

深層学習の適用による ニューラルネットワーク洪水予測の精度向上

ACCURACY IMPROVEMENT OF ARTIFICIAL NEURAL NETWORK USING DEEP LEARNING METHOD

一言正之¹・桜庭雅明¹

Masayuki HITOKOTO and Masaaki SAKURABA

¹正会員 博士(工) 日本工営株式会社 中央研究所 (〒300-1259 茨城県つくば市稲荷原2304)

In flood prediction, reduction of the uncertainty is one of the biggest issues. As a novel river stage prediction model, the artificial neural network model which is trained by the deep learning method was developed. The model is composed of 4 layer feed-forward network. As a network training method, stochastic gradient descent method based on the back propagation method was applied. Input of the model is hourly change of water level and hourly rainfall, output data is water level of prediction point. Developed model was applied to 4 rivers in Japan, OYOYODO River, KOKAI River, ONGA River and KANO River.

As a result, there was a significant improvement at OYOYODO and ONGA River, which has relatively many observation stations. In these basins, enhance of the learning ability may contributed to the result. On the other hand, at KOKAI and KANO River, there may be little margin for improvement even though learning ability enhanced.

Key Words : River stage, real-time prediction, deep learning, artificial neural network

1. はじめに

全国の一級河川で洪水予測システムが稼働しているが、住民の適切な避難判断に役立てるためには、予測精度が不十分な場合が多い¹⁾。河川の水位予測には様々な手法が提案されており、その一つにニューラルネットワーク (Artificial Neural Network ; ANN) を用いた予測手法がある。これまでの研究で、様々な河川においてANNの適用性が報告されている^{2,3,4,5)}が、他の手法と比べた精度の優位性は示されておらず、全国の洪水予測システムなどで実用に至っている例は少ない。一方、ANNの新しい学習手法として深層学習⁶⁾と呼ばれる手法が開発されており、高い学習能力により画像認識⁷⁾や音声認識⁸⁾など、様々な分野で成果が挙がりつつある。

ANN水位予測に深層学習を適用した事例として、大淀川でのケーススタディを行った例⁹⁾がある。しかしながら、これまでに検討された事例は限られており、対象とする流域の面積や流出特性、予測に利用可能な観測データの数や種類などによる適用性の違いは明らかではない。本研究では、高精度な河川水位予測手法の開発を

目的として、ANN水位予測モデルに深層学習によるネットワーク学習手法を適用し、複数の流域で精度検証を行った。

国内の4つの流域（大淀川、小貝川、遠賀川、狩野川）において、深層学習を適用したANNのケーススタディを行い、適用性の検証を行った。学習データとして、各流域で既往の20洪水程度の水位、雨量データを水文・水質データベースより抽出した。予測精度検証として、leave-one-out交差検証により上位の数出水について再現性を確認した。各ケースにおいて、学習回数や学習パラメータ、中間層や中間素子数について感度分析を行い、学習に関する各種設定を最適化した。従来型学習と深層学習との各手法による予測精度について、流域特性の違いや、入力データの数や種類、予測時間に応じた違いなどを検討し、特徴をまとめた。

従来型の学習手法に比べて、深層学習を適用したANNでは、4流域のうち2流域で高い予測精度を示した。入力データとして多数の観測データが利用できる場合、深層学習による精度向上の効果が大きく、一方で観測データが不十分な場合には深層学習の適用効果が見られなかった。




図-1 大淀川流域と観測所位置図。




図-2 小貝川流域と観測所位置図。




図-3 遠賀川流域と観測所位置図。




図-4 狩野川流域と観測所位置図。

表-1 予測対象地点の概要。

予測地点名	流域名	流域面積	上流の水位観測所数	雨量観測所数
樋渡	大淀川	861.0	4	14
小貝川水海道	小貝川	757.5	5	6
日の出橋	遠賀川	695.0	10	11
大仁	狩野川	322.0	0	8

2. 検討流域と対象洪水

(1) 対象流域の概要

対象流域は、大淀川水系の樋渡（ひわたし）地点（図-1）、遠賀川水系の日の出橋地点（図-2）、利根川水系小貝川の小貝川水海道（こかいがわみつかいどう）地点（図-3）、狩野川水系の大仁（おおひと）地点（図-4）とした。各流域の流域面積と、本検討に用いた水位・雨量観測所の数を表-1に示す。各流域で、上流に大きな洪水調整施設は無い。日の出橋上流には陣屋ダムがあるが、

流域面積は12.6 km²と小さく、影響はごくわずかと考えられる。検討に用いた実績水位、地上雨量データは、水文・水質データベースより取得し、対象洪水において欠測が少ない地点を検討に用いた。小貝川水海道については、利用できる国交省の雨量観測地点が少なかったため、気象庁のアメダス観測雨量も併せて利用した。大仁については、上流に水位観測所が無いいため、雨量データのみで予測を行った。なお、各流域で取得したデータは全て1時間間隔である。

