

常呂川を事例としたリカレントニューラルネットワークによる水位予測

Water Level Prediction using Recurrent Neural Network in the 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, 台風 7 号, 11 号, 9 号, 10 号の 4 つの台風及び前線が続々と北海道に上陸, 接近し, 大雨で道内各地に甚大な被害を与えた. 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, 計画高水位を超過し, 観測史上最高水位を記録した¹⁾. このような洪水による被害を軽減させるためには, 水防活動, 避難場所の開設や住民の避難等といった防災・減災対策に要する時間である, LT (リードタイム; Lead Time) を十分に確保した, 水位予測が必要である.

統計的モデルによる水位予測の手法に水位相関法があり, 計測値点の水位を目的変数, それよりも上流の計測地点における水位を説明変数とする単/重回帰分析による統計モデルを作成する²⁾. しかし, 単/重回帰分析は目的変数の線形性を仮定するため, 水位予測の様に様々な自然現象が複雑に絡み合う現象では計測できる一部の説明変数のみでの正確な予測が困難である. この様な複雑な非線形データの解析には機械学習を用いた統計モデルの利用が情報工学分野を中心に広がっている. 特に ANN (人工ニューラルネットワーク; Artificial Neural Network) は利用例が多く, すでに河川水位予測での利用が提案されている. 関らは, ANN により, 阿武隈川と名取川の予測モデルを 49 の洪水事例より構築し, その RMSE (平均二乗誤差; Root Mean Squared Error) は LT が 6 時間のとき, 0.30 m と報告している³⁾. 一言らは, 深層学習を用いた ANN により, 鹿児島県・宮崎県を流れる大淀川の樋渡 (ひわたし) 地点の水位を予測し, 水位が顕著に上昇し始めた時刻からピーク 6 時間後までの期間における水位の RMSE について LT が 6 時間のとき, 約 0.62 m であると報告している⁴⁾. また, ANN 以外の手法による水位予測に, 岡崎らは, 多数の決定木によるアンサンブル学習を利用した RF (ランダムフォレスト; Random Forest) を用いた, 北海道東部の常呂川下流の上川沿地点の水位予測を提案している⁵⁾. その結果, RMSE は LT が 6 時間のとき, 0.319 m であった.

これらの先行研究で作成された統計モデルは, 複数の説明変数の計測時間差を利用することで, 時系列情報処理を試みてはいるが, モデルの学習アルゴリズムが時系列情報を扱う構造となっていない. 著者らは時系列処理を考慮したモデル学習が可能な, RNN (リカレントニューラルネットワーク; Recurrent Neural Network)




図-1 対象河川の概略図と諸元 (出典: 国土地理院, 国土数値情報, 水文水質データベース)

を利用した水位予測を提案し, 岡崎ら⁵⁾と同様に 2016 年の常呂川の事例の水位予測を試みた⁶⁾. その結果, RMSE は LT が 6 時間のとき, 0.400 m と RF よりも劣ったが, LT が 12 時間の時は 0.626 m と RF の 0.715 m よりも精度が高かった. このモデルの予測水位のハイドログラフより, 高水位時は比較的に合致しているが, 水位が 4 m 以下の低水位時を過大評価し, RMSE が増加していた. よって, 本稿では RNN による水位予測モデルでも平時や低水位時といった, 洪水時以外の予測性能を向上させるため, さらに多くのデータを学習し予測性能が改善するか検討する.

2. 予測対象の河川データと RNN

2.1 利用データ

対象河川はこれまでの検討^{5, 6)}と同様に北海道東部を流れる一級河川常呂川とし, 予測対象地点は 2016 年 8 月に計画高水位 8.45 m を超過し, 既往最大水位である 8.88 m を観測した下流の上川沿地点とした. 図-1 に対象河川の概略図と諸元を示す.

表-1 に利用データの概要を示す. これは表に記載した 6 地点のある時刻 t における 4 時間前までの水位計測値を統計モデルに説明変数として入力し, LT 時間後の水位を目的変数とする. 本データは, 水文水質データベース⁷⁾より取得して利用した. 水文水質データベースには, 常呂川内の各観測所のデータが 1998 年 1 月分から公開されている. この公開データを 2016 年の 10 月まで取得した. この際に, 説明変数または目的変数に用いる観測所に閉局あるいは欠測等により取得できない

値がある場合には、該当期間のデータを除いた*1。収集したデータを評価実験の条件毎に統計モデルの学習に利用する学習データとモデルの評価に利用するテストデータに分割して利用した。

