ACCURACY IMPROVEMENT OF DEEP ARTIFICIAL NEURAL NETWORK RIVER STAGE PREDICTION USING MULTIPOINT OBSERVATION DATA

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 prediction model, artificial neural network (ANN) is one of the potent methods. To improve the accuracy and lead-time of the river-stage prediction model, it is desirable to take advantage of as many observation data as possible. However, due to the limitation of the learning ability of ANN model, it is undesirable to use too many input data into the model. As a new learning method of ANN, deep learning is said to have an excellent ability of learning, and able to handle huge input data. In this study, we developed to models, 4 layered deep learning based ANN and 3 layered conventional ANN. We applied 2 models to the 3 rivers in Japan, Ooyodo River, Onga River and Kokai River. Compared to the conventional ANN, deep learning based ANN model could reflect more observational information and could reproduce the past flood well.

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

(Aritificial 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モ デルの適用性が報告されている^{2),3),4)}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.

従来のANNモデルの課題として、入力データが増大 するとネットワークの未知パラメータが膨大となり、学 習効果が低下することが挙げられる.そのため、できる 限り重要な入力データを絞り込むことが必要とされてき た^{2,3,4}.しかしながら、水位予測の精度向上のためには、 流域の降雨分布や降雨履歴、上流の水位情報などより多 数の観測情報を有効活用することが望ましい.

一方,ANNの新しい学習手法として深層学習⁵と呼ば れる手法が開発されている.筆者らは,ANNモデルの 発展形として,深層学習を適用した河川水位予測手法 (以下,深層ANNモデル)を構築し,精度向上を図っ てきた^{0,7,9}. 深層学習は従来手法に比べて高い学習能力 が報告されており⁵,多量の入力データに対しても適切 な学習効果が期待される.

本検討は、多地点観測情報の有効活用という観点に着 目し、従来の学習手法を用いたANN水位予測モデル (以下、従来型ANNモデル)と、深層ANNモデルとの それぞれについて、複数流域におけるケーススタディを 行った.ケース1では、水位予測地点に対して支配的な 水位観測地点と雨量観測地点を1箇所ずつ絞り込み、そ れらを学習データとした.ケース2では、流域内の全て の観測地点を活用して学習データを作成した.各ケース について、従来型ANNモデルと深層ANNモデルの予測 精度を比較・考察した.

2. 検討流域と対象洪水

(1) 対象流域の概要

対象流域は、大淀川の樋渡(ひわたし)地点(図-1)、



図-1 大淀川流域と観測所位置図.



図-2 遠賀川流域と観測所位置図.

遠賀川の日の出橋(ひのでばし)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)とした.各流域面積と,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.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.取得したデータは全て1時間間隔である.

(2) 対象洪水の概要

対象洪水として,各地点よりはん濫注意水位を超過し た洪水を抽出した.対象洪水の一覧を表-2に示す.なお

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		
日の出橋	遠賀川	695.0	10	11		
小貝川水海道	小貝川	757.5	5	10		



図-3 小貝川流域と観測所位置図.

洪水抽出期間は、水文・水質データベースで主な地点 のデータが入手できる期間とし、樋渡では1982~2016年、 日の出橋では1987~2016年、小貝川水海道では1980~ 2016年である。検討対象洪水数は、樋渡で22、日の出橋 で18、小貝川水海道で18である。検証対象洪水は、樋渡 と小貝川水海道では対象洪水のうち上位の4洪水、日の 出橋では上位5洪水とした。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。例えば樋渡地点では 22洪水×121時間=2662時間分のデータが検討対象とな る。ただし、その中から欠測のあるデータは除外したう えで検討に用いた。

(3) 相関分析による洪水到達時間の算出

洪水予測モデルの入力値として有効な時系列データを 選定するため、対象洪水データの相関分析を行った.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(ΔH)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.予

表-2 検討対象洪水の一覧(太字ゴシックは検証対象洪水).