表-2 検討対象洪水のピーク水位一覧（太字ゴシック表記は検証対象洪水）。

順位	樋渡	小貝川水海道	日の出橋	大仁
1	10.65	7.03	8.06	3.94
2	9.80	5.99	8.06	2.93
3	9.50	5.76	7.99	2.90
4	9.44	5.75	6.34	2.75
5	9.16	5.66	6.33	2.64
6	8.26	5.66	6.32	2.61
7	8.04	5.57	6.18	2.48
8	7.70	5.34	5.82	2.45
9	7.47	5.33	5.80	2.19
10	7.24	5.28	5.70	2.17
11	7.11	5.27	5.63	1.99
12	6.99	5.19	5.59	1.95
13	6.90	5.08	5.58	1.94
14	6.84	5.08	5.55	1.87
15	6.79	5.02	5.41	1.84
16	6.72	4.97	5.06	1.78
17	6.53	4.89	4.92	1.69
18	6.30	4.85	4.87	1.61
19	6.03	4.75	4.80	1.51
20	-	4.73	4.74	-

凡例

はん濫危険水位を超過	避難判断水位を超過
はん濫注意水位を超過	水防団待機水位を超過

(2) 対象洪水の概要

対象洪水として、各地点より20洪水程度を抽出した。対象洪水の一覧を表-2に示す。なお洪水抽出期間は、樋渡で1990～2013、小貝川水海道で1980～2015年、日の出橋で2005～2014年、大仁で1980～2015年である。洪水対象期間は、ピークの72時間前から48時間後までとした。したがって、例えば樋渡地点では19洪水×121時間＝2299時間分のデータを検討対象に用いた。各対象洪水のうち、上位の3～4出水を検証対象洪水とした。

(3) 相関分析による洪水到達時間の算出

対象洪水データの相関分析により、上流の水位、雨量観測所から予測地点までの洪水到達時間を算出した。相関分析の目的変数は、予測地点における1時間あたりの水位変化とした。説明変数は、上流地点における1時間あたりの水位変化、および時間雨量とした。算出した洪水到達時間を表-3に示す。なお小貝川水海道では、上郷水位観測所からの到達時間が4時間程度、その他の観測所からの到達時間が12～13時間程度であった。

3. ニューラルネットワークと深層学習

ニューラルネットワークおよび深層学習を用いた水位予測手法は、既往文献⁹⁾に詳述されている。本稿では概要のみを記載する。

表-3 相関分析による観測所からの洪水到達時間。

予測地点名	雨量観測所からの到達時間	水位観測所からの到達時間
樋渡	1～2時間	1～2時間
小貝川水海道	12～15時間	4～13時間
日の出橋	1～3時間	1～2時間
大仁	1時間未満	-




図-5 ANNの概念図。




図-6 ANN構成素子の概念図。

(1) ニューラルネットワーク水位予測モデルの概要

本検討で用いたモデルは、入力層・中間層・出力層から構成される階層型ネットワークとした（図-5）。ネットワークを構成する素子の模式図は図-6に示すとおりであり、各素子において以下のように計算を行う。

$$u = \theta_i + \sum_{i=1}^K w_i x_i \quad (1)$$

$$z = f(u) \quad (2)$$

ここで、 u は各素子の入力値、 x は入力値、 w は重み係数、 θ はバイアス、 K は各階層の構成素子数、 $f(u)$ は活性化関数、 z は素子の出力である。本稿で以下はバイアスも含めたパラメータベクトル w を改めて重み係数と呼ぶ。なお活性化関数には様々な関数が使われるが、本検討では最も適用事例の多いシグモイド関数を用いた。

ネットワークの学習には確率的勾配降下法を用い、学習係数の設定は、近年最もよく使われているAdaGrad¹⁰⁾を適用した。重み更新の際にはモーメンタム¹¹⁾を与えることで勾配降下法の収束性の向上を図った。誤差関数の勾配の算出には誤差逆伝搬法¹²⁾を用いた。学習データの関連性を十分に学習し、かつ過学習による精度低下を避けるため、ドロップアウト¹³⁾を適用した。ドロップアウトは、学習計算時にネットワークの素子を確率の割合で無効化することで、ネットワークの自由度を強制的に小さくし過学習を避ける狙いがある。




図-7 自己符号化器の概念図。

(2) 深層学習を適用した水位予測モデルの概要

深層ANNの学習時における勾配消失問題への対応として、本研究では自己符号化器⁴⁾による事前学習を行い、精度向上を図った。自己符号化器の模式図は図-7に示す通りであり、入力 x と出力 $\hat{x}$ ができるだけ同じになるよう、重みの調整（学習）を行う。

