

深層学習による中小河川を対象とした河川水位予測手法に関する検討

長岡工業高等専門学校 学生会員 ○武樋 力
長岡工業高等専門学校 正会員 込山晃市
長岡工業高等専門学校 正会員 山本隆広

1. はじめに

近年、地球温暖化の影響による集中豪雨の頻度増加や台風の巨大化等により、洪水被害が多発しているため、洪水予測情報の重要性が増している。洪水予測は降雨流出過程を考慮した物理的モデルにより行われていることが多いが、河川の横断面形状等に関する河道情報があまり整備されていない中小河川では精度の良い予測が困難である。一方で、物理過程などの複雑な計算過程をブラックボックス化し、入出力要素の関係のみに依存する深層学習等のニューラルネットワークを用いた洪水予測では、物理的モデルよりも高い精度を示した報告りもあるが中小河川に適用した事例は少ない。そのため、深層学習を用いて中小河川の洪水予測を行うことができれば、洪水被害の軽減のための有益な情報となる。一方で、新潟県は水位観測所の普及が進んでおり、従来型水位計については1996年よりデータの蓄積がされている。最近では、洪水時の観測に特化した危機管理型水位計の設置も進められている。また、ニューラルネットワークを用いた河川水位予測モデルの中には複数地点の水位を同時に予測する手法²⁾も提案されており、本研究で対象とする洪水到達時間が短い中小河川において、その手法を適用することは河川全体の被害危険度を把握する上で有意義であると考えられる。そこで、本研究では、今後、蓄積される危機管理型水位計のデータの活用を前提に、新潟県において豊富に存在する従来型水位計のデータを用いて、中小河川を対象に深層学習による河川水位予測モデルの開発を行うとともに、複数地点の水位を同時に予測するモデルについても検討する。

2. 対象河川と使用データ

対象河川は、新潟県内を流れる中小河川で、過去に大規模な水害が発生した刈谷田川であり、流域面積は約239.8 km²である。使用データは新潟県が管理する従来型水位計の水位および気象庁の AMeDAS 観測所の降水であり、欠測値や明らかな異常値については前後の時間の観測値を用いて一次線形補完した。図-1 に刈谷田川流域と水位観測所および AMeDAS 観測所の位置を示した。図中の▽印は水位観測所を、○印は AMeDAS 観測所を示している。また、図中の赤▼印で示す地点の水位観測所は氾濫危険水位が指定されている地点であるとともに、本研究における予測対象地点である。取得したデータの期間は2014年1月1日 0:00 から2017年12月31日 23:50 であり、各データともに10分間値を用いた。また、2014年1月1日 0:00 から2016年12月31日 23:50 (157825 個)までを学習用データセット、2017年1月1日 0:00 から2017年12月31日 23:50 (52560 個)を検証用データセットとして利用した。

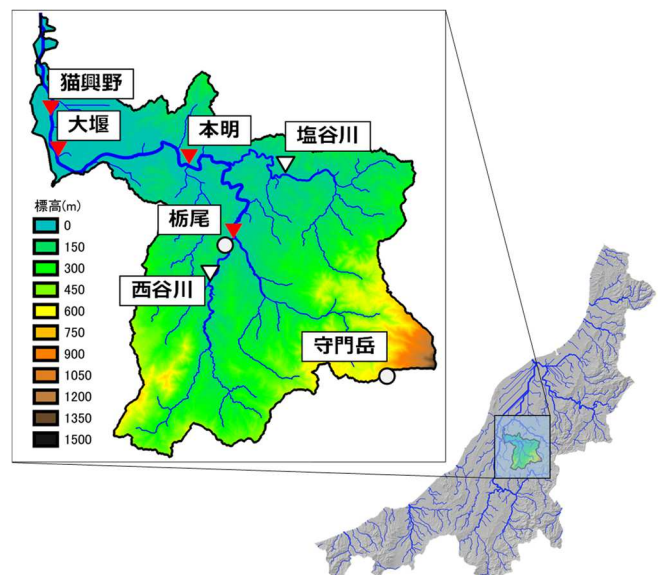


図-1 刈谷田川流域の概略図と水位観測所および AMeDAS 観測所。▽印は水位観測所、○印は AMeDAS 観測所、赤▼印は氾濫危険水位が指定される水位観測所で予測対象地点を示す。

表-1 モデルの入出力要素

要素	入力	出力
詳細	図-1 に示す猫興野, 大堰, 本明, 栃尾, 塩谷川, 西谷川の 6 地点の水位観測所の水位と栃尾, 守門岳の 2 地点の AMeDAS 観測所の降水の過去 6 時間分の時系列データ	図-1 に示す猫興野, 大堰, 本明, 栃尾の 4 地点の水位観測所の 6 時間先まで予測水位

3. 解析手法

(1) 入出力要素

国土基盤情報ダウンロードサービスが提供している 10 m メッシュの数値標高モデルと QGIS を用いて, Kirpich 方程式により流出時間と河道の流下時間の和を計算した. その結果, 刈谷田川流域の最上流から最下流までの流出時間と河道の流下時間の和は約 312 分であった. そのため, その情報をもとに本研究では, 水位予測モデルへの入出力要素を表-1 に示すように設定とした. また, 学習データが偏りを含む場合, 学習の効果が低下してしまうため本研究では, 学習計算の実施前にデータの最大値を 1, 最小値を -1 とする正規化を行い, データによって異なるスケールを統一した.

