

## 転移学習を実装した畳み込みニューラルネットワークによる

### 洪水イベントの水位予測手法の開発

#### Development of a flood prediction model using convolutional neural network with a transfer learning approach.

○木村延明\*・吉永育生\*・関島建志\*・安瀬地一作\*・馬場大地\*\*

○Nobuaki KIMURA・Ikuo YOSHINAGA・Kenji SEKIJIMA・Issaku AZECHI・Daichi BABA

## 1. はじめに

近年急速に発達してきた深層ニューラルネットワーク（Deep Neural Network, 以下 DNN という）を用いて、排水機場遊水地や河川の水位などの高精度な予測が可能な洪水モデルの開発が進められている。しかし、予測精度の向上のために大量データによるモデルのパラメータの調整（以下、学習という）が必要なことに加え、学習時間がかかることが課題である。これらを解決するために、大量な観測データを有する流域（ソース流域）で事前に学習したモデルを少ない観測データを有する流域（ターゲット流域）で再利用する方法である転移学習を用いる。本研究では、転移学習を導入した DNN を用いて、ターゲット流域の洪水予測を行う際に、少量データでも、より高精度な予測が可能で、且つ DNN の学習時間が短縮できる新たな洪水予測手法を開発する。

## 2. 方法

### 2.1 研究対象流域と入力データ

転移学習を用いるために、図1のようにソースとターゲットの流域をそれぞれ選定する。なお、これらの流域では、人為的な操作で河川水位が変化するような治水ダムなどの大規模構造物が存在しないものとする。入力データは、水位と降雨量を変数とし、ソース流域では過去30年間に発生した洪水イベントのデータ（43イベント）と、ターゲット流域では比較的少ないデータ（17イベント）を利用する。なお、一イベントあたり1時間毎で5日間分の連続観測データを有する。

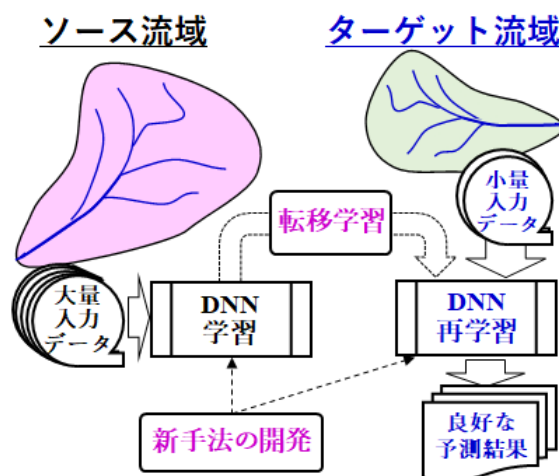


図-1 転移学習の概念とデータフロー図  
Concept & data flow of transfer learning

### 2.2 深層ニューラルネットワーク(DNN)

本研究では DNN として、動植物等の画像分類に頻繁に利用される畳み込みニューラルネットワーク（Convolutional Neural Network, 以下 CNN という）を採用する。CNN を利用する利点は、複数の観測データを2次元の画像に変換し、流域の疑似空間情報を用いた学習が可能なることに加え、CNN の転移学習は多くの実績を有するからである。

### 2.3 水位予測方法と予測精度の検証方法

洪水イベントの情報は、観測点での時系列データであり、時間軸方向の線情報と見なせる。そこで、各観測点における複数の時系列データを並べることで面情報を生成

\* 農研機構－農村工学研究部門 The Institute for Rural Engineering, NARO

\*\* (株)アーク情報システム ARK Information Systems, INC.

キーワード 洪水流出, 河川工学, 転移学習, 畳み込みニューラルネットワーク

する。この面情報から切り出された小領域の画像を入力値、数時間後の予測地点の値を出力と定義し、1時間毎に小領域をシフトしながら相互の関係を CNN で学習する。

まず、ソース流域の多くのデータで CNN の学習を行う（学習回数=100回）。この事前に学習された CNN を用いて、ターゲット流域の水位予測のために転移学習を行う。