4. ケーススタディ

(1) 水位予測モデルの構築

本検討では2種類のモデルを構築した。一つ目のモデルは深層学習モデル、二つ目のモデルはANN（従来型）である。深層学習モデルは、入力層・中間層2層・出力層の4層から構成され、学習時には自己符号化器による事前学習を適用した。ANN（従来型）は入力層・中間層・出力層の3層から構成され、事前学習は行わない。それぞれのモデルで、事前学習以外の学習手順や、学習・検証に用いるデータは同じとした。

(2) 入力層の設定

入出力層の組合せは表-4の通りとし、1～6時間の予測時間ごとにネットワークを構築した。入力データは、第2章の相関分析による洪水到達時間の検討より、水位予測に影響を及ぼしうる地点・時刻のデータをできる限り包含するように設定した。

例えば樋渡水位変化に対する各水位観測所の水位変化の相関は、タイムラグが1～2時間の時に最大となったため、入力層には現時刻から2時間前までのデータを設定した。また同様に各降雨観測所についてもタイムラグ1～2時間の時に相関が最大となったが、累積雨量が影響する可能性を考慮して予測時刻から5時間前までのデータを設定した。例えば3時間予測を行うネットワークでは、出力層は現時刻から3時間後までの樋渡の水位変化、入力層には樋渡自身の1時間前と現時刻の水位、流域内5水位観測所の2時間前～現時刻における1時間あたりの水位変化、流域内14地点の2時間前～2時間後の時間雨量となる。将来時刻の雨量には、実測雨量を予測雨量に見立てた完全予測データを用いた。将来時刻の水位は未知で

表-4 時刻0からt時間予測を行う場合の入出力層組合せ。

入力				出力
予測地点名	時間雨量	1時間の水位変化	時刻水位	
樋渡	t-5～t-1	-2～0	-1,0	時刻 0～tの 水位変化
小貝川水海道	t-16～t-1	-16～0	-1,0	
日の出橋	t-5～t-1	-2～0	-1,0	
大仁	t-5～t-1	-	-1,0	

表-5 学習の各種設定。

種別	設定内容
学習データ期間	過去10～36年間の上位20洪水程度
学習データ種類	予測地点水位、上流水位変化、時間雨量
データセット数	2299～2420
バッチサイズ	100
予測時間	1時間～6時間
モーメントム	0.5
学習率	初期値0.1としてAdaGradで自動設定
ドロップアウト率	0.1

表-6 学習の設定に関するスタディケース（樋渡）。

ケース番号	学習回数	各層の素子数	ドロップアウト率(p)
1	300	87-10-5-1	0.1
2	1000	87-20-10-1	0.3
3	3000	87-40-20-1	0.5
4	10000	87-60-30-1	

あるため、水位変化は現時刻までのものを用いた。以上より、1つの学習データセットの入力層は87個のデータより構成される。同様に、各予測モデルの入力データ数は、小貝川水海道では206、日の出橋では90、大仁では45となった。

(3) 学習回数・中間層数・中間素子数の設定

学習に関する各種の設定が、どのように予測精度に影響するか不明である。本研究ではケーススタディにより予測精度の比較を行った。学習の基本設定は表-5の通りとした。ドロップアウト率(p)、学習回数、各層の素子数については、表-6のようにスタディケースを設定した。ただし、入力層の素子数は入力データ数と同様であり、中間層の素子数は入力データ数に応じて流域ごとに設定した。

(4) 予測計算の実施

検証対象4洪水に対してleave-one-out交差検証を行っ




図-8 樋渡（大淀川）の予測水位RMSE（4洪水平均）。




図-9 小貝川水海道の予測水位RMSE（4洪水平均）。




図-10 日の出橋（遠賀川）の予測水位RMSE（3洪水平均）。




図-11 大仁（狩野川）の予測水位RMSE（4洪水平均）。

た．具体的には，例えば樋渡では，19事例の検討対象洪水のうち1洪水を検証データ，残り19洪水を学習データとした計算を1セットとし，同様の手順を検証対象4洪水について行うことで精度を評価した．乱数による重み係数の初期設定の影響を平滑化するため，同様の手順を10回繰り返す，それぞれの計算結果の算術平均を予測水位とした．なお精度評価の対象は，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（Root Mean Squared Error）とした．




図-12 樋渡（大淀川）の予測水位。




図-13 小貝川水海道の予測水位。




図-14 日の出橋（遠賀川）の予測水位。




図-15 大仁（狩野川）の予測水位。

5. 計算結果と精度評価

各地点における予測水位と実測水位とのRMSE（4洪水平均）結果を図-8～11に、期間最大洪水における予測水位の結果を図-12～15に示す。樋渡および日の出橋では深層学習の適用による精度向上の効果が大きい。一方、小貝川水海道と大仁では2つのモデルでほとんど差が無い結果となった。

