

リカレントニューラルネットワークによる 常呂川・上川沿地点を対象とした河川の水位予測

Water Level Prediction using Recurrent Neural Network at Kamikawazoi on Tokoro River

室蘭工業大学 ○学生員 山田 恒輝 (Koki Yamada)
室蘭工業大学 非会員 小林 洋介 (Yosuke Kobayashi)
室蘭工業大学 正 員 中津川 誠 (Makoto Nakatsugawa)
室蘭工業大学 非会員 岸上 順一 (Jay Kishigami)

1. はじめに

2016 年 8 月の北海道豪雨災害は、北海道東部を中心に、全道各地で記録的な大雨となり、道内各地で甚大な被害が発生した。特に、北海道東部の常呂川では、下流部の上川沿地点と太茶苗地点で、計画高水位を超過、観測史上最高水位を記録した¹⁾。このような災害時の防災・減災対策のためのソフト面の対策の一つとして、対策に当てられる時間である、LT(Lead Time)を十分に確保した、水位予測システムの構築が求められている²⁾。

現在、実際の業務に用いられている水位予測手法の貯留関数モデル³⁾は、最適なパラメータの設定が困難であり、予測の過程に変換誤差などが指摘されている⁴⁾。これらの問題点を解決するため、高度な統計モデルを作成する、機械学習技術を用いた河川の水位予測が提案されている^{5, 6, 7)}。しかし、これらで利用する学習アルゴリズムは時系列処理に適した構造となっていない。本研究では、時系列を考慮した学習が可能な、RNN(Recurrent Neural Network; リカレントニューラルネットワーク)による、水位予測を行った。

2. 水位予測へのリカレントニューラルネットワークの適用

RNN はニューラルネットワークの構成法の一つであり、一般的なニューラルネットワークを拡張し、時系列情報を扱える構造にしたものである。RNN を用いることで、並びに規則性やパターンのあるデータの時系列情報を適切にモデル化できる。水位相関法は上流と下流の水位に相関関係があることに着目している。これは複数地点の水位情報による規則性を持った情報の時系列データであり、RNN でモデル化することが可能である。

3. 予測性能評価実験

RNN を用いて 2015 年末までの約 18 年間の水位データを学習したモデルを作成し、2016 年の観測データによる水位予測を行い、性能評価を行う。

3.1 対象河川・対象地点

対象河川、予測地点は、岡崎らの検討⁷⁾と同様に北海道東部を流れる一級河川の常呂川と、その下流部の上川沿地点とした。図-1 に対象河川の概略図と水位観測所を示す。上川沿地点は 2016 年豪雨の際、計画高水位の 8.45 m を超える、観測史上最高水位の 8.88 m を観測した。



図-1 対象河川の概略図と水位観測所

表-1 評価実験の設定

トレーニングデータ	1998 年 1 月–2015 年 12 月
テストデータ	2016 年 1 月–2016 年 10 月
LT	6 時間, 12 時間
性能評価指標	RMSE

表-2 モデルの入出力要素

LT	入力
出力	
6 時間	図-1 に示す各観測地点
上川沿地点予測水位	6, 7, ..., 10 時間前観測水位
12 時間	図-1 に示す各観測地点
上川沿地点予測水位	12, 13, ..., 16 時間前観測水位

3.2 実験条件

表-1 に評価実験の設定、表-2 に RNN モデルの入出力要素を示す。本稿では、水位相関法と同様に計測水位を入力させ、予測水位を出力するモデルとした。水位データは、水文水質データベース⁸⁾より、1998 年 1 月–2016 年 12 月のデータのうち、学習データの最高水位を超える水位であっても、適切に予測可能であるか評価するため、閉局期間を除く、1998 年 1 月–2015 年 12 月を学習データとして、統計モデルを生成し、2016 年 1 月–10 月をモデル評価のテストデータとした。LT は、十分に長い、6 時間と 12 時間とし、水位予測モデルの予測性能の評価指標は、RMSE(Root Mean Squared Error; 平均二乗誤差平方根)を用いた。

キーワード 常呂川, 水位予測, リードタイム, Recurrent Neural Network, AI, 深層学習

連絡先 〒050-8585 北海道室蘭市水元町 27-1 TEL 0143-46-5440




図-2 実験結果 (2016 年 8 月 3 日-2016 年 9 月 14 日)

3.3 RNN の設定

本稿では、RNN の一つである、LSTM(Long Short-term Memory)⁹⁾を用いた。ネットワークの構成は、ノード数 30 の入力層、予備実験によりノード数を 1200~16 に決定した 7 層の隠れ層、1 ノードの出力層の全結合ネットワークで、隠れ層の活性化関数には ReLU、出力層では恒等関数を用いた。モデルの学習には、バッチサイズを 12 としてバッチ単位にパラメータを最適化した。最適化関数にはパラメータの勾配の 1 次、2 次モーメントから更新する Adam¹⁰⁾を用いた。学習回数であるエポック数は固定せず、Early Stopping を用いて損失関数の値が 5 エポック改善しなくなった時点で学習を打ち切った。

