

O-030

## 微分方程式をベースとした AI による中規模流域をターゲットとした洪水予測 Flood Forecasting Targeting Medium Scale Watershed by AI based on Differential Equation

岡田 治, 中安 正晃, 佐々木 一英, 清新, 此島 健男子†

Osamu Okada, Masaaki Nakayasu, Kazuhide Sasaki, Arata Sei, Konoshima Takehiko

### 1. はじめに

洪水予測を AI で行う既存研究があるが、未学習の降雨事例で精度が低下する等の問題がある。我々は流出モデルのひとつである 3 段タンクモデルの微分方程式を差分化し、Keras、TensorFlow、Python、CUDA、GPU を用いて AI を実装している。レーダ雨量を入力データ、流出量を出力データに用いて流出モデルのパラメータ同定と流出量を高精度で再現計算できることを報告済である [1]。流出現象の複雑さ、例えば土砂の堆積、樹木の繁茂、蒸発散、地下浸透、土壤水分量の変化等を反映し、流出モデルのパラメータは降雨事例毎に変動することが知られている。このため、集中型、分布型の流出モデルの種類によらず、過去の降雨事例を用いたキャリブレーションが必要であるが、特にパラメータの確率分布に対処する手法は技術者とコンサル会社のノウハウともされ明らかになっていない。この研究では、報告済みの微分方程式と AI の融合による流出計算技術を 1 段目の AI として用い、この AI で計算した流出量をアンサンブル学習用の 2 段目の AI に入力して学習させることにより、流出量を機械的かつ自動的に計算できる技術を開発したのでその手法と計算結果の例を報告する。

### 2. 微分方程式を組み込んだ AI で流出モデルのパラメータを降雨事例毎に同定する

AI による回帰と予測を論じる際、AI が汎用的な関数近似器であることを認識する必要がある。関数の関数、行列の掛け算の繰り返しは AI の分散処理のモデルであ

り、逆誤差伝搬法による優れた最適化技術により、深層でも重みとバイアスの最適化が可能となっている。AI の社会実装に向けてこのことを正しく認識する必要がある。関数が大域的な関係を記述するのに便利な道具である一方、微分方程式は局所的で簡潔な自然法則等を反映し、微小変化から大域的变化を逐次計算するのに便利な道具である。これは AI が自然法則をデータのみから学習困難であることを示唆する。トロント大の Ricky T. Q. Chen らは、NeurIPS2018 でアドジョイント法を用いた AI による微分方程式の解法を示した。2019 年、AI と微分方程式を組み合わせたシミュレーション技術の研究が注目されている。図 1 (左) に報告済みの微分方程式を組み合わせた AI を示す。中心付近が 3 段タンクモデルの微分方程式を差分化し計算グラフで表現したものである。横方向に 1000 タイムステップ分ニューロンが繰り返す。貯留高を保持するニューロン、浸透量、流出量を保持するニューロン、外力としての 1 タイムステップ内の降水量、貯留高の変化と浸透量、流出量、降水量との局所的な関係を表現する。周辺付近のニューロンが流出係数、浸透係数、有効雨量を表現し、全タイムステップで重みを共有し、入力データと出力データを用いて誤差を最小化する過程で重みを学習する。図 2 (左) にパラメータ間の相関係数をヒートマップで示す。白い部分が正の相関が強い部分である。浸透係数 (左上隅) と 2 段目タンクの流出係数に正の相関がある。相関はパラメータが多価性を持ちモデルが良くないことを示唆する。