(2) 深層学習モデルの構築

モデルは入力層, 中間層, 出力層によって構成され, 複数の中間層を用いた手法を深層学習という. モデルの構築には, 機械学習に用いるためのソフトウェアライブラリである TensorFlow と, Python で書かれた TensorFlow 上で実行可能な高水準のニューラルネットワークライブラリである Keras を用いた. 構築したモデルについては, 既往の研究で水位予測において適用性が確認されている全結合ニューラルネットワーク(これ以降, Dense と言う.)によって構成され, 非線形的な連続関数を近似することが可能である人工ニューラルネットワーク(Artificial Neural Network, これ以降, ANN と言う.)モデルと時系列情報を処理することを考慮した ANN の再起型ニューラルネットワークのアーキテクチャの 1 つである長短期記憶(Long Short-Term Memory, これ以降, LSTM と言う.)を用いた. モデルの詳細は表-2 に示す通りであり, 複数のモデルを構築し, 予測結果の比較を行った. また, 入力層を個別とするモデルについては, 観測所ごとに計算を行うことで各地点の水位や降水の時間的変化をより学習に反映させるためである. また, 出力層については各予測対象地点の 6 時間先までの予測結果が 10 分間隔に一度に出力されるような設定とした.

表-2 モデルの詳細

Num.	Model Name	入力層		中間層(1層)		中間層(2層)		出力層
		複数	個別	Dense	LSTM	Dense	LSTM	
1	ANN	○	—	○	—	—	—	各水位観測所の 6 時間先までの 予測値 (10 分間隔)
2	ANN(2layer)	○	—	○	—	○	—	
3	LSTM	○	—	—	○	—	—	
4	LSTM(2layer)	○	—	—	○	—	○	
5	LSTM-ANN	○	—	—	○	○	—	
6	ANN(Ind-2layer)	—	○	○	—	○	—	
7	LSTM(Ind-2layer)	—	○	—	○	—	○	
8	LSTM-ANN(Ind)	—	○	—	○	○	—	

※表中の Ind は入力層が個別であること, 2layer は中間層が 2 層であることを示す.

(3) モデルの最適化

表-3 学習時の各種設定

種別	設定
学習	ミニバッチ最急降下法
Bach Size	4096
epoch 数	Early Stopping (100 epoch)
損失関数	平均二乗誤差
学習係数	Adam
中間層	1層(108) [ANN / LSTM] 2層(108-54)[複数 ANN / LSTM] (18-54) [個別 ANN / LSTM]

表-3 に学習の際のモデルの設定を示した。中間層のニューロン数を除くパラメータについては、全てのモデルで共通のパラメータを設定した。学習はミニバッチ勾配降下法により行った。ミニバッチ勾配降下法は、バッチ勾配降下法と確率的勾配降下法の間をとった手法であり、全学習サンプルから少数のサンプルの集合(ミニバッチ)をひとまとめにし、その単位で重みを更新する手法である。ミニバッチのサイズについては4096とした。epoch 数は学習の繰り返し回数の中で、過学習を抑制するために Early Stopping 法を用いて学習条件毎に異なる epoch 数で学習を行った。Early Stopping 法は損失が増加し始めたとき、

つまり、学習後の改善が設定したエポック数で見られなくなった段階で学習を打ち切る手法である。損失関数は予測精度を評価する指標で、回帰問題において広く適用されている平均二乗誤差を用いた。また、勾配降下法ではパラメータの更新量の大きさは学習係数によって変わり、この学習係数をどう決めるかは学習の成否を左右するため極めて重要である。本研究ではニューラルネットワークの学習でよく用いられる Adam とした。

4. 結果と考察

(1) 検証期間全体の予測結果

観測値と予測結果の精度評価は二乗平均平方根誤差(Root Mean Squared Error, これ以降、RMSE と言う。)と Nash 効率係数を用いた。RMSE は観測値と予測結果が一致するほど 0 に近づき、Nash 効率係数は 0.8 以上であれば観測値と予測結果の波形の再現性が良好であるとされる。図-2 に検証期間全体での各モデルの予測結果の全予測対象地点平均 RMSE および Nash 効率係数の 6 時間先までの時間的推移を示した。図より各モデルによる予測結果を比較すると ANN では、予測結果の精度がタイムステップに関係なくばらつく傾向にあったが、LSTM を用いたモデルでは 時系列情報を考慮する学習が行えることにより検証期間全体で 6 時間先までの水位を良好に予測することができた。一方で、本研究では入力層を観測所ごとに個別にし、入力することによる予測精度の向上は確認されなかった。ただし、本稿では次節において予測対象地点平均 RMSE および Nash 効率係数で最も良好な精度を示した LSTM-ANN モデルの氾濫注意水位を超えた期間の予測結果を示した。

