

再帰型ニューラルネットワークによる 観測雨量を用いた水位予測の検討 ～山口県厚東川流域を対象として～

福丸大智*・赤松良久**・新谷哲也***・藤井晴香**

*山口大学工学部社会建設工学科

山口大学大学院創成科学研究科, *東京都立大学都市基盤環境学科

1. はじめに

近年の我が国において、平成 27 年 9 月関東・東北豪雨、平成 29 年の九州北部豪雨、平成 30 年 7 月豪雨、令和 2 年 7 月豪雨などと大規模な豪雨災害が多発しており、それに伴った洪水災害も増大している。また、そのような洪水災害による甚大な被害は一級河川の支流や、都道府県管理の二級河川などの中小河川であることが多い。さらには、そのような中小河川では降雨から流出までの応答時間が相対的に短くなっており避難時の逃げ遅れのリスクは増大する。逃げ遅れによる人的被害をなくすためのソフト的対策の 1 つとして、即時的かつ高精度な河川水位予測が必要不可欠である。

本研究で用いた深層学習による河川水位予測手法は、従来広く用いられている物理型モデルのように多様な入力データや複雑なキャリブレーションを有していないのが特徴であり、国内河川への適用事例もいくつか報告されている¹⁾²⁾。しかしながら、そのほとんどは流域面積が大きく、水文観測データが充実している一級河川への適用事例である。また、予測時の入力において観測水位を必要とする場合が多いため、ただでさえ観測網が貧弱な中小河川で水位計の故障などによりリアルタイムの水位観測が断たれた場合、水位予測は難しい。したがって、予測時の入力で降雨情報のみの入力により、即時的に河川水位を予測する手法があれば、中小河川における逃げ遅れのリスク軽減につながることを考えられる。そこで、本研究ではリアルタイムの降雨情報に基づいて、流域内多地点で河川水位を即時的かつ高精度で予測することを目的として、近年大きな注目を集めている深層学習を用いて、実測降雨のみの入力で将来水位を出力するモデルを構築し、山口県二級水系の多地点水位観測所に適用してその実用性に関して検討した。

2. 水位予測モデルの概要

本研究では、時系列の関連性の学習能力が高い深層ニューラルネットワークの 1 つである再帰型ニューラルネットワーク(Recurrent Neural Network : RNN)を用いた。RNN を用いることで、時系列データである降雨と水位の関係性をより高度に学習することが期待される。ネットワークの構成は、入力層・2 層の中間層・出力層から構成されるが、通常の RNN を用いた場合に学習時に誤差関数の勾配が損失する勾配損失問題や、それによって長時間の時系列の情報が損なわれる短期記憶問題が懸念される。そこで、勾配が長期間伝達される経路を作るために自己ループを導入するような長短期記憶(Long Short-Term Memory : LSTM)³⁾ブロックを中間層に適用した。LSTM ブロックの基本構造は記憶素子に加えて、入力データの制御をする入力ゲート、不要な情報を忘却する忘却ゲート、出力データの制御をする出力ゲートの 3 つのゲートで構成されている。ここで、水位予測モデルの詳細な設定については、入力層には過去 72 時間から現在までにおける多地点の実測雨量を、出力層には 1 時間先の流域内多地点における将来水位を出力する設定とした。

3. 対象河川と検討方法

3.1 対象河川

本研究で対象としたのは、山口県二級河川の厚東川流域とした(図-3)。本川厚東川は山口県美祢市秋芳町を源に発し、宇部市大字に位置している厚東ダムにおいて支川大田川と合流したのちに宇部市の市街地に流下する流域面積約 405[km²]、幹川路延長 59.9[km]の二級河川である。流域内には雨量観測所が 9 地点、水位観測所が 7 地点設置されている。なお、再現計算は潮汐の影響、欠測が多数存在しないことを考慮して信高橋、綾木、岩永、木田橋の 4 地点を対象とし、以降、上流から Koto0~Koto3 と記す。

3.2 検討方法

検討には、厚東川流域における 2006 年から 2019 年までの実測雨量・水位データを使用した。雨量データは 1 時間雨量[mm/hr]、水位データは 1 時間ごとの観測水位[cm]を使用した。欠測に関して、雨量は周辺の最近隣の観測所の同時系列における雨量から空間補間した。水位に関しては周辺時系列における水位から時間補間した。なお、欠測の多かった真長田雨量観測所は検討の対象から除いた。また、学習の際に雨量・水位のデータのスケール間で大きな偏りがある場合にスケールの違いが学習に悪影響を及ぼすことが考えられる。そこで、雨量・水位の各データを平均値 0、標準偏差 1 となるように標準化処理を施すことで各データ間スケールの偏りを軽減した。