	樋渡		日の出橋		小貝川水	小貝川水海道	
順位	ピーク	ピーク	ピーク	ピーク	ピーク	ピーク	
	年月日	水位	年月日	水位	年月日	水位	
1	2005/9/6	10.65	2010/7/14	8.06	1986/8/6	7.03	
2	2004/8/30	9.80	2012/7/14	8.06	2004/10/21	5.76	
3	1993/8/1	9.50	2003/7/19	8.02	1993/8/28	5.75	
4	1990/9/29	9.44	2009/7/25	7.99	2008/8/29	5.66	
5	2010/7/3	9.16	2001/6/20	7.80	2015/9/11	5.66	
6	1989/7/28	8.40	1995/7/3	6.90	2012/5/4	5.34	
7	1999/9/14	8.26	1999/6/29	6.72	1985/7/2	5.33	
8	1993/8/10	8.04	1991/6/10	6.55	2002/7/11	5.28	
9	2004/10/20	7.70	1991/7/27	6.47	1998/9/17	5.27	
10	1990/9/19	7.47	2013/8/30	6.34	2011/9/22	5.19	
11	1999/8/6	7.24	2006/6/23	6.33	1997/5/26	5.08	
12	2007/7/14	7.11	2006/7/5	6.32	2000/7/9	5.08	
13	1993/9/3	6.99	1993/8/19	6.30	1988/9/26	5.02	
14	1995/6/25	6.90	1988/7/23	6.19	2001/10/11	4.97	
15	1996/7/18	6.84	2008/6/21	6.18	2006/6/17	4.89	
16	2003/8/8	6.79	2016/7/13	6.17	2014/10/7	4.85	
17	1999/7/27	6.72	1991/7/4	5.94	1996/9/23	4.75	
18	2014/7/31	6.61	1990/6/15	5.91	2004/10/10	4.73	
19	2000/6/3	6.53					
20	2010/6/20	6.30		/=-1	はん濫危険水位を超過		
21	2014/8/9	6.08	, 가	1列:	産難判断水位を	超過	
22	1999/8/17	6.03		l	はん濫注意水位を超過		



測地点の水位変化と相関の高いタイムラグは、樋渡と日 の出橋では1、2時間程度であるのに対し、小貝川水海道 では最大16時間程度となった(図-4). これらのタイム ラグは、各観測所からの洪水到達時間に相当していると 考えられる.小貝川水海道では樋渡流域・日の出橋流域 と比べて河道長が長く勾配も緩やかなため洪水到達時間 が長くなっている.



3. ニューラルネットワーク水位予測モデル

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^{0,7,8}に詳述されている.本稿では 概要のみを記載する.

(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(図-5上)を用いた. ネットワーク を構成する各素子において以下のように計算を行う.

$$u = \theta + \sum_{i=1}^{K} w_i x_i \tag{1}$$
$$z = f(u) \tag{2}$$

$$=f(u) \tag{2}$$

ここで, uは各素子の入力和, 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. 入力層・中間層の活性化関数には、従来研究で最も適用 事例の多いシグモイド関数を用いた. 出力層の活性化関 数は恒等写像 (f(u)=u) とした.

ネットワークの学習には確率的勾配降下法を用い、学 習係数の設定にはAdaGrad⁹を用いた. 重み更新の際に はモーメンタム10を与えることで勾配降下法の収束性の 向上を図った. 誤差関数の勾配算出には誤差逆伝搬法11) 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12)を 適用した. ドロップアウトは、学習時にネットワークの 素子を確率pの割合で無効化することで自由度を強制的 に小さくし過学習を避ける効果がある.

ケーフタ	予測地点名	入力データ数(時系列数×地点数)					出力
7-74		時間雨量	上流∆H	自己ΔΗ	自己水位	合計	データ数
	樋渡	5×1	3×1	3×1	2×1	13	1
2地点 ケース	日の出橋	5×1	3×1	3×1	2×1	13	1
	小貝川水海道	6×1	6×1	3×1	2×1	17	1
	小貝川水海道※	18×1	18×1	3×1	2×1	41	1
多地点 ケース	樋渡	5×14	3×4	3×1	2×1	87	1
	日の出橋	5×11	3×10	3×1	2×1	90	1
	小貝川水海道	6×10	6×5	3×1	2×1	95	1

表-3 ANNモデル(従来型ANNモデルおよび深層ANNモデル)の入出力データ.

(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¹³による事前学習を適用した.自己符号化器の模式図は図-5に示す通りであり、入力xと出力 x ができるだけ同じになるよう重みの調整(学習)を行うことで、入力データ中の重要な成分(特徴)を中間層に集約する効果がある.