2.2 RNN によるモデル学習

RNN とは、深層学習の一つで、ANN を時系列データを扱えるように拡張したものであり、音声信号処理や自然言語処理の分野などで高い予測精度を持つ統計モデルの作成法となっている^{8,9)}。図-2 に RNN の概念図を示す。図の U は入力層と隠れ層の間の重み、 V は隠れ層と出力層との間の重み、 W は過去の隠れ層と現在の隠れ層の間の重みである。入力層では入力そのまま出力する。一方、現在の隠れ層では現在の入力層と過去の隠れ層の出力に結合の重み U 、 W をかけたものを、出力層では隠れ層の出力に結合の重み V をかけたものを入力とし、それぞれ総和を活性化関数によって出力する。一般的な ANN では、図の上部のネットワークのみで構成され、ある目的変数の値と説明変数との関係が隠れ層の重みである U と V として学習される。しかし、RNN では、目的変数間の時系列を考慮するため、以前の時刻で学習された隠れ層の重みを過去の隠れ層として参照することで、学習時に前のデータの情報も加わる。しかし、単純に過去の隠れ層として全てのネットワークを構築し、重みを参照した場合、長時間の学習の際に過去の重みの影響が大きくなり、急峻な変化に対応しきれない問題がある。この問題を解決する方法が複数提案されており、本研究では LSTM(Long-Short Term Memory)¹⁰⁾ という手法を利用した。LSTM は ANN の隠れ層のノードを LSTM ブロックに置き換え、ブロック内に忘却ゲートを導入¹¹⁾ し、過去の隠れ層の影響を抑えるものである。

本研究ではこの LSTM を用いた RNN (以降、単に RNN とした場合も LSTM を用いているものとする。)によって水位予測モデルを学習する。このモデルは 2.1 節で述べたデータの説明変数を入力とし、目的変数である上川沿地点の予測水位を算出する。この他にも学習に際し、様々なパラメータを設定する必要があるため、予備実験によって表-2 の値を設定した。各パラメータの詳細な説明に関しては文献¹²⁾を参照されたい。

2.3 モデルの評価指標

本稿ではモデルの評価に式 (1) で示す RMSE を用いる。これは目的変数である上川沿地点の水位の実測値とモデルによる予測値との誤差の大きさの平均値である。この値を用いることで、直感的にどの程度の誤差であるかがわかる。ここで、 n は要素数で、 $y^{(i)}$ は i 番目の標本値、 $\hat{y}^{(i)}$ は i 番目の推定値である。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2} \quad (1)$$

*1 特に 2016 年のデータには 11 月、12 月が含まれていない点に注意が必要である。




図-2 RNN の概念図




図-3 評価実験 1 の結果

3. 結果・考察

本稿では表-3 に示す 3 パターンの水位予測モデルを作成し、その結果を考察する。評価実験 1 では、長期間の学習データによって作成したモデルが 2016 年の 10 ヶ月間をどの程度予測できたかを評価することで、学習データサイズによるモデル性能を検証する。評価実験 2 では、既往最大の 2016 年 8 月の事例を含む 10 ヶ月間を学習することで、過去のデータをどの程度予測できたかを評価する。これは、RNN を含む機械学習による統計モデルは、学習した目的変数の値の範囲内での予測精度は高いものの、学習していない目的変数の値に対してはロバストではないことが多いためである。最後の評価実験 3 では、関ら³⁾や岡崎ら⁵⁾と同様に既往の洪水事例として最大水位の事例である 2016 年 8 月の連続洪水の事例を学習することで、評価実験 2 で RMSE が大きかった期間が改善するか検証する。

3.1 評価実験 1

図-3 に評価実験 1 の結果を示す。図中の橙線が RNN モデル 1 による予測値、青破線が上川沿における観測水位の実測値、緑線が計画高水位、赤線が水防団待機水位である。図より明らかなように RNN モデルは、水位の増加するタイミングに関しては傾向をよく捉えており、洪水期間ではない低水位から水防団待機水位程度までの予測は行えている。一方で、台風の影響による更なる増水を絶対値として予測しきれっていない。これは、RNN で用いた学習データのうち、ほとんどの期間が洪水期間ではない平常期間であるため、平常期間の RMSE を最小化する方向に学習されてしまったためである。

表-1 利用データの概要

観測項目	入力			出力
	地点	データ概要	時刻	
水位 (m)	上川沿, 太茶苗, 忠志, 北見, 上常呂, 置戸	地点観測水位 (テレメータ水位)	$t-4, t-3, t-2, t-1, t$	LT 時間後の水位

表-2 学習に用いたパラメータや設定

バッチサイズ	12
活性化関数	ReLU (Rectified Linear Unit)
最適化手法	Adam (Adaptive moment estimation)
損失関数	MSE (Mean Squared Error)
その他	Dropout, early stopping