(2) 氾濫注意水位を超えた期間の予測結果

2017 年 7 月 3 日に本明地点にて氾濫注意水位 24.39 m を超える水位が観測された。そのため、図-3 にそのイベントのピーク水位から前後 12 時間を対象に各予測対象地点で 6 時間先までの RMSE と Nash 効率係数を算出した結果を示した。図より予測対象地点の RMSE と Nash 効率係数を比較すると、6 時間先までの水位を通年で予測する深層学習モデルであっても 2 時間程度の比較的短時間であれば氾濫の危険度が高まっている




図-2 検証期間全体での各モデルの予測結果の全予測対象地点平均 RMSE(左), Nash 効率係数(右)の 6 時間先までの時間的推移




図-3 氾濫注意水位を超えた期間の各予測対象地点の RMSE(左), Nash 効率係数(右)の 6 時間先までの時間的推移

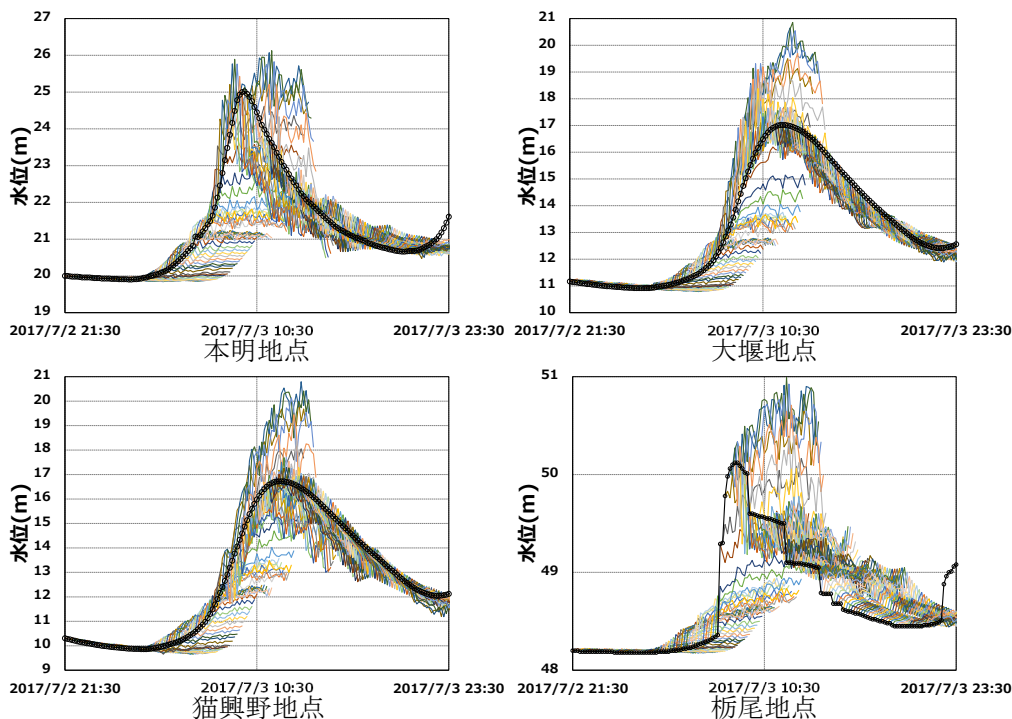


図-4 氾濫注意水位を超えた期間の各予測対象地点の 6 時間先までの予測結果

期間の水位を良好に予測することが可能であると示唆された。図-4 に氾濫注意水位を超えた期間の各予測対象地点の 6 時間先までの水位の予測結果を示した。結果より、同一のモデルからの予測であっても地点によって予測結果の挙動が異なることが確認できる。これは予測対象地点よりも上流域側に水位観測所が存在するかどうかによる影響も考えられるが、本研究でモデルが各予測対象地点の 10 分先から 360 分先を一度に出力するような設定としているために、学習時の計算によるバイアスのかけ方の違いで予測精度や挙動に差が出たと考えられる。そのため、モデルの初期値を変化させた際の予測結果の違いを検証する必要がある。

5. まとめ

本研究では、従来型水位計の水位データと AMeDAS 観測所の降水データを用いて刈谷田川を対象に 6 時間先までの水位を通年で予測する深層学習モデルを開発した。モデルに関しては LSTM を用いた場合に予測精度が良好となることが確認された。また、氾濫の危険性がある期間であっても 2 時間程度の短時間であれば比較的良好的な精度で予測が行えることが示唆された。今後は、蓄積される危機管理型水位計のデータの活用を前提により氾濫の危険性がある期間に着目した水位予測モデルの開発を行いたいと考える。

参考文献

- 1) 一言ら：深層学習を用いた河川水位予測法の開発，土木学会論文集 B1(水工学)，Vol.72，No.4，pp.I_187-I_192，2016。
- 2) 山田ら：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，土木学会論文集 B1(水工学)，Vol.74，No.5，pp.I_1369-I_1374，2018。