

人工知能技術の河川ハイドログラフ予測への適用に関する研究

水圏防災工学研究室
指導教員

森山 諒
細山田 得三

1 序論

近年日本では台風や大雨によって洪水や土砂による災害が多発している。これらの災害に対して、日本において堤防やダム等の対策設備が整備されている。しかしながら、いずれの設備にも能力の限界があり、能力の限界を超える災害が起こった際は迅速に避難をしなければならない。そのためには避難情報をいち早く入手し、避難指示に従わなければならない。¹⁾

また、より正確な予測をするためには河川の形状や細かい地形変化に対応するために、これらのデータの更新が必要となってくる。そこで本研究では、近年水工分野でも、災害予測、予測降雨の修正、水質予測、気象データの高度化、風速の短時間予測、画像による植生判別、ダム操作の効率化等に利用されており、さかんになりつつある AI (Artificial Intelligence) 技術に着目し、細かいパラメータ等の調整が不要で予測をすることができる AI を用いて信濃川流域における長岡、渡部の流量の予測を行った。

2 収集したデータ

本研究では、長岡および渡部の流量を予測するにあたり、国土交通省の信濃川河川事務所から拝借した信濃川流域の流量・水位データを収集した。収集した地点は、図-1に示す渡部、長岡、小千谷、十日町、宮野原の5地点である。期間は2017年1月1日から2018年12月31日までの2年間の1時間ごとの時系列データである。長岡の期間については前述の2年間に加え、1987年1月1日から2019年12月31日までの合計32年間分のデータを収集した。流量観測データは、国土交通省北陸地方整備局信濃川河川事務所によって計測されたものを借用した。実際には流量の値は毎正時の水位データを水位流量曲線によって流量に変換されたものである。また、予測結果を比較する際に2018年の代表的な融雪(2018年4月2日~4月9日)、梅雨(2018年7月5日~7



図-1 水位・流量データを収集した地点

月9日)、台風(2018年10月1日~10月5日)の期間を対象として、比較を行った。

3 予測の手法

3.1 LSTM

時系列データを扱うため、隠れ層の値を再び隠れ層に入力するという構造にしたニューラルネットワークをRNN (Recurrent Neural Network) と呼ぶ。しかしながらRNNは長時間前のデータを利用しようとすると、誤差の消滅や、演算量が爆発するなどの問題があり、短時間のデータの処理のみに対応していた。これらの問題点を3つのゲートを加えることによって解消し、長期間の時系列データを学習できるようにしたモデルをLSTM (Long Short-Term Memory) と呼ぶ。本研究ではLSTMを用いて予測をするにあたって検討すべき切り出す期間を2日間(48時間)、3日間(72時間)、1週間(168時間)、2週間(336時間)、1か月(7200時間)の5期間で比較を行い、続いて学習期間の検討を10年間、20年間、30年間の3期間で比較を行った。これらの結果から後述の粒子フィルタでの予測結果との性能の比較も行った。

表-3 切り出す期間の検討の比較 (平均二乗平方根誤差)

	全期間 (m/s ²)		融雪 (m/s ²)		梅雨 (m/s ²)		台風 (m/s ²)	
	1時間後	12時間後	1時間後	12時間後	1時間後	12時間後	1時間後	12時間後
2日間	57.66	150.4	80.23	189.7	119.9	463.0	204.3	636.6
3日間	54.78	151.5	73.34	172.6	106.1	482.9	154.1	479.7
1週間	56.05	160.2	83.13	182.6	106.9	469.1	205.9	668.2
2週間	62.49	173.1	79.28	198.8	117.5	526.7	215.7	706.1
1か月	70.17	175.2	85.82	221.7	138.6	429.5	230.9	595.8

表-2 学習期間の検討の比較 (平均二乗平方根誤差)

	全期間 (m/s ²)		融雪 (m/s ²)		梅雨 (m/s ²)		台風 (m/s ²)	
	1時間後	12時間後	1時間後	12時間後	1時間後	12時間後	1時間後	12時間後
1年間	54.78	151.5	73.34	172.6	108.1	482.9	154.1	479.7
10年間	54.29	146.5	76.45	171.5	117.9	477.9	152.8	441.0
20年間	53.10	143.7	71.38	175.6	100.3	450.6	143.7	411.1
30年間	63.59	150.4	95.27	180.6	135.7	491.2	182.3	439.8

表-1 粒子フィルタと LSTM の比較 (平均二乗平方根誤差)

	全期間 (m/s ²)		融雪 (m/s ²)		梅雨 (m/s ²)		台風 (m/s ²)	
	1時間後	12時間後	1時間後	12時間後	1時間後	12時間後	1時間後	12時間後
LSTM (20年間)	54.78	151.5	73.34	172.6	108.1	482.9	154.1	479.7
粒子フィルタ	60.15	165.8	93.31	210.6	122.5	498.3	201.3	619.5

3.2 粒子フィルタ

粒子フィルタは、非線形・非ガウス型のあらゆる一般状態空間モデルに対する逐次解法である。本研究ではタンクモデル等に適用せず、流量に対してフィルタリングを行うことによって時系列的に予測を行った。最終的に粒子フィルタによる予測結果を LSTM の予測結果との比較を行った。

4 予測結果

本研究では、結果の比較をそれぞれの結果の平均二乗誤差と平均二乗平方根誤差で行った。

4.1 切り出す期間の検討

切り出す期間の比較を行った結果を表-1 で示す。5 期間のうち最も誤差の少なかった予測結果を黄色で示している。最も精度の良かった切り出す期間 2 日間の融雪期間の 12 時間先までの 3 時間ごとの予測を行った図を図-2 で示す。これらの結果から、最も精度の良かった切り出す期間は 3 日間であることが分かった。

4.2 学習期間の検討

切り出す期間の検討結果と同様、学習期間の比較を行った結果を表-2 で示す。3 期間のうち最も誤差の少なかった予測結果を黄色で示している。また、同様に最も精度の良かった学習期間 20 年間の融雪期間の 12 時間先までの 3 時間ごとの予測を行った図を図-3 で示す。これらの結果から、最も精度の良かった学習期間は 20 年間であることが分かった。

4.3 粒子フィルタとの比較

同様に、粒子フィルタの予測結果と LSTM の切り




図-2 切り出す期間 3 日の融雪期間の予測結果




図-3 学習期間 20 年間の融雪期間の予測結果




図-4 粒子フィルタの予測結果

出す期間 3 日、学習期間 20 年での予測結果の比較した結果を表-3 で示す。2 つのうち誤差の少ない方を黄色で示している。粒子フィルタでの融雪期間の 12 時間先までの 3 時間ごとの予測を行った図を図-4 で示す。これらの結果から、LSTM の予測結果のほうが誤差が少ないということが分かった。

5 結論

本研究では次の結論が得られた。

- 切り出す期間は 3 日が最も誤差が少ない
- 学習期間は 20 年が最も誤差が少ない
- 粒子フィルタと LSTM を比較すると、LSTM のほうが誤差が少ない

参考文献

- 1) 吉田均, 野村泰稔, 広兼道幸, 一言正之, 小田和広, 秋山孝正, 宇津木真司: AI のインフラ分野への応用, 電気書院, pp63-81, 2019.