CNN は複数の層からなるネットワーク構造（図 2a）をもつが、本研究の転移学習（図 2b）では、全結合層 1, 2 のみを再学習する（学習回数=0~20回）。予測精度の検証方法は、学習・バリデーション・テストのプロセスを通して行われる。ネットワーク内のパラメータを調整するために、流域の 1~3 番目までの大きな洪水イベントと 2 つの中程度の洪水イベントを除いた残りのイベントに対して学習を行う。学習結果の妥当性を確認するために、過去 2, 3 番目に大きな洪水イベントと 2 つの中規模イベントについてバリデーションを実施する。モデルの汎用性の確認は過去最大の洪水イベントを用いてテストを行う。転移学習の効果を評価するために、ソース流域で事前学習したモデルを再学習してテストを行う。誤差評価には二乗平均平方根誤差 (RMSE) と Nash-Sutcliffe 係数 (Ns) を用いる。これらの詳細は先行研究<sup>1)</sup>を参照されたい。

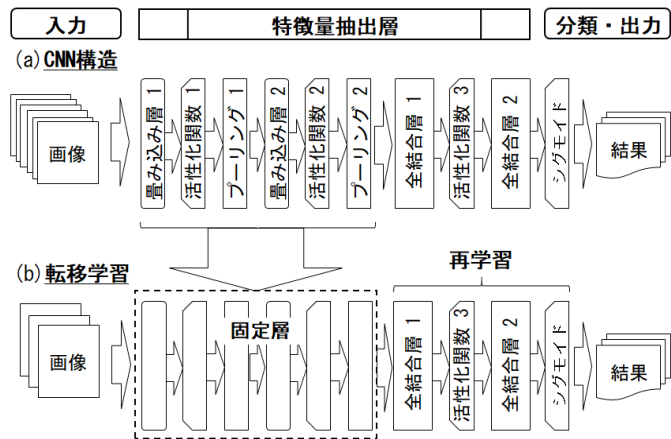


図-2 CNN の構造と CNN の転移学習  
CNN structure and CNN with transfer learning

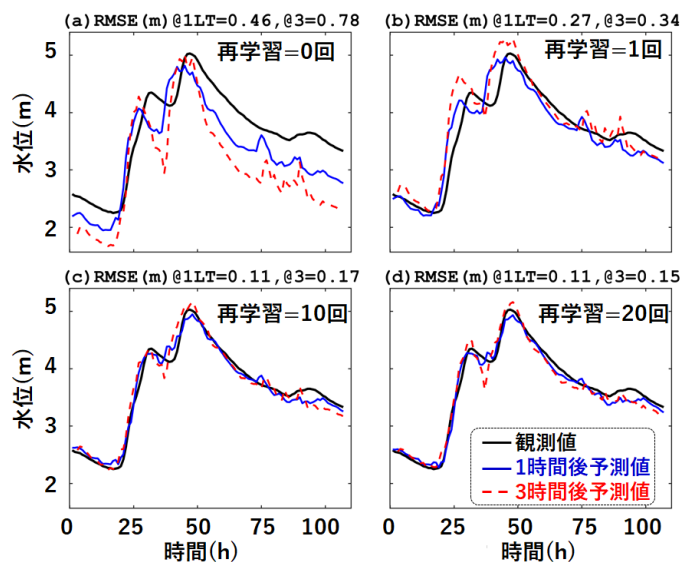


図-3 再学習(1~20回)の水位予測(1,3時間後)と観測値  
Retrained and observed water levels in 1 and 3 lead times

### 3. 解析結果とまとめ

ターゲット流域の過去最大の洪水イベントについて、再学習後の 1, 3 時間後の水位予測結果と観測データの比較を図-3に示す。再学習 0 回では、直近の 1 時間後の予測結果であっても RMSE の値は大きい（図-3a）。しかし、再学習回数が 10 回以上になれば、良好に観測値を再現できた。再学習 20 回の Ns は、1, 3 時間後予測において、それぞれ 0.98, 0.96 の値を示した。また、転移学習なしの予測結果と比較して、1 時間後の RMSE は約 20% の減少になったものの、3 時間後では約 10% の増加に転じた。学習時間では、CNN は比較的シンプルな構造をもつので、ほぼ学習回数にかかる時間に匹敵し 1/5 に削減された。転移学習を導入した CNN による洪水予測手法は、直近の予測に有効であることを示した。

参考文献: 1) Kimura, N., I. Yoshinaga, K. Sekijima, I. Azechi, and D. Baba (2020) Convolutional neural network coupled with a transfer-learning approach for time-series flood predictions. Water, 12(1), 96.