/24, そのうちの最大降雨を含む 2019/7/2～2019/9/23 をテストデータとした. また 2020/5/2～2020/7/24 の期間を学習度確認のための検証データとして用いた.

【結果と考察】テストデータにおける $t+1$ ～ $t+24$ 時間の平均 RMSE を図 2 に示す. 予測時刻 $t+10$ 時間付近まではモデル出力間に大きな差はみられないが, 予測時刻が長期になるにつれて ED モデルの RMSE は SO モデルを大きく下回り, $t+24$ 時間には従来の SO モデルに比べ RMSE が 42% 小さくなった. この結果から Decoder 構造によって連続的に出力することで予測誤差の拡大を抑制する効果があると言える. 次に学習データの範囲内にある降雨イベントによる予測結果を図 3 に示す. ED モデルにおける予測結果は, 降雨による水位の上昇初期から緩やかな水位の増加を再現できている. またこのケースにおける ED モデルの RMSE は 0.02m 程度と高い精度で予測が可能であった. 図 3 の降雨イベントにおいて, 降雨開始前に放流を行った場合の水位変動シミュレーションの結果を図 4 に示す. このように放流操作を行う場合との水位予測結果を比較できるため, 将来の降雨に対し放流期間の決定が可能となり, より緻密なため池水位管理への活用が期待される.

【参考文献】

- 1) Hu, C.; Wu, Q.; Li, H.; Jian, S.; Li, N.; Lou, Z. Deep learning with a long short-term memory networks approach for rainfall-runoff simulation. *Water (Switzerland)* 2018, 10, 1–16, doi:10.3390/w10111543.
- 2) Li, W.; Kiaghadi, A.; Dawson, C. Exploring the best sequence LSTM modeling architecture for flood prediction. *Neural Comput. Appl.* 2020, 3, doi:10.1007/s00521-020-05334-3.

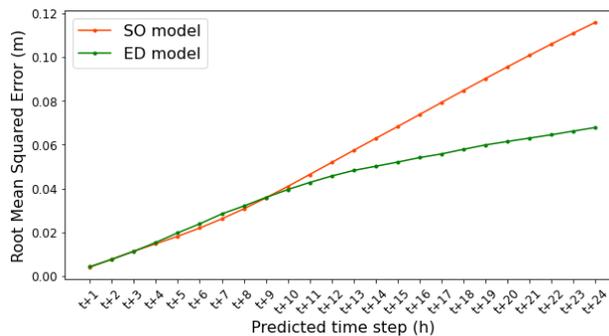


図 2. 各時刻の RMSE
Fig2. RMSE for each time

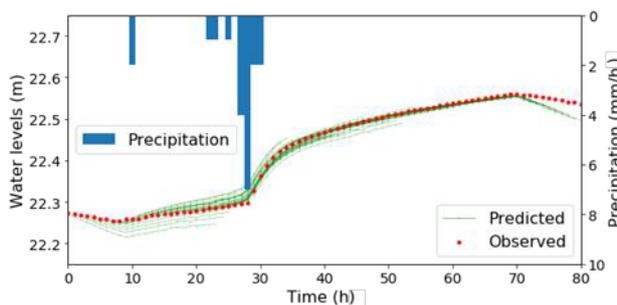


図 3. ED モデルによる予測値と実測値の比較
Fig3. Comparison of ED predictions and observations

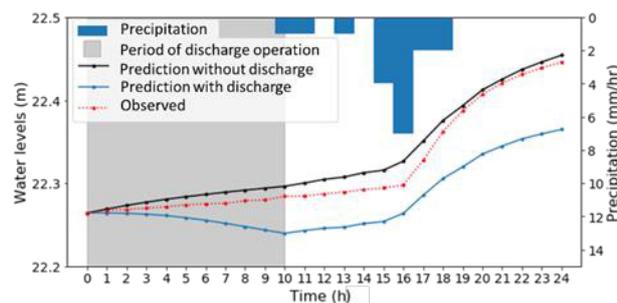


図 4. 放流操作の有無による
予測水位の違い
Fig4. Differences in predicted water level
due to simulated discharge operations