

# 深層学習の基礎となるニューラルネットワークを用いた実時間洪水予測 Real time flood forecasting using Artificial Neural Network as a basis of Deep Learning

○窪田 薫, 田中丸治哉, 多田明夫

○Kaoru KUBOTA, Haruya TANAKAMARU and Akio TADA

**1. はじめに** 近年, 深層学習が注目され, 様々な分野に普及しつつあるが (岡谷, 2015), その背景として比較的簡単にプログラムを組むことができるプラットフォームが整備されたことが挙げられる. 水文学の分野でも流出予測に深層学習が適用されている (一言ら, 2016). これまでの概念的流出モデルにフィルタリングを組み合わせたシステムは, 流出予測の正攻法と言えるが, その構築にはある程度の水文学的知識を要する. 一方, ニューラルネットワーク (Artificial Neural Network, 以下 ANN) やそれを拡張した深層学習による流出予測は, ブラックボックス型でシステム構築が比較的容易であり, 水文学的な知見もそれほど必要としない. ただし, 深層学習の流出予測への適応性や深層学習の導入効果を明らかにするためには, 適用事例の蓄積が必要である.

本研究は, 深層学習の実時間洪水予測への適応性を明らかにすることを目的としているが, その第一段階として, 深層学習の基礎となる ANN を実時間洪水予測に適用し, 河川流量の予測精度を検討した.

**2. ANN の概要** 一般的な ANN は, 入力・中間・出力層の 3 層構造で, 中間・出力層にはノードが存在する (Fig.1). ノードでは, 前層から出力された値に重み係数を乗じてバイアスを加算したものを次の活性化関数で変換したものを出力とする (Fig.2).

$$f(u) = \frac{1}{1 + \exp(-u)} \quad (1)$$

ここに,  $u$  はノードにおける入力値である. 重み係数  $\omega$  とバイアス  $\theta$  の決定 (学習) は, 最終出力値と観測値の誤差を表す次式を小さくすることで行う.

$$E(\omega, \theta) = \frac{1}{2} \sum_{n=1}^N (Y_{obs} - Y_{cal})^2 \quad (2)$$

ここで,  $E(\omega, \theta)$  は誤差関数,  $Y_{obs}$  は観測値,  $Y_{cal}$  は出




Fig.1 ANN の構造  
Structure of ANN




Fig.2 ノードの構造  
Structure of Node

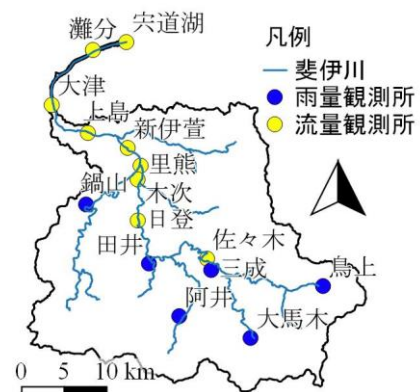


Fig.3 斐伊川流域の概要  
Overview of the Hii River basin

(所属) 神戸大学大学院農学研究科 Graduate School of Agricultural Science, Kobe University

(キーワード) 深層学習, ニューラルネットワーク, 実時間洪水予測

力値,  $N$  はデータ数である. 誤差関数の最小化には, 次の勾配降下法を用いる.

$$\omega^{(t+1)} = \omega^{(t)} - \eta \nabla E(\omega, \theta), \quad \theta^{(t+1)} = \theta^{(t)} - \eta \nabla E(\omega, \theta) \quad (3)$$

ここに,  $\eta$  は学習率,  $t$  は学習回数である.


**3. 実時間洪水予測への ANN の適用結果** 対象流域: 島根県東部に位置する斐伊川流域を対象とする. 斐伊川の概要を Fig.3 に示す. 斐伊川流域の計画基準地点である上島流量観測所における 6 時間先までの河川流量を予測する. 上島の流域面積は 894.80km<sup>2</sup> である.

**水文データ:** 上島の流量と相関が強い観測値を入力データとして用いた. ここでは, 上島の流量 5 時間分, 木次の流量 5 時間分, 上島上流の流域平均雨量 10 時間分の計 20 個を入力値として採用した. 上島の比流量が 1m<sup>3</sup>/s/km<sup>2</sup> を超える 16 出水の内, 13 出水を同定データ, 残りの 3 出水を検証データとし, 検証データには既往最大出水が含まれる.

**パラメータ同定:** 中間層のノード数には {1, 2, ..., 40} の 40 通り, 学習率には {0.01, 0.05, 0.1, 0.25} の 4 通りを検討し, 中間層ノード数に 25, 学習率に 0.05 を採用した. 学習回数は最大で 100,000 回とした. 重み係数とバイアスの初期値は (0, 1) の一様乱数から決定し, 乱数の種は 10 通り用意したが, その内で最も予測精度が良かったケースを採用した.


**結果と考察:** 1 時間先予測における学習回数と RMSE の関係を Fig.4(a) に示す. 学習は 30,000 回程度で十分であることが分かった. 検証データ 3 出水平均で求めた各予測先行時間の RMSE を Fig.4(b) に示す. 当然のことながら予測先行時間が長くなると精度が低くなる. 既往最大出水の 3 時間先及び 6 時間先予測結果を Fig.5 に示す. 3 時間先予測の結果は良好であるが, 6 時間先予測ではピーク付近の流量が過小推定となった. 予測雨量を使用していないことを考えれば, 全般的に見て ANN の予測精度は概ね良好である.

**4. 深層学習の適用に向けて** 深層学習は, 本質的な考え方は ANN と変わらないが, 通常 1 層とする ANN の中間層を複数設けた構造となっている. 本研究では, ANN による洪水予測精度を検討したが, 今後, 深層学習を用いた実時間洪水予測を行い, ANN による予測精度と対比することで, 深層学習の導入効果を明らかにする.



**Fig.4** ANNによる洪水予測精度

Estimation error of flood forecasting by ANN  
(a)同定データにおける学習時間と RMSE の関係 (1 時間先予測), (b)検証データにおける予測先行時間と RMSE の関係



**Fig.5** 既往最大出水における流量予測結果

Flood forecasting in the largest flood event

3 時間先: RMSE 107m<sup>3</sup>/s, RE 12.0%

6 時間先: RMSE 264m<sup>3</sup>/s, RE 26.6%

**参考文献** 岡谷貴之 (2015): 深層学習, 講談社, 一言正之, 櫻庭雅明, 清 雄一 (2016): 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), 72 巻 4 号, pp.I\_187-I\_192