3.2 評価実験 2

評価実験 1 より, 長期間の学習では低水位は改善するものの, 洪水の予測には不向きなことが明らかとなった. そこで, 学習データとテストデータを入れ替え, 洪水事例を含む 2016 年の 10 ヶ月間を学習したモデル 2 を作成し, その他の月を予測した. 図-4 に LT が 6 時間で予測した結果を, 図-5 に LT が 12 時間で予測した結果をそれぞれ示す. この図では, 年を横軸に, 月を縦軸にとっており, 色は淡赤であるほど RMSE が小さく, 濃赤であるほど RMSE が大きく, 予測精度の悪い月であることを示す. ここで着目すべきは, 図-4 と図-5 の濃赤の部分が共通している点である. これは予測しにくい月が共通することを示す. また, LT に関わらず, 平均 RMSE がほぼ変わらないことから, 12 時間と長い LT でもロバストな予測が行えている. なお, 図の全データの平均 RMSE は, LT が 6 時間では 0.508 m, 12 時間では 0.500 m であった.

もっとも濃い 2015 年 4 月については, 2014 年以前や 2016 年に比べ, 3, 4 月の積雪が深く, 気温が高いため, 融雪により, 上川沿地点水位が 4 m から 5 m と高水位の状態が続いた時期であった. モデル 2 が学習したデータには上川沿地点水位が 4 m から 5 m のときのデータが少なく, 正しく予測できなかったと考えられる. 他の濃色部は, 2001 年 9 月や 2006 年 10 月など, 8 月から 10 月の間に多く存在している. この期間の RMSE の高い 10 ヶ月を LT 別に分析したところ, 共通した月だった. この 10 ヶ月には, 2016 年 8 月の洪水事例を除く, 既往最大水位上位 10 事例のうち 7 ヶ月が含まれていた. 以上の結果より, たとえ既往最大水位の 2016 年 8 月を含む期間を学習したモデル 2 であっても, 平時の値の影響を強く受けてしまい, 高水位の精度が低下したと考えられる.

3.3 評価実験 3

評価実験 1 と 2 では, 時系列データによるモデル学習のため, 学習データが連続データとなるように洪水時と平常時を分割していなかった. 評価実験 2 の結果より, 長期間を学習したモデル 1,2 で予測が困難な 1998 年から 2015 年の 8 月から 10 月の中で 10 事例のデータを選択し, 2016 年 8 月の事例で学習させたモデルで水位予測を行う. 表-4 に選択した 10 ヶ月の評価実




図-4 評価実験 2 の RMSE(LT 6h)




図-5 評価実験 2 の RMSE(LT 12h)

験 2 で作成したモデル 2 の RMSE と 2016 年 8 月事例のみを学習させたモデル 3 による水位予測時の RMSE を示す. 太字は, モデル 2 と 3 で RMSE を比較し, より小さいものを示す. 多くの場合, 2016 年 8 月の事例だけを学習したモデル 3 の方が RMSE が小さい傾向にある. しかし, モデル 2 の方が RMSE が小さいものもあり, LT が 6 時間のときであれば, 2015 年 10 月, 2008 年 10 月, 2004 年 10 月になる. この内, 2008 年 10 月, 2004 年 10 月については, 9 月, 10 月の降水量が平年値の 1 割から 5 割と少なく, 1 ヶ月のほとんどが 2 m を前後するような低水位状態であった. 例年, 10 月の水位が一番低い, 評価実験 2 の学習データで用いた 2016 年は, 8 月, 9 月と降水量の多い状態が続く, 一番水位の低い 10 月でも 2.5 m であった. このため, 2008 年 10 月, 2004 年 10 月を適切に予測できず, RMSE が大きくなったと考えられる. 一方, 2015 年 10 月については, 2015 年 10 月 8 日に, 気象庁のアメダス北見地点で観測史上 3 番目となる, 101 mm の日降水量を記録する大雨となったため, 例年のような低水位の状態から, 急激に水位が上昇し, モデル 2 での予測が追いつかない状態となった. しかし, その後は雨がほとんど降らず, 2.5 m 前後の水位であったため, モデ

表-3 各評価実験の条件

	学習データの期間	予測対象期間
モデル 1	1998 年 1 月から 2015 年 12 月まで	2016 年 1 月から 10 月まで
モデル 2	2016 年 1 月から 10 月まで	1998 年 1 月から 2015 年 12 月まで
モデル 3	既往最大である 2016 年 8 月の連続洪水の事例期間 (2016 年 8 月 4 日から 2016 年 9 月 14 日)	評価実験 2 の結果, 8 月から 10 月の間で RMSE が大き かった 10 ヶ月