(3) 水位予測モデルの構築

深層ANNモデルと従来型ANNモデルの2種類の水位予 測モデルを構築した.深層ANNモデルは、入力層・中 間層2層・出力層の4層で構成し、学習時には自己符号化 器による事前学習を適用した.従来型ANNモデルは入 力層・中間層・出力層の3層で構成し、事前学習は行わ ない.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.ANNの入力データは、観測所の 時間雨量、水位および1時間あたりの水位変化(ΔH) と した.出力データは、予測地点における現時刻から予測 時間までの水位変化とし、1~6時間の予測時間ごとに ネットワークを構築した.

4. 入出力データの設定

従来のANNでは、大量の入力データを与えると学習 効率が低下してしまうために、事前に重要な入力データ を絞り込むことが必要とされてきた^{21,3,4}. 一方で深層学 習は従来型ANNの学習手法よりも高い能力が報告され ており^{5,10},より多量のデータに対しても効率的に学習 が可能となり、予測精度向上につながることが期待され る.本検討では、従来型ANNモデルおよび深層ANNモ デルのそれぞれについて、主要な観測地点を絞り込んで 入力データとしたケースと、多地点の観測情報を活用し たケースに分けて検討を行った.

設定した入力データの組合せは**表-3**の通りとした.入 カデータの時系列については,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.以下に具体的な設定方法を示す. ※2地点-多時系列ケース

入力データを主要な観測所データのみに絞り込んだ モデル(2地点モデル)

第2章の相関分析の結果から、予測地点の水位変化と 相関の高い雨量観測所、水位観測所をそれぞれ1地点ず つ選定した.選定した地点は、樋渡予測では岳下(雨) および岳下(水位),日の出橋予測では内野(雨)およ び川島(水位),小貝川水海道予測では真壁(雨)およ び上郷(水位)である.選定した地点の時間雨量,時間 水位変化をANNモデルの入力データとした.データの 時系列については、最も相関の高いタイムラグの前後数 時間分を入力データとして用いた.また、予測地点自身 の水位、水位変化の時系列も入力データに加えた.

例えば樋渡における多地点ケースの場合,1時間予測 の入力層は、4時間前から現時刻までの14地点の時間雨 量,現時刻から2時間前までの4地点のΔH,2時間前から 現時刻までの樋渡自身のΔH,1時間前と現時刻の樋渡自 身の水位である.2時間以上の予測では、雨量データに 予測雨量を用いるものとし、本検討では実測雨量を予測 雨量に見立てた完全予測データを用いた.

小貝川水海道については、他の2流域よりも流下時間 が長いため、時系列的に多数の入力データを用いること が有益であると考え、ケースを追加した(以下,2地点-多時系列ケース).具体的には、時間雨量・時間水位変 化の最も相関の高いタイムラグ前後から現時刻までの データを用いるものとし、それぞれ18時間分の時系列 データを入力データとした.

(2) 入力データに全ての観測所データを用いたモデル (多地点モデル)

図-1, 2, 3および表-1に示す全ての観測地点のデータ を入力データとした.データの時系列は表-3のとおり, 2地点モデルと同様とした.

5. ケーススタディの実施

(1) ネットワークおよび学習条件の各種設定

学習の基本設定は**表-4**の通りとした.中間層の素子数 およびドロップアウト率(*p*)については,**表-5**のように

表−4 学習の各種設定.					
種別					
学習データ期間	過去 30~37 年間の洪水データ				
学習データ種類	水位,水位変化,時間雨量				
ミニバッチのサイズ	100				
モーメンタム	0.5				
学習率の設定方法	AdaGrad (初期值 0.1)				

表5	学習条件の最適化のためのスタディケーン			
	(北通))市	名批占エデル	涩屑ANNモデル)	

ケース		学習	쇧	ドロップ			
番号		回数	入力	中間	出力	アウト率	
	1					0.00	
	2					0.05	
1	3		87	40-20	1	0.10	
	4					0.15	
	5					0.20	
	1	30000			1	0.00	
	2			60-30		0.05	
2	3		87			0.10	
	4					0.15	
	5					0.20	
3	1					0.00	
	2					0.05	
	3		87	80-40	1	0.10	
	4					0.15	
	5					0.20	

ケーススタディにより最適値を設定した. なお,入力層 の素子数は入力データ数と同様である. またドロップア ウトは中間層のみに適用した.

(2) 予測計算の実施

検証対象洪水に対してleave-one-out交差検証を行った. 例えば樋渡では、22事例の検討対象洪水のうち1洪水を 検証データ、残り21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.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.