樋渡では、全般的に洪水波形を良く再現したが、図-12のようにピーク付近で予測が過大となった。本稿で示した期間最大洪水では、特にこのような傾向が強く見られた。入力層の工夫などで改善する可能性があるが、今後の検討が必要である。

小貝川水海道では、出水全体の再現性が比較的良好な結果となった。上流の水位観測地点からの到達時間が、予測時間に対して十分に長いため、十分な水位情報が活用できたためと考えられる。

日の出橋では、深層学習の適用による効果が最も大きかった。波形の立ち上がりでやや予測が過小評価となる傾向が見られたが、全体的な再現性は良好であった。

大仁地点では、ピーク前後の急激な立ち上がり、低減が十分に表現できていない。大仁地点では上流の水位観測地点が無いいため、予測精度向上には不利である。また降雨-流出時間が1時間未満であるのに対し、検討に用いたデータは全て1時間間隔であったため、十分に出水パターンが学習できていない可能性がある。10分間隔のデータを用いることで精度向上の余地があると考えられる。

学習に用いた雨量・水位観測所の地点数は、樋渡で18地点、日の出橋で21地点であるのに対し、小貝川水海道では12地点、大仁では8地点と比較的少ない。したがって前者の2地点では、深層学習の適用による精度向上の余地が大きかった一方で、後者の2地点では精度向上の余地が小さかったものと考えられる。

6. おわりに

本研究では、深層学習の適用によるニューラルネットワーク水位予測モデルの精度向上を目的として、国内の4河川について事例検討を行った。検討の結果、入力データとして多数の観測データが利用できる場合、特に深層学習による精度向上の効果が確認された。一方で利用できる観測データが少ない場合には、従来型のANNからの精度向上の余地が少ない結果となった。

また両手法に共通した課題として、既往洪水中に規模の大きな洪水が少ない場合などに、高水位に対する十分な学習がなされず予測精度が落ちる場合が確認された。今後、高水位に対する精度向上策として、入力層の工夫などによる更なる検討が課題として挙げられる。

参考文献

- 1) 椿涼太, 小林健一郎, 内藤正彦, 谷口丞: 洪水予測技術の現状と課題について, 河川技術論文集, Vol.19, pp.1-6, 2013.
- 2) ASCE Task Committee on Application of Artificial Neural Networks in Hydrology: Artificial neural networks in hydrology. II: Hydrologic Applications, Journal of Hydrologic Engineering, Vol.5, No.2, pp.124-137, 2000.
- 3) Dawson, C.W. and Wilby, R.L.: Hydrological modeling using artificial neural networks, Progress in Physical Geography, Vol.25, No.1, pp.80-108, 2001.
- 4) Maier, H.R. and Dandy, G.C.: Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, Environmental Modelling & Software, Vol.15, pp.101-124, 2000.
- 5) Maier, H.R., Jain, A., Dandy, G.C. and Sudheer, K.P.: Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions, Environmental Modelling & Software, Vol.25, pp.891-909, 2010.
- 6) Hinton, G.E., Osindero, S. and Teh, Y.: A fast learning algorithm for deep belief nets, Neural Computation, Vol.18, pp.1527-1544, 2006.
- 7) Krizhevsky, A., Sutskever, I., & Hinton, G. E.: Imagenet classification with deep convolutional neural networks, In Advances in neural information processing systems, pp. 1097-1105, 2012.
- 8) Seide, Frank, Gang Li, and Dong Yu: Conversational Speech Transcription Using Context-Dependent Deep Neural Networks, Interspeech, 2011.
- 9) 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.1_187-1_192, 2016.
- 10) Duchi, J., Hazan, E. and Singer, Y.: Adaptive subgradient methods for online learning and stochastic optimization, Journal of machine learning research, Vol.12, pp.2121-2159, 2011.
- 11) 岡谷貴之: 深層学習, 講談社サイエンティフィック, 2015.
- 12) Rumelhart, D. E., Hinton, G. E., and Williams, R. J.: Learning representations by back-propagating errors. Nature, 323, pp.533-536, 1986.
- 13) Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.: Dropout: A simple way to prevent neural networks from overfitting, Journal of machine learning research, Vol.15, pp.1929-1958, 2014.
- 14) Bengio, Y., Lamblin, P., Popovici, D. and Larochelle, H.: Greedy layer-wise training of deep networks, Advances in Neural Information Processing Systems 19, pp.153-160, 2007.

(2016. 4. 4受付)