

長短期記憶(LSTM)を用いた溜池水位予測モデルの構築と最適化
Development and Optimization of Reservoir Water Level Prediction Model by
LSTM

楠堂紡*, 林大輔*, 松浦大輝*, 山本純之*, 木村匡臣*, 松野裕*

Tsumugu KUSUDO, Daisuke HAYASHI, Daiki MATSURA, Atsushi YAMAMOTO Masaomi KIMURA,
and Yutaka MATSUNO

【はじめに】近年農業用溜池においては、その老朽化や管理不足による、豪雨や地震などの際の事故が懸念されている。この解決策として中小規模の溜池においても豪雨による流入量の増加を考慮した事前放流が考えられている。そのためには、降雨に対応した溜池の水位変化を予測する事が重要となる。本稿では、溜池水位予測の手法として長短期記憶(LSTM)を用いた再帰型ニューラルネットワーク(RNN)の構築を行った。そして、モデル各層のパラメータチューニングとテストデータに着目し、その再現性を評価した。

【実施地概要】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、灌漑面積約530ha、貯水容量約58万 m^3 、堤高約23mのため池である。主に農業用水として下流域に放流を行っている。この高山溜池の西部に気象センサー、南部に水位計を設置し降雨量と水位の観測を行った。

【深層学習と LSTM】深層学習とは機械学習手法の一つであり、深層学習の中でも再帰型ニューラルネットワーク(RNN)は時系列データの学習を行う際に用いられる。長短期記憶(LSTM)は中間層ユニットをLSTMブロックに置き換えたRNNであり、シンプルなRNNとは異なり長期的な学習においても勾配損失問題による精度低下が起こらないモデルとして注目されている。水位予測において長期的な学習(過去の大雨や水位変化等)が重要であるため本研究ではLSTMモデルを採用した。

【水位予測モデルの構築】今回各層のパラメータチューニングによる精度比較を行う為に中間層の損失関数をMSEとMAEに変えた2パターン、過去降雨時間の入力範囲を1時間前~24時間前とした24パターンの計26モデルを作成した。損失関数比較における過去降雨時間は12時間前以降、過去降雨時間比較における損失関数はMAEとした。降雨以外の入力値は現在水位、中間層のLSTM層の数は1、ユニット数は32、出力層は現在水位と1~24時間後の水位との差、学習回数(Epoch)は300とした。使用したデータの観測期間は2018/8~2020/2、このうち2019/8/15~2019/8/18(降雨パターンA)と2018/9/28~2018/10/2(降雨パターンB)をテストデータとし、それ以外のすべてのデータを学習データとした。テストデータの選定理由として、Aは最大20mm程度の強雨を含む降雨パターン、Bは5mm程度の弱雨と10mm程度の雨が組み合わさった降雨パターンであり、特徴が異なることが挙げられる。出力された水位差を0時間時点の水位に加算し、実測の水位変化と比較・評価した。評価関数には二乗平均平方誤差(RMSE)を用いた。

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

キーワード：溜池 深層学習 LSTM

【結果①損失関数の比較】損失関数の違いにおける学習度は、損失関数のMSEに比べMAEが0.002mほど優位であった(Fig. 1). MSEは一般的に外れ値や変化の大きい値を学習に大きく取り入れるとされる。水位予測においてもMSEを用いた先行研究も見受けられるが、豪雨による急激な変化以外にも緩やかな水位変化も多くあるため、総合的な学習度の評価においてはMAEが優位になったと考えられる。




Fig.1 損失関数による学習度の違い

【結果②入力範囲と降雨パターンにおける精度比較】最も多い過去降雨量範囲の24時間前よりも、14時間前の過去降雨量を入力とした場合の方が、RMSEの値は低くなった(Table. 1). 深層学習は、数多くの入力層の中から必要な要素を抽出し学習できるという報告もあるが、溜池水位予測においては流入範囲などに則った適切な入力範囲の選定が必要であることが示された。また今回異なる降雨パターンでも評価を行った結果、降雨パターンによって予測できる精度に差が生まれることがわかった(Fig. 2, 3, 4, 5). これは、深層学習が非線形のモデルであり、学習させる降雨パターンや水位変化量に依存するためであると考えられる。また、少量の降雨で緩やかに水位が上がる場合は実測より低く予測する傾向にあった。

Table.1 入力範囲とテストデータにおけるRMSEの違い

過去降雨量 (時間前)	降雨パターンAでの RMSE(m)	降雨パターンBでの RMSE(m)
24	0.103	0.088
14	0.059	0.101




Fig.2 24時間前+降雨パターンAの予測実測比較




Fig.3 24時間前+降雨パターンBの予測実測比較




Fig.4 14時間前+降雨パターンAの予測実測比較




Fig.5 14時間前+降雨パターンBの予測実測比較

【おわりに】本稿において、溜池水位予測におけるLSTM型RNNモデルの有用性が示された。一方で、中間層のパラメータや入力する過去降雨量の範囲によって精度が異なり、その重要性が改めて示された。特に深層学習においては入力層から必要なデータを抽出できるという利点もあるが、水位予測においては流入域と合わせた範囲の選定が必要であると考えられる。また、モデルの評価に2つの降雨パターンを用いたところ、RMSEが示す値に大きな差がみられた。今後この溜池水位予測モデルの更なる精度向上や他溜池での適応を進めていき、その上でパラメータチューニングや評価に留意する必要がある。