3.4 結果と考察

図-2 に、評価実験の結果のうち、高水位を記録した、2016 年豪雨の期間 (2016 年 8 月 3 日-9 月 14 日) の水位ハイドログラフを示す。図中の青色の破線は観測水位、橙線は LT が 6 時間の予測結果、緑線は LT が 12 時間の予測結果である。LT が 6 時間、12 時間のどちらも、水位の傾向を捉えている。しかし、観測水位のピーク時、予測水位は観測水位より低く、8 月 20 日 18 時の LT が 6 時間の結果は、8.49m と、学習データ中の最高水位である、8.48m をわずかに上回った程度であった。実際に計測された水位データによる RNN 統計モデルは、学習データ中の最高水位を超える水位についての予測精度向上が今後の課題である。

表-3 に、作成した統計モデルの RMSE を示す。表中の RNN は提案モデル、RF は岡崎ら⁷⁾の Random Forest 法による予測モデルの結果である。2016 年豪雨では、LT が 6 時間のとき、提案 RNN モデルの RMSE が 0.19m と最小になった。RF モデルでは、入力要素に水位、観測雨量、予測雨量、ダム放流量、水位差分を用いているが、提案 RNN モデルは水位のみであり、RF モデルの LT が 6 時間のときの 54 次元、12 時間のときの 60 次元と比較し、36 次元と少ない入力次元数でより RMSE が小さい予測結果が得られた。特に水位以外のデータを扱わないことは、災害時のネットワークトラブルに対してより頑健であり、有効である。

表-3 性能評価実験の結果 (RMSE)

LT	手法	テストデータの期間	
		2016 年 1 月-10 月	2016 年豪雨
6 時間	RNN	0.09 m	0.19 m
	RF ⁷⁾		0.44 m
12 時間	RNN	0.22 m	0.49 m
	RF ⁷⁾		1.04 m

4. まとめ

本稿では、常呂川を対象とし、上川沿地点を予測対象として、約 18 年間の水位データを学習させた RNN モデルによる、予測性能評価実験を行った。その結果は、2016 年豪雨期間に対し、LT が 6 時間のとき、RMSE は 0.19m、LT が 12 時間のとき、RMSE は 0.49m であった。LT が 6 時間、12 時間ともに、先行研究と比較して優れており、LT を考慮すれば、防災・減災上、十分な結果が得られた。本稿では、上流に水位観測所が 5 箇所ある上川沿地点で評価実験を行ったが、今後は上流部などでの予測精度について、評価する必要がある。

謝辞: 本研究を進めるにあたり、国土交通省北海道開発局網走開発建設部には洪水に関する資料の提供を頂いた。また、室蘭工業大学水環境システム研究室の岡崎亮太氏には資料の提供等、様々な協力を頂いた。本研究の一部はノーステック財団の助成を受けた。ここに記して謝意を表す。

参考文献

- 1) 土木学会・2016 年 8 月北海道豪雨災害調査団: 2016 年 8 月北海道豪雨災害調査団報告書, <http://committees.jsce.or.jp/report/node/144>, 2017.
- 2) 平成 28 年 8 月北海道大雨激甚災害を踏まえた水防災対策検討委員会: 平成 28 年 8 月北海道大雨激甚災害を踏まえた今後の水防災対策のあり方〜気候変動への適応により、命を守り国土の保全と発展へ〜, https://www.hkd.mlit.go.jp/ky/kn/kawa_kei/ud49g7000000f010.html, 2017.
- 3) 片山直樹 星清: 北海道開発局における洪水予測システムの比較検討, 土木学会第 61 回年次学術講演会講演概要集, No.2, pp.83-84, 2006.
- 4) 本永良樹, 銭潮潮, 山田正, 山坂昌成: 水位・通水能曲線 (hk 曲線) を利用した新しい流量算出手法, 土木学会論文集 B1 (水工学), Vol.68, No.4, pp.I.1357-I.1362, 2012.
- 5) 関基, 木村晃, 古山一志, 和田高宏, 金子祐, 穴水秀樹, 真間修一: 河川特性を反映したニューラルネットワーク洪水予測の精度向上, 河川技術論文集, Vol.19, pp.295-300, 2013.6.
- 6) 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, pp.I.187-I.192, 2016.
- 7) 岡崎亮太, 中津川誠, 小林洋介: ランダムフォレスト法による洪水時の水位予測手法の提案, 土木学会論文集 B1(水工学), Vol.74, No.4, pp.I.1459-I.1464.
- 8) 国土交通省: 水文水質データベース, <http://www1.river.go.jp/>.
- 9) Gers, F. A., Schmidhuber, J. A., and Cummins, F. A.: Learning to forget: Continual prediction with lstm, Neural Comput., Vol.12, No.10, pp.2451-2471, 2000.10.
- 10) Kingma, D. P. and Ba, J.: Adam: A method for stochastic optimization, 2014.