

再帰型ニューラルネットワークによる河川水位予測

西日本技術開発株式会社 正会員 ○瀧口 晃
西日本技術開発株式会社 非会員 坂本奈々美

1. はじめに

近年、IoTやAI技術の利活用が急速に進んできており、特にインフラメンテナンス分野では点検・診断作業の効率化を図るための劣化診断を始めとする判定技術、ダム運用支援のためのダム流入量や下流の河川水位の予測技術を始めとして様々な計測分野においてAIの活用、研究開発が進んでいる。

本研究では、ダムの運用などに資する予測技術の高精度化を図る上での基礎的研究として、時系列データの予測に有用な再帰型ニューラルネットワーク(以下RNNと表記する)を活用し、降雨の観測データから河川水位を予測する場合の予測精度とその適用性を検討した。

2. 深層学習と予測手法

RNNの中間層では、入力層のデータに加え1つ前のステップの中間層の値も保持するため、時間ステップごとに連結した過去の時系列データとの依存性が考慮可能となる(図1)。ただし、数十ステップではそれほど問題とはならないが、長期に及ぶほど勾配消失の問題が生じる得るため、活性化関数にはReLUを採用する。

本検討では、上記のRNNの通常セル(BasicRNN)および長期依存性などに有用とされるLSTM(Long Short-Term Memory)セル¹⁾、その簡易版に相当するGRUセル²⁾についても比較検討を行った。

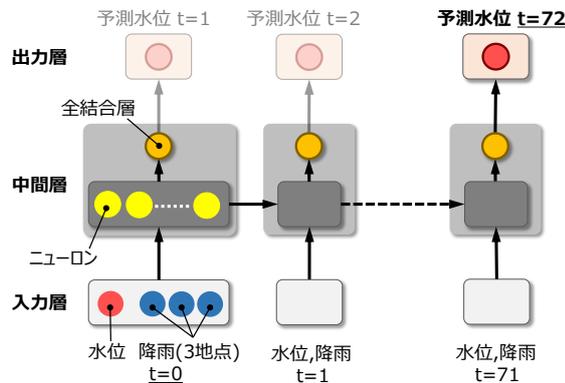


図1 本検討でのRNNモデル概念図

(1) 学習方法

予測モデルが様々な降雨パターンに対応できるようにするため、学習には72時間分の水位と降雨(3地点)

を1バッチサイズとした入力データを準備し、1時間先の水位の予測誤差を最小化するように学習を行った。

(2) 河川水位の予測方法

学習したモデルを用いて、予測開始前の72時間分の水位と降雨データをインプットデータとし、以後は降雨データのみ実測値を使用し、水位には予測値を繰り返し入力することにより10日先までの河川水位を予測する。

- ① 予測開始時の降雨データから1時間先の河川水位(WL①)を予測
- ② 1時間後の予測水位WL①と1時間後の降雨データから2時間後の水位を予測(WL②)
: [②を繰り返し]
- ③ 239時間後の予測水位と239時間後の降雨データから240時間後の水位を予測

(3) 検証方法

精度検証には10日間の毎正時の予測と実測水位の平均平方二乗誤差RMSE、予測と実測の最高水位の最大誤差の2項目を採用した。

3. 検討対象

遠賀川水系の水位観測所「川島」から上流域(約295km²)を対象とし、流域内の3つの雨量観測所(大隈、内野、飯塚)のデータを使用する(図2参照)。本検討では、比較的ダムの影響が少ないと想定される地点を選定した。

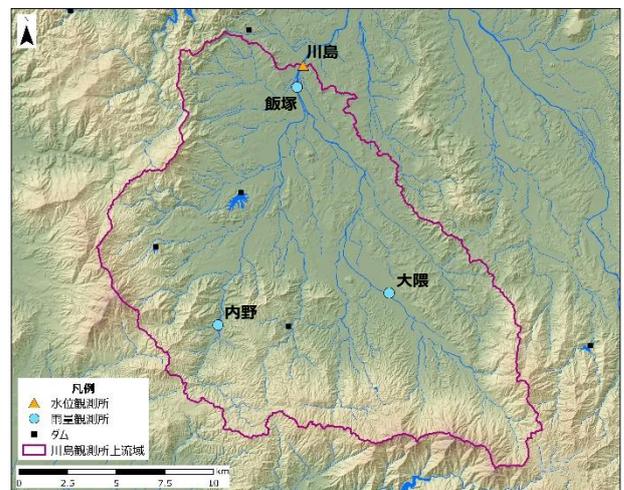


図2 検討対象流域

キーワード 深層学習, AI, リカレントニューラルネットワーク, 水位予測

連絡先 〒810-0004 福岡県福岡市中央区渡辺通1-1-1 西日本技術開発(株)施設開発部 TEL 092-781-2890

4. 検討ケース

学習には2008年～2017年の10年間の観測データをトレーニングデータとして使用し、その全データを対象とする場合と出水期（6月～10月）のみを対象とした2ケースで予測モデルを学習させ、2018年7月の出水時の13日間をテストデータとして予測精度の検証を行った。これらの期間における川島地点と大隈地点の水位と降雨の観測結果を図3に示すが、予測検証に使用する2018年の水位は学習期間中の最高水位よりも高い水位である。