### 3. 降雨事例毎の AI で計算した流出量をスタックアンサンブル法により混合する

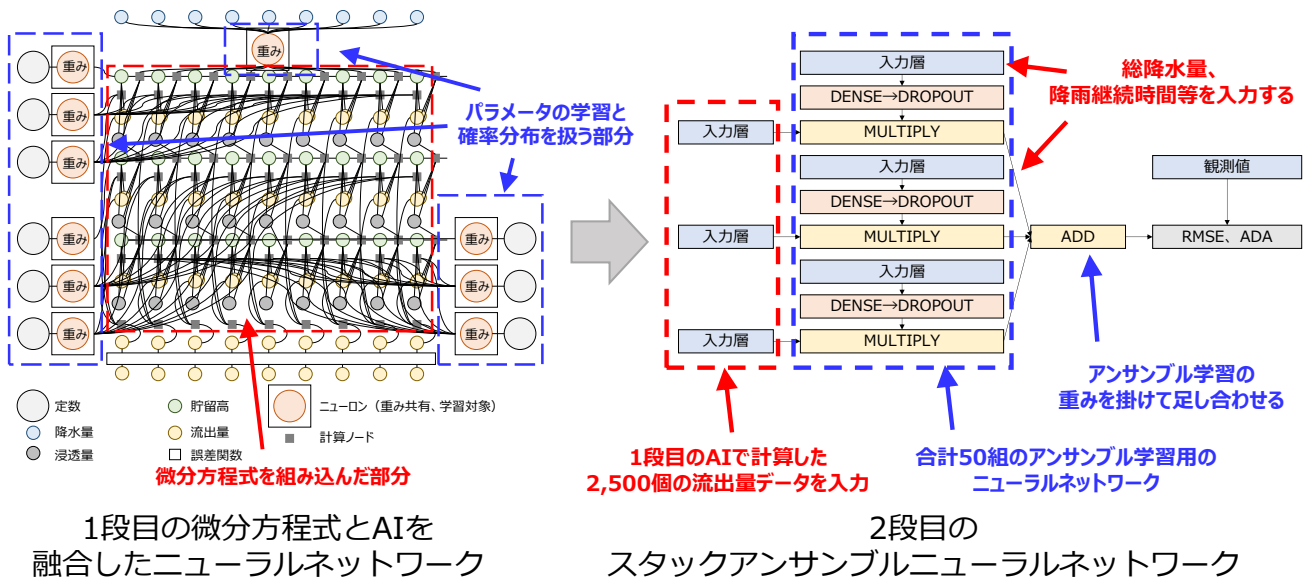


図-1 左：微分方程式と AI を融合したニューラルネット、右：スタックアンサンブル AI

†一般財団法人河川情報センター  
Foundation of River & basin Integrated Communications

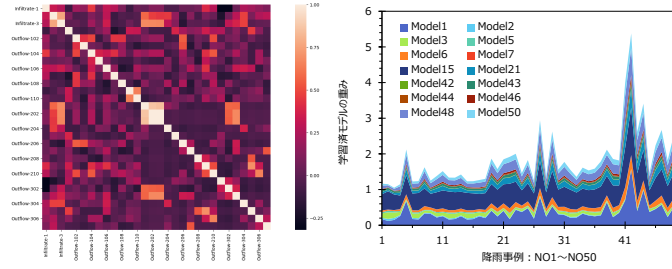


図-2 左：パラメータ間の相関係数のヒートマップ、右：スタックアンサンブル AI で学習したアンサンブルの重み

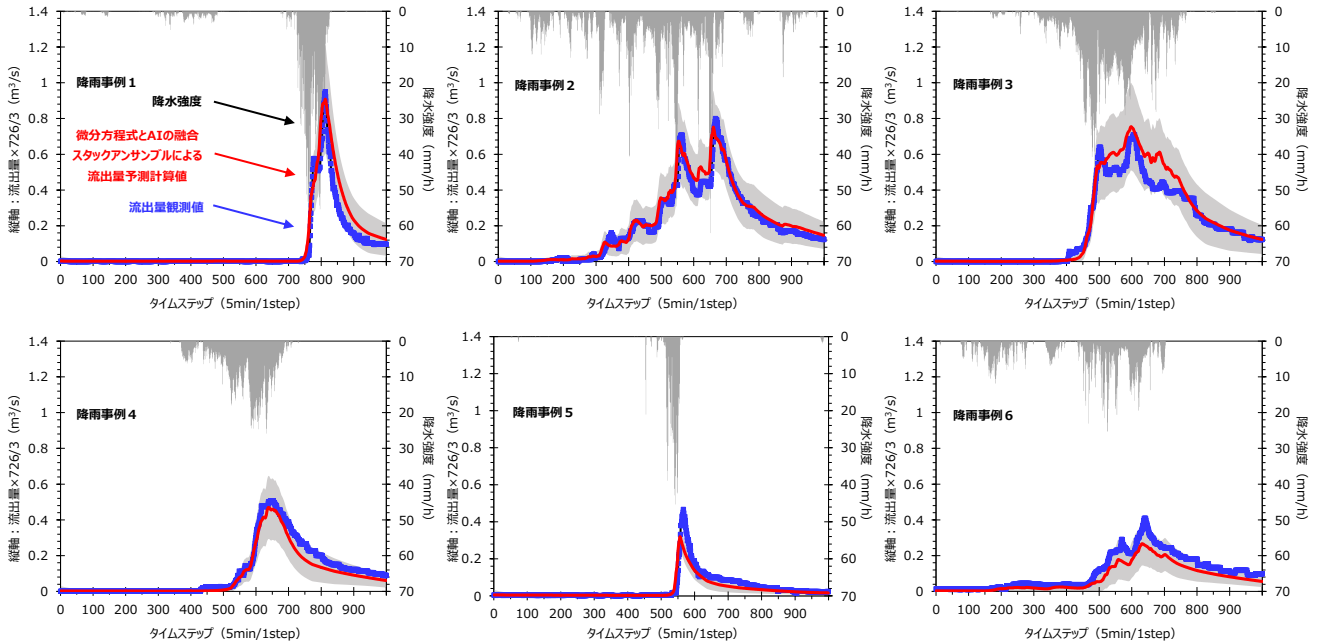


図-3 微分方程式と AI を融合したニューラルネットとスタックアンサンブル AI の 2 段階で計算した予測流出量

図 1 (右) にスタックアンサンブル学習を行う AI を示す。スタックアンサンブル学習は Kaggle 等の AI 競技会で上位入賞チームが頻繁に用いる手法である。図 1 (左) の微分方程式と AI を融合したニューラルネットワークを用い、降雨事例 50 個のデータから最適なパラメータを合計 50 組同定する。図 1 (左) の AI を用い、降雨事例 50 個のレーダ雨量と最適化したパラメータ合計 50 組から合計 2,500 個の流出量データを計算する。図 1 (右) の AI を用い、2,500 個の流出量データを入力データ (図の左側の層に入力)、50 個の観測した流出量データを入力データ (図の右上の層に入力) とし、各パラメータの組の重みを学習、つまり予測性能に優れるパラメータの組を自動的に抽出する。学習時、パラメータ同定に使用した降雨事例を再度学習しないように学習過程から除外することが、過学習防止と予測性能向上に重要である。