

深層学習を用いた農業用水の供給量予測

Prediction of agricultural water supply using deep learning

○伊藤 良栄* 本村 侑哉** 加治佐 隆光* 近藤 雅秋*

○Ryoei Ito, Yuya Motomura, Takamitsu Kajisa and Masaaki Kondo

1. はじめに

AI を用いた予測手法に関する研究が盛り上がりを見せている。その一方、農業用水予測に適用した研究は少なく、槻瀬(2018)の試みがなどがあるのみである。

本研究では、槻瀬(2018)に従い中勢用水をモデル地区とし、深層学習を用いた農業用水の供給量予測が可能か再検討した。さらに、最も予測精度が高くなる学習手法や説明変数の最適化を試みた。

2. 研究方法

2.1 目的変数

目的変数は、中勢用水土地改良区事務所に蓄積されている 2016 年 1 月 1 日から 2018 年 10 月 31 日までの幹線水路(2 路線)及び頭首工(4 か所)の日単位取水量実績 (m^3/day) を採用した。なお、予測期間は 2018 年 4 月 20 日から 2018 年 10 月 31 日の 195 日間とした。

2.2 説明変数

説明変数は、津地方気象台で観測された同期間の 1 日あたりの降水量(mm/day)、平均気温($^{\circ}C$)、日照時間($hour/day$)に加え、今回新たに安濃ダムの有効貯留量(m^3)及び中勢用水の水利権量(m^3/day)を採用した。

2.3 深層学習モデル

LSTM, CNN, GRU, QRNN の計 4 つの学習手法で計算を試みた。いずれの手法でも、学習させた後に予測日前日から過去 60 日間分の説明変数を 1 セットとして入力し、目的変数である予測日の取水量を出力するモデルとした。最適化手法は Adam, 学習率は 0.001 を採用した。説明変数は

Z-Score Normalization, 目的変数は Min-Max Normalization により正規化した。

2.4 モデルの評価基準

基本的には予測値と実測値の RMSE を基準とした。しかし、実用面も考慮して、予測値と実測値のグラフの形状の一致度合い、さらに取水量が急増または急減する時期をどれだけ捉えているかを含めて総合的に判断した。

3. 結果及び考察

3.1 槻瀬(2018)モデルの改良

取水量及び気象データを訓練、検証及びテストデータに分割、さらに情報の漏れを減らすため、データの分割前にランダムにシャッフルせずに訓練した。

気象データのみを入力した場合、予測精度が悪く、改善の余地がある結果となった(図 1)。




図 1 実測値と予測値の比較(槻瀬(2018)モデル)

Fig.1 Result of Tsukise (2018) model

3.2 説明変数の追加

そこで、気象データに加え、安濃ダムの有効貯留量 (m^3) 及び中勢用水地区内の水利権量 (m^3/day) を説明変数に追加し、予測精度がどの

* 三重大学大学院生物資源学研究科 Graduate School of Bioresources, Mie University

** 元三重大学生物資源学部 Faculty of Bioresources, Mie University

キーワード: IT, 機械学習, 水田灌漑

程度改善されるか比較した。安濃ダムの有効貯留量，水利権量のいずれか一つを説明変数に追加した場合(図2)，両方を追加した場合(図3)のいずれでも予測精度が向上した。

ま

また，これまでエポック数は1,000としていたが，計算時間も考慮し，以降の解析ではエポック数は100を採用することにした。




図2 実測値と予測値の比較(説明変数追加)

Fig. 2 Result of adding objective variable

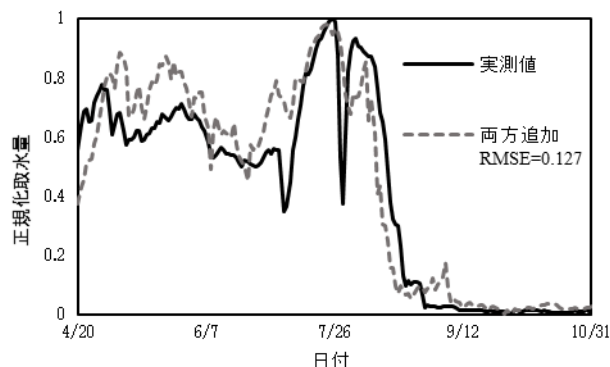


図3 実測値と予測値の比較(説明変数追加)

Fig. 3 Result of adding both objective variables

3.3 別期間のデータセットを用いた検証

槻瀬(2018)が使用した取水量データの中で欠測値のない範囲を学習用データとし，本研究で使用した取水量をテストデータとした。

予測結果は実測値と概ね一致しており，学習用データセットとテストデータセットの期間が不連続の場合でも予測可能であった(図4)。この結果より，中勢用水では供給主導型の水管理がなされ，年毎の取水量に大きな変化が見られないことが示唆され，土地改良区へのヒアリングでも供給主導型の水管理が再確認された。




図4 実測値と予測値の比較(別期間データセット)

Fig.4 result using data set of another period

3.4 学習手法の最適化

学習手法をLSTM以外のもの(CNN, GRU, QNN)に変えることで予測精度の向上がはかれるか検証した。

いずれの学習手法も予測精度の向上は見られず，今回の検討の範囲では，供給量予測においてLSTMが最も高い予測精度を発揮することが分かった(図5)。

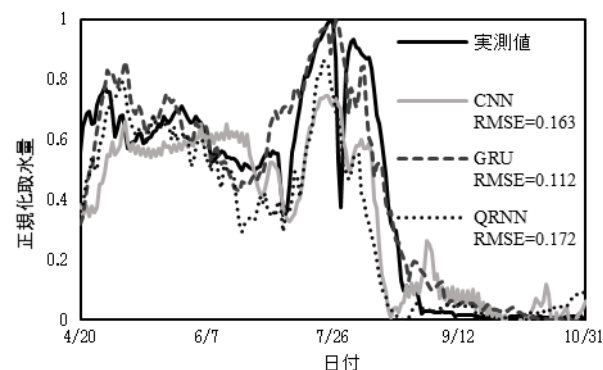


図5 実測値と予測値の比較(学習手法の比較)

Fig.5 Comparison of different learning methods

4. まとめ

深層学習を用いた農業用水の供給量予測の可能性を再検討し，十分予測可能であることを示せた。その過程で，学習手法としてLSTMが最善であり，貯水ダムの有効貯留量や水利権量のいずれも取水量予測に重要な因子であることを示した。

参考文献

槻瀬(2018)「機械学習を活用した農業用水需要の予測手法」, 2018年度農業農村工学会大会講演会要旨