3L4-4

ニューラルネットワークによる洪水予測の精度向上

Accuracy improvement of ANN flood forecasting model

一言　正之[*1]
HITOKOTO Masayuki

清　雄一[*2]
SEI Yuichi

櫻庭　雅明[*1]
SAKURABA Masaaki

[*1] 日本工営株式会社 中央研究所
Nippon Koei Co., Ltd.
R&D Center

[*2] 電気通信大学 大学院情報システム学研究科
Graduate School of Information Systems,
The University of Electro-Communications

The Artificial Neural Network (ANN) is widely used as a flood forecasting model that can be applied to a wide range of watershed. One of the challenges for the ANN model is to clarify the prediction accuracy and the uncertainty. In this study, the ANN flood forecasting model is developed through the case study approach. Then the ensemble study of the ANN model is applied to the Japanese first-grade river, and the accuracy improvement was obtained compared to the normal ANN model.

1. はじめに

洪水災害に対するソフト対策として，洪水予測技術の高度化が求められている．洪水予測手法として，降雨－流出過程を表現する物理型モデルなどが全国の河川で適用されているが，様々な誤差が内在する．一方，降雨や水位等の水文観測データに基づいたニューラルネットワーク（Artificial Neural Network: ANN）による洪水予測も，既往の研究にて広く適用性が確認されている[ASCE Task Committee 2000，Dawson 2001，Maier 2000]．いずれの予測手法も，予測の精度向上・不確実性の低減が課題となっている．ANN 洪水予測の精度向上の一つとしてアンサンブル学習[Anctil 2004]が研究されているが，国内での適用事例はみられない．本研究では，ANN による洪水予測の精度向上を目的として，国内の1級河川を対象として検討を行った．ANN の最適な入力データの組合せ，ネットワーク構造，学習回数に関するケーススタディを行い，予測モデルを構築した．構築したモデルにアンサンブル学習を適用し，単一の学習モデルに比べ予測精度向上を確認した．

2. 予測対象

2.1 予測対象流域

対象流域は国内1級河川の A 川，B 地点とした．予測地点から上流の流域面積は約 900km^2，最上流部までの河道延長は約 80km である．流域内には水位観測所が 8 か所，雨量観測所が 10 箇所設置されている．雨量・水位の時間データをはじめ，水質やダムデータなど様々な観測データが水文水質データベースに公開されている[http://www1.river.go.jp/]．

2.2 予測対象洪水

治水上の重要な河川では，複数の基準地点で洪水予報の発表基準となる河川水位および危険度レベルが段階的に設定されている．もっとも初期の予報レベルとして水防団待機水位が定められており，水防活動の準備を始める目安となっている．本研究で対象とする A 川の B 地点では，2001 年 1 月～2014 年 12 月までに水防団待機水位への到達は 46 回である．本研究では，これら 46 事例に関する基準水位への到達判定を予測対象とし，1～3 時間予測の再現精度を検証した．

連絡先：一言正之，日本工営株式会社 中央研究所，茨城県つくば市稲荷原 2304，029-871-2034，029-871-2022，hitokoto-ms@n-koei.jp

3. ANN 洪水予測モデルの概要

3.1 ANN モデルの概要

本研究では，洪水予測において最も実績例の多い階層型のネットワークを用いた．ネットワークの構成を図 1 に示す．ネットワークの学習にはバックプロパゲーション法を用いた．

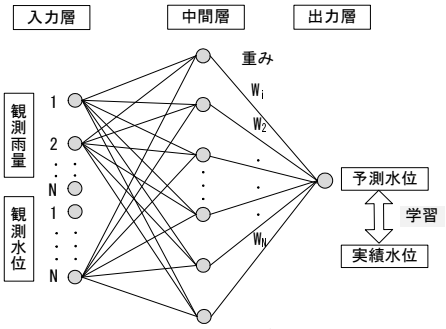

図 1: ニューラルネットワークの構成

3.2 相関分析による入力層データの選別

ANN モデルの入力層に用いる観測所を決定するため，B 地点の水位変化と相関の強い地点を選別した[Maier 2000，一言 2012]．ここでは，B 地点から最も近い水位観測所 C と，流域中央付近に位置する雨量観測所 D が選別された．B 地点と C 地点の水位変化の相関は，タイムラグが 2 時間の時に最も高くなり，これは C 地点から B 地点までの洪水流下時間に対応している．また B 地点水位変化と D 地点の雨量は，タイムラグ 6 時間で最も相関が高くなり，これは降雨-流出の時間に対応している．

3.3 ケーススタディによるによるネットワークの決定

(1) 学習対象データ

学習対象は 2004 年～2013 年の上位 12 洪水とした．各洪水のピークから前後 60 時間を 1 洪水とし，全部で 121 時間×12 洪水=1452 時間分のデータを学習対象とした．

(2) ケーススタディの設定

最適な ANN モデルを構築するため，ケーススタディを実施した．ケーススタディの組合せを表 1，表 2 に示す．表 1 において，

$\Delta H_{地点名(-t)}$：ある地点での時刻(-t-1)～(-t)における水位変化，$R_{地点名(-t)}$：ある地点での時刻(-t)における時間雨量，を表わす．例えば，$\Delta H_{B(-1)}$ は，B 地点での 2 時間前～1 時間前における水位変化を表す．ケース 1 では，予測地点における直近 2 時間分の水位変化，上流 C 地点における 2 時間分の水位変化，雨量観測所 D 地点における 3 時間分の雨量とした．ケース 2 では，入力層の雨量データを減らして 1 時間分のみとした．なお，予測は 1～3 時間後まで行い，2,3 時間予測の入力層の一部には予測モデル自身の予測データを用いるものとした．