6. 計算結果と精度評価

(1) 樋渡(大淀川),日の出橋(遠賀川)の精度評価

主要2地点の観測情報を入力データとしたケースと, 多地点の観測情報を入力データとしたケースとの2ケー スについて,それぞれ従来型ANNモデルと深層ANNモ デルを用いた結果のRMSEを図-6に示す.また,両地点 の期間最大洪水における予測結果(深層ANNモデル, 多地点)を図-8,9に示す.

従来型ANNモデルでは、いずれの流域でも主要2地点



図-6 樋渡,日の出橋の予測水位RMSE(全検証対象洪水の平均, 6時間平均).



図-7 小貝川水海道の予測水位RMSE(全検証対象洪水の平均,6 時間平均).

ケースの方が再現性が高くなった.これは、多地点ケー スではデータが多量になり学習効率が低下したためと考 えられる.

深層ANNモデルでは、多地点ケースの方が再現性が 高くなった.深層学習を適用したことで多量のデータを 適切に学習することが可能となり、上流域の降雨・水位 変化の分布が適切に反映されたことで再現精度が向上し たものと考えられる.

(2) 小貝川水海道の精度評価

小貝川水海道では、2地点ケース、多地点ケースに加 え、2地点のより多時系列情報を入力データとしたケー ス(2地点-多時系列ケース)の3ケースを実施した.各 ケースにおいて、従来型ANNモデルと深層ANNモデル を用いた結果のRMSEを図-7に、期間最大洪水における 予測結果(深層ANNモデル、2地点-多時系列ケース) を図-10に示す.

従来型ANNモデルでは、2地点ケースが最も再現性が 高く、次いで2地点-多時系列ケース、多地点ケースの順 となった. 樋渡・日の出橋の場合と同様に、データが多 量になるにつれ、かえって再現精度が低下する結果と なっている.

深層ANNモデルでは、2地点ケースと多地点ケースが 同程度の再現性となり、2地点-多時系列ケースが最も再 現性が高くなった.小貝川水海道では流域の形状が直線



図-10 小貝川水海道の予測水位(深層ANN, 2地点-多時系列).

状で支川合流が少ないため、多地点データを用いるメ リットが表れなかったものと考えられる.一方で洪水流 下時間が長いため、より多くの時系列データが影響して おり、多時系列データを用いたケースの再現性が高く なったものと考えられる.深層学習を適用したことによ り、多時系列にわたる多データを適切に学習することが 可能になったものと考えられる.

7. おわりに

本検討は、多地点観測情報の有効活用という観点に着 目し、従来型ANNモデルと比べた深層ANNモデルの優 位性について検証を行った.

従来型ANNモデルは、入力データを絞り込んだ方が 予測精度が高く、より多量の観測情報を用いたケースで はかえって精度が悪くなった.

深層ANNモデルは、より多量の観測データを用いる ことにより精度向上が実現できた.小貝川水海道の予測 では、観測地点を増やすことによる精度向上は見られな かった一方で、観測データの時系列数を増やすことによ る精度向上を実現することができた.深層学習を用いた 場合にも、むやみに入力データを増やすよりは、あるて いど有益な情報を選別することが有効だと考えられる.

従来型ANNモデルとの比較では、深層ANNモデルは、 各ケースにおいて高い予測精度を示した.特に多数の観 測情報が活用できる場合、深層学習の適用による精度向 上への優位性が大きいことが示された.

参考文献

- 椿凉太,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.
- 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.
- 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.
- 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.
- Hinton, G. E., Osindero, S. and Teh, Y. : A fast learning algorithm for deep belief nets, *Neural Computation*, Vol. 18, pp. 1527-1544, 2006.
- 一言正之, 桜庭雅明, 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 187-1 192, 2016.
- 一言正之, 桜庭雅明: 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, 河川技術論文集, Vol.22, pp.1-6, 2016.
- 一言正之, 桜庭雅明:深層ニューラルネットワークと分布 型モデルを組み合わせたハイブリッド河川水位予測手法, 土木学会論文集B1(水工学), pp.22-33, 2017.
- 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.
- 10) 岡谷貴之: 深層学習, 講談社サイエンティフィック, 2015.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. : Learning representations by back-propagating errors. *Nature*, Vol.323, pp.533-536, 1986.
- 12) 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.
- 13) Bengio, Y., Lamblin, P., Popovici, D. and Larochelle, H. : Greedy layer-wise training of deep networks, *Advances in Neural Information Processing Systems*, Vol. 19, pp. 153-160, 2007.

(2017.4.3受付)