検討ケースとしては、学習に使用するデータの影響とRNNのセルやハイパーパラメータの影響の把握を目的に表1のとおりとした。

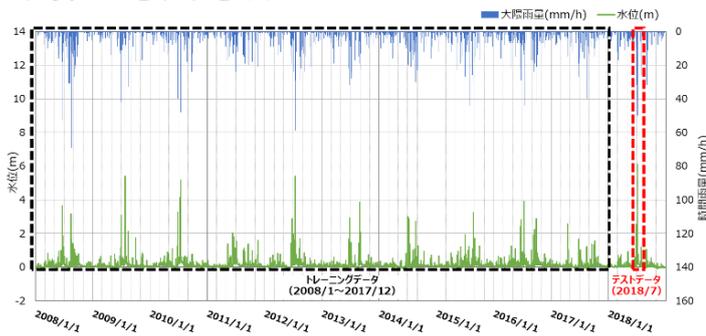


図3 対象とする河川水位(川島)と降雨(大隈)データ

表1 予測モデルの検討ケース

| セル | ニューロン数 | 学習データ |
|---|------------|-----------------------|
| BasicRNN | 10, 30, 50 | ・全期間 ・出水期のみ(6～12月) |
| LSTM | | |
| GRU | | |
| 【ハイパーパラメータ】 ・活性化関数: ReLU ・最適化関数: Adam ・バッチサイズ: 500～1,500 ・エポック数: MSE監視による自動停止 【学習データ】: 2008～2017年 (約87,000データ) | | |

5. 予測精度検証結果

検討ケース別にテストデータで実施したRMSEによる精度検証結果を図4に示す。ニューロン数に着目すると30,50の方が10よりも精度は良好である。また、水位変動を含む教師データの割合が多い出水期のデータで学習した方がRMSEは小さい傾向にある。LSTM及びGRUセルについてはRMSEが大きい傾向にあるが、これは重

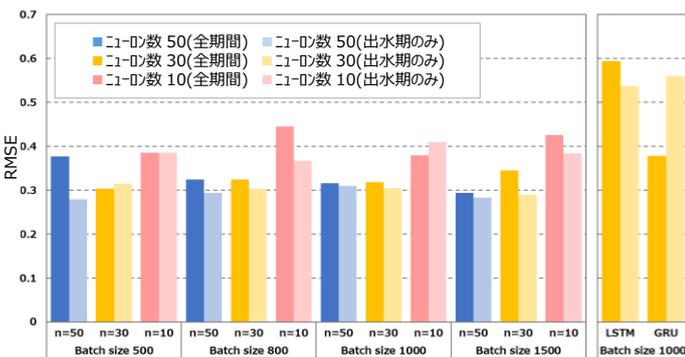


図4 BasicRNNの精度検証結果 (参考: LSTM, GRU)

み等が多く複雑なセルでは学習の度に得られるモデル精度のばらつきが大きいことによると推察され、良好に学習されたモデルではRMSEは小さい。

BasicRNNとLSTMの水位予測結果を図5に示すが、10日先までの水位変動を良好に再現している。最高水位の誤差についてはBasicRNNのケースで30cm程度である。LSTMセルのケースでは最高水位に加え水位低下の過程も良好に再現できている。

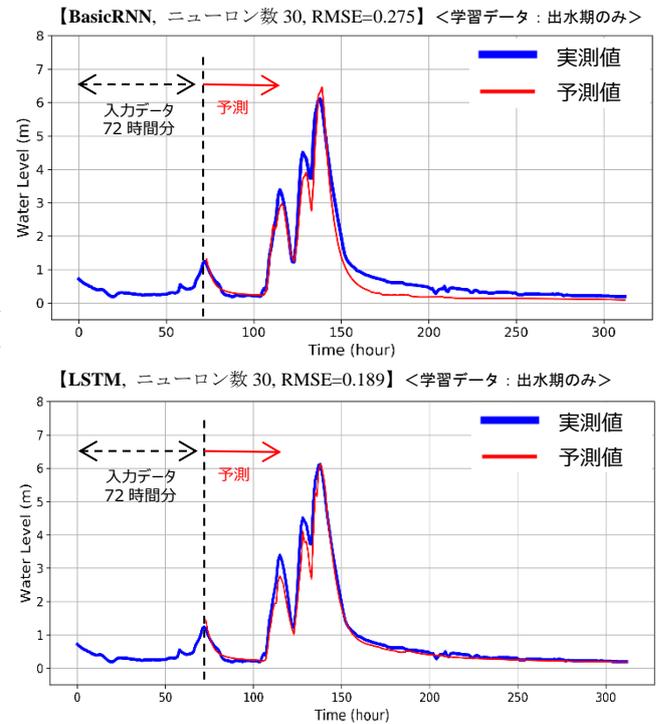


図5 水位予測結果(テストデータ)

6. まとめ

3地点の雨量観測所のデータからその下流の河川水位をRNNにより予測するモデルを学習した結果、出水時に10日先までの水位変動を良好に再現し、河川水位予測の適用性を確認した。RNNの通常セルの精度についてはLSTMに比べ多少劣る程度であった。モデルでは過去72時間の影響を考慮しているが、72ステップ程度の期間の依存性であれば通常のRNNでも十分に予測可能であることが示された。ハイパーパラメータは予測結果に影響を与えており、これらの最適化の重要性を確認した。

今後は学習の試行回数や検証データを増やしてモデルの信頼性を確認するとともに、ダム運用に資するダム流入量やダム水位の予測モデルの構築を進めるなど、予測技術の高度化を図る予定である。

参考文献

- 1) S.Hochreiter, and J.Schmidhuber : Long short-term memory. Neural Computation, 9(8), pp.1735-1780, 1997.
- 2) K.Cho, B.Merriënboer, C.Gulcehre, F.Bougares, H.Schwenk, and Y.Bengio: Learning phrase representations using run encoder-decoder for statistical machine translation, Proceedings of the Empirical Methods in Natural Language Processing (EMNLP2014), 2014