表 1: 入力層データの組合せケーススタディ表

ケース	出力層	入力層
1	$\Delta H_{B(0)}$	$\Delta H_{B(-1)}$, $\Delta H_{B(-2)}$, $\Delta H_{C(-2)}$, $\Delta H_{C(-3)}$, $R_{D(-5)}$, $R_{D(-6)}$, $R_{D(-7)}$
2	$\Delta H_{B(0)}$	$\Delta H_{B(-1)}$, $\Delta H_{B(-2)}$, $\Delta H_{C(-2)}$, $\Delta H_{C(-3)}$, $R_{D(-6)}$

表 2: 中間素子数・学習回数のケーススタディ表

中間素子数	学習回数
1～20 (20 ケース，1 刻み)	25～300 (12 ケース，25 刻み)

(3) ケーススタディによる ANN モデルの決定

対象 12 洪水に対して，4 分割交差検定によりケーススタディを行った．予測水位と実測水位との RMSE（Root Mean Square Error：二乗平均平方根誤差）がもっとも小さくなったケース（入力層組合せ 2，中間素子数 7，学習回数 50）を最適な ANN モデルとして決定し，以下の検討に用いた．

4. ANN 洪水予測モデルの精度検証

4.1 単一学習モデルの再現計算

分割交差検定に用いたデータセットの一つを利用して学習器を作成し，2001 年 1 月～2014 年 12 月の検証期間に対して 1 時間ごとの予測再現計算を行った．

4.2 アンサンブル学習モデルによる再現計算

学習用の 12 洪水データを用いてアンサンブル学習を行った．アンサンブル学習の方法として Bagging や Boosting といった手法があるが，本研究ではより単純に，学習用 12 洪水から 1 事例ずつ除いた 11 洪水からなるデータセットを 12 個用意した．それぞれのデータセットより，12 個の学習器を作成した．各学習器の算術平均をアンサンブル学習モデルの予測結果とした．

4.3 精度検証

水防団待機水位に到達した 46 回の洪水について，単一学習モデルとアンサンブル学習モデルの精度検証を行った．各モデルの適合率と再現率を表 3，表 4 に示す．アンサンブル学習の結果，各予測時刻で単一の学習器を上回る精度が得られた．アンサンブル学習モデルの結果を表 **5** および図 **2** に示す．

表 3: 予測時間ごとの適合率（%）

予測時間	単一学習	アンサンブル
1 時間予測	93.6	95.7
2 時間予測	67.3	78.7
3 時間予測	32.3	47.9

表 4: 予測時間ごとの再現率（%）

予測時間	単一学習	アンサンブル
1 時間予測	95.7	95.7
2 時間予測	71.7	80.4
3 時間予測	43.5	50.0

表 5: アンサンブル学習モデルの 3 時間予測と実績の対比

		実績	
		基準水位到達	基準水位未到達
予測	基準水位到達	23	25
	基準水位未到達	23	113637

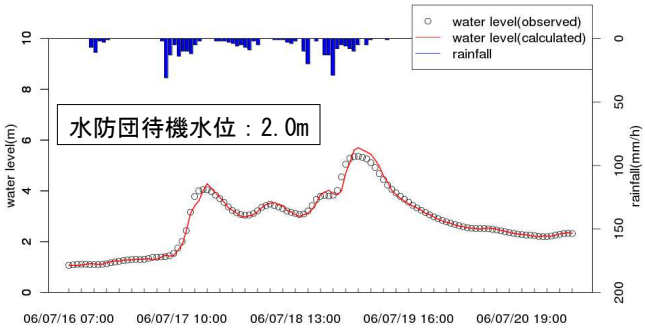

図 2:洪水予測結果の時系列（3 時間予測）

5. おわりに

本研究では，国内の 1 級河川を対象として，ANN による洪水予測モデルを構築し，アンサンブル学習を適用することにより精度向上を実現した．洪水予測では，防災上の安全側の判断が最優先とされるが，実際の判断は容易ではない．今後は，アンサンブル予測により幅を持った予測情報の適用性など，より活用しやすい予測情報の提供が課題として挙げられる．

参考文献

[ASCE Task Committee on Application of Artificial Neural Networks in Hydrology 2000] 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, 2000.

[Dawson 2001] Dawson, C. W., Wilby, R. L. : Hydrological modeling using artificial neural networks, Progress in Physical Geography,Vol.25, No.1, 2001.

[Maier 2000] H. R. Maier, G. C. Dandy：Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, Environmental Modelling & Software, Vol.15, 2000.

[Anctil 2004] Anctil, F., Lauzon, N.: Generalisation for neural networks through data sampling and training proceures, with applications to streamflow predictions, Hydrology & Earth System Science, 8(5), 2004.

[一言 2012] 一言正之，服部洋佑，梶正範，小野寺勝，桜庭雅明：斐伊川を対象としたニューラルネットワーク洪水予測の精度向上に関する研究，河川技術論文集，第 18 巻，2012.