表-4 評価実験 3 の結果

テストデータ (最高観測水位順)	LT 6h の RMSE[m]		LT 12h の RMSE[m]	
	モデル 2	モデル 3	モデル 2	モデル 3
2001 年 9 月	1.104	0.889	1.137	0.923
2006 年 10 月	1.094	0.887	1.123	0.930
2006 年 8 月	0.977	0.937	0.994	1.059
1998 年 9 月	1.015	0.712	1.062	0.737
1998 年 8 月	0.917	0.838	0.947	0.947
2015 年 10 月	0.978	0.995	0.978	1.043
2011 年 9 月	1.082	0.758	1.133	0.739
2014 年 8 月	0.902	0.847	0.900	0.835
2008 年 10 月	0.894	1.071	0.875	1.248
2004 年 10 月	0.884	1.061	0.864	1.237

ル 2 の方が RMSE が小さくなったと考える。また、LT が 12 時間のとき、モデル 3 よりモデル 2 の RMSE が小さいのは、2015 年 10 月、2008 年 10 月、2004 年 10 月、2006 年 8 月であった。その中でも、2006 年 8 月は LT が 6 時間のときとは異なり、モデル 2 の方がスコアが良い結果となった。2006 年 8 月は増水前は 2 m 前後と低水位であったが、アメダス北見地点で観測史上 2 番目となる、105 mm の日降水量を記録する大雨となり、2015 年 10 月と同様に急激に水位が上昇し、モデル 2 での予測が追いつかない状態となった。その後も、降雨があり、2016 年 8 月の洪水時と水位のパターンが異なるため、モデル 2 の方が RMSE が小さくなったと考える。

4. 結論

本稿では、RNN を用いた北海道東部に位置する常呂川下流の上川沿地点の水位予測を提案した。特に時系列情報として、水文水質データベースでデータが取得可能な 1998 年から既往最大水位を記録する洪水のあった 2016 年までのテレメータ観測水位を用いて、3 つの評価実験を行った。結果を以下に示す。

- 1) 13 年分のような長期のデータを学習した場合、低水位の予測精度は高いが、洪水のような異常値の予測は困難になる。
- 2) 2016 年のように大規模洪水のある年のデータを 1 年間分のみ学習した場合も洪水のような異常値がある場合の予測性能は低い。
- 3) 多くの洪水事例では、2016 年 8 月のように大規模洪水だけで作成した統計モデルの方が予測性能が高い傾向にある。

これらの結果より、RNN による河川の水位予測は、定常時の低水位の影響が強く出るため、学習データに用いる期間をより吟味する必要があることがわかった。

今後の課題として、雨量データやダムの放流量、予想

降水量といった水位以外の説明変数を加えることを検討する。また、文献⁴⁾では、予測対象を水位値ではなく、水位の変化分としており、その利用を検討する必要がある。文献³⁾では、水位に応じた複数の予測モデルの構築をしており、その利用を検討する必要がある。

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多大な協力を頂いた。本研究の一部は(公財)北海道科学技術総合振興センター(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) 大塚康平, 中津川誠, 谷口陽子: 釧路川を対象とした洪水流出再現精度向上の研究, 土木学会北海道支部, Vol.72, pp.B-23, 2015.
- 3) 関基, 木村晃, 古山一志, 和田高宏, 金子祐, 穴水秀樹, 眞間修一: 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.
- 4) 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.L187-L192, 2016.
- 5) 岡崎亮太, 中津川誠, 小林洋介, 谷口陽子: 機械学習手法に基づく 2016 年 8 月の常呂川連続洪水を対象とした水位予測の研究, 土木学会北海道支部, Vol.73, pp.B-19, 2017.
- 6) 山田恒輝, 中津川誠, 小林洋介, 岸上順一: リカレントニューラルネットワークによる河川の水位予測 - 2016 年 8 月の北海道・常呂川の洪水をケーススタディとして -, 情報処理学会北海道シンポジウム, 2017.
- 7) 国土交通省: 水文水質データベース, <http://www1.river.go.jp/>.
- 8) Graves, A., Mohamed, A.-r., and Hinton, G.: Speech recognition with deep recurrent neural networks, Acoustics, speech and signal processing (icassp), 2013 ieee international conference on, pp. 6645-6649, IEEE, 2013.
- 9) Mikolov, T., Karafiát, M., Burget, L., Cernocký, J., and Khudanpur, S.: Recurrent neural network based language model., Interspeech, Vol. 2, p. 3, 2010.
- 10) Hochreiter, S. and Schmidhuber, J.: Long short-term memory, Neural Comput., Vol.9, No.8, pp.1735-1780, 1997.November.
- 11) 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.
- 12) 巢籠悠輔: 詳解 ディープラーニング TensorFlow・Keras による時系列データ処理, マイナビ出版, 2017.5.