また、総降水量、1/総降水量、降雨継続時間、1/降雨継続時間、総降水量×降雨継続時間を図の上側の層に入力する。流出モデルのパラメータが大規模降雨事例と小規模降雨事例で異なるという傾向から学習し、予測精度向上を目標とする。学習用ニューラルネットワークは、入力 5 次元、1 層目 1,000 次元、2 層目 1,000 次元の全結合接続とし、過学習防止のためドロップアウト層 (ドロップアウト率: 0.1) を含める。図 2 (右) に 2 段階目のスタック

アンサンブル AI で学習した重みを示す。降雨事例毎に重みが異なり、50 降雨事例の内、予測性能向上に寄与すると思われる 14 降雨事例のパラメータの組を自動的に抽出した。ドロップアウト層を用いないと過学習が発生し、抽出するパラメータの組が 2 組等と減少し、過学習でよく見られるように予測精度が低下する。

#### 4. 結果と考察

図 3 にこの研究で開発した AI の予測計算の結果 (降雨事例 50 個の内、比較的総降水量、ピーク流出量が多い 6 事例を示す。) 青線が流出量の観測値、赤線が流出量の予測計算の値、その周辺の灰色の範囲が 50 降雨事例のパラメータの組毎に予測計算した値の範囲 ( $2\sigma$ ) を示す。上部の棒グラフが降水強度である。

#### 参考文献

- 1) Okada, O., Kakizawa, K., Hirakuni, T., Nakayasu, M., Tadokoro, T., Sasaki, K.: Nonlinear Parameter Identification and Stochastic Outflow Calculation by AI based on Three-Stage Tank Model, *JSCE*, Received 2019/1/8.