表-1 に再現計算の各種設定を示す。本検討は、過去の雨量と水位の関係性を学習するための学習期間とそれをもとに推論を行う検証期間に分けた。また、深層学習には学習を行う上でハイパーパラメータを設定する必要がある。ハイパーパラメータのバッチサイズ、エポック数、中間層のノード数は試行錯誤により決定した。また、本検討では学習時にノードを一定確率 p で無効化して強制的に自由度を下げることで過学習を抑制するドロップアウト⁴⁾を適用している。ドロップアウトを用いることで学習時の不要な入力情報を削減しつつ学習の表現力を高めることを目指した。 p については一般的に広く用いられる値である 0.5 を採用した。



図-1 厚東川流域

表-1 再現計算の各種設定

	各値
学習データ期間	2006~2017
再現計算期間	2018/1/4 0:00~2019/1/1 0:00
p	0.5
バッチサイズ	512
エポック数	150
中間層のノード数	400

4. 結果

4.1 再現計算の結果

図-2 に検証期間における LSTM モデルによる再現計算の結果を示す。再現計算の結果から、全体的な傾向としてハイドログラフの立ち上がりは概ね再現できているが、出水時のピーク水位の再現性が低い傾向が確認された。また、平水時の水位に着目すると、計算値がある一定値以下の値を示さず、閾値があるような結果を示していることが分かる。さらに詳細に見ていくと、立ち上がり時に関しては良好な再現性を示しているにもかかわらず、通減時の再現性が不十分であった。

図-3 に示す散布図を用いて、さらに詳細な傾向について述べる。散布を見ると、ここでも出水時の再現性が不十分であり、具体的には過小評価傾向を示していることが確認された。また、全地点で平水時の 1:1 直線に対する散布が相対的に大きなばらつきを示していることが確認された。平水時の散布が大きければついては、出水時に比べて平水時の頻度が多いことも関係するが、先述した通減時において再現性が不十分であることが大きく関係している。

4.2 出水時における再現性の評価

図-4 に、平成 30 年 7 月豪雨の期間である 2018 年 6 月 28 日 0 時から 7 月 14 日 0 時までにおける再現計算の結果を示す。なお、図中には水防団待機水位(緑色破線)と氾濫注意水位(黄色破線)も示している。この結果から、全体として立ち上がりのタイミングは良好に捉えられていることが分かる。しかしながら、4.1 節でも述べたように、通減時の再現性が不十分であり、具体的には過小評価していることが明らかになった。また、ピーク水位について Koto2 で若干の過小評価傾向がみられるものの、Koto1 および Koto2 は概ね再現している。それ

に対して、特に Koto0 および Koto3 が過小評価しており、具体的には実測水位が氾濫注意水位以上を記録するような場合を境に実測値を捉えきれなかった。このように、出水時のハイドログラフを調べることで地点によってその予測精度はばらつきがあることが明らかになった。これは、過去に観測さ

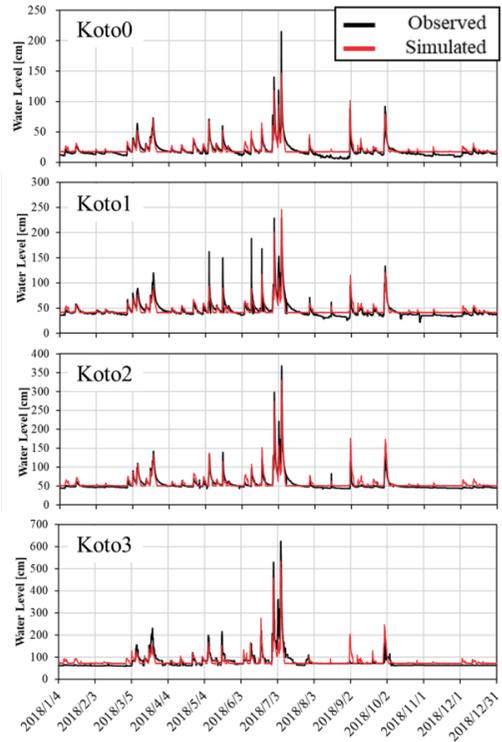


図-2 再現計算の結果

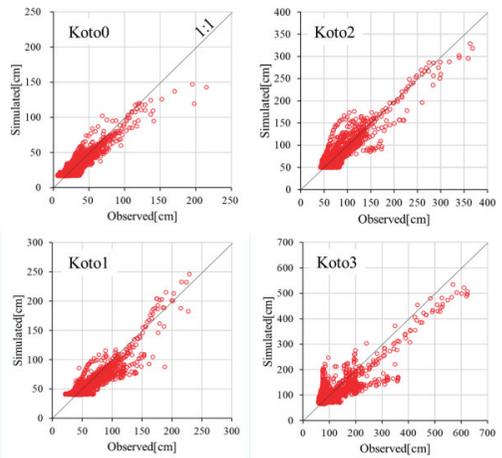


図-3 散布図による比較(2018/1/4~2018/12/31)

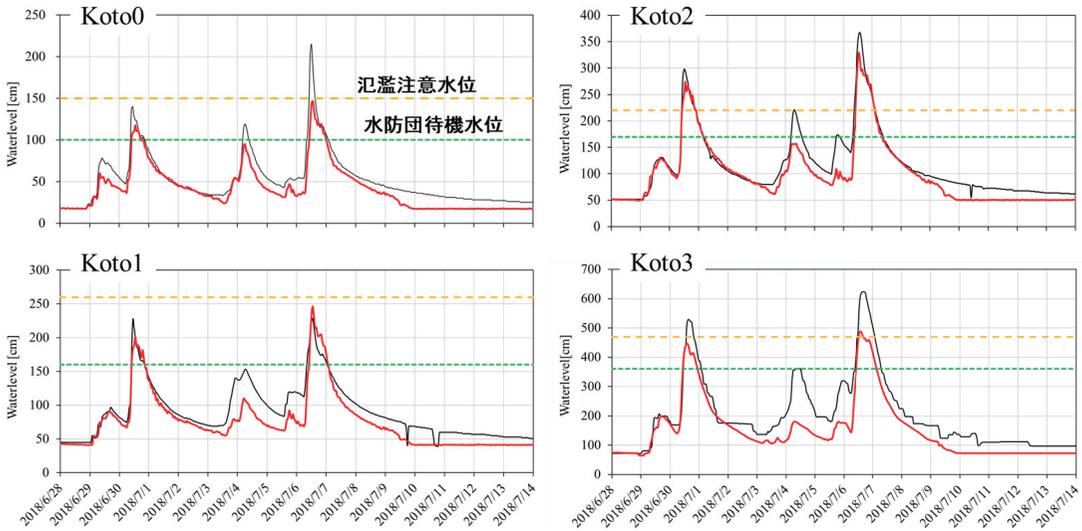


図-4 平成30年7月豪雨期間の再現結果

れた降雨のみを入力層に配置して水位との関係性を学習しているような本モデルにおいて、降雨情報のみでは流域内多地点における水位の急激な変化を学習できなかったことが要因の1つであることが考えられる。

5. まとめ

本研究では、再帰型ニューラルネットワークを用いて観測雨量の情報に基づく河川水位予測モデルを構築し、厚東川流域内多地点の水位観測所の水位を同時に予測した。検証期間の約1年間で評価した結果、水位の立ち上がりは良好にとらえているものの特に逡減部分や出水時の水位の再現性が不十分であった。そこで、平成30年7月豪雨に着目すると、主に氾濫注意水位以上を記録するような場合に実測値を捉えきれなかった水位観測所が確認され、モデルの予測精度は水位観測所ごとにばらつきがあることが明らかになり、降雨情報のみでは流域内多地点の水位観測所における水位の急激な変化を学習できなかった可能性が示された。以上より、本研究の目的である流域内多地点の河川水位を即時かつ高精度で予測することは現時点では難しく、今後さらなる検討やモデルの改善が必要である。

6. 参考文献

- 1) 一言正之, 櫻庭雅明, 清雄一: 深層学習を用いた河川水位予測手法の開発, 土木学会論文集 B1(水工学), Vol.72, No.4, I_187-I_192, 2016
- 2) 山田恒輝, 小林洋介, 中津川誠, 岸上順一: リカレントニューラルネットワークを用いた2016年の常呂川洪水事例の水位予測
- 3) Hochreiter, S. and Schmidhuber, J.: Long Short-Term Memory, *Neural Computation*, Vol.9, No.8, pp.1735-1780, 1997
- 4) Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov: Dropout: A Simple way to Prevent Neural Networks from Overfitting, *Journal on Machine Learning* 15 (2014) 1929-1958