

(12)

深層学習を用いた都市流出モデルのエミュレーションに関する一考察

東京都 建設局 江東治水事務所  
 首都大学東京大学院 都市基盤環境学域  
 首都大学東京大学院 都市基盤環境学域  
 東京都 土木技術支援・人材育成センター

○藤塚 慎太郎  
 河村 明  
 天口 英雄  
 高崎 忠勝

1. はじめに

都市域では降雨から流出までの時間が短く、河川水位を事前に精度良く予測する手法の開発が重要であるが、都市流域の複雑な流出機構を精度良くモデル化することは困難であり、簡易で精度が良い都市流出予測モデルの開発が課題となっている。近年、深層学習技術の向上にともない第三次 AI ブームと呼ばれるほど人工知能 (AI) 技術の発展がめざましく、様々な分野への応用が進められている<sup>1)</sup>。人工知能技術を応用した深層学習モデルはデータ (学習・教師) があれば、自動的にモデルのパラメータを調整してくれることから、モデルの構築が容易である。洪水予測分野においては、過去の洪水事例の観測データを用いて、ニューラルネットワークや深層学習を用いた予測モデルの研究が試みられているが<sup>2)</sup>、流域ごとに実測データを用いるため、異なるデータによりモデルが構築されている。しかし、一般に深層学習モデルの入力データセットが異なる場合、モデルの誤差要因を切り分けることが困難であり、適切なモデルの精度評価ができない。

そこで、本研究では著者ら<sup>3)</sup>が構築した都市流出モデルを深層学習モデルでエミュレーションできるか確認することを目的として、都市流出モデルの入力降雨を入力層に与え、都市流出モデルを介した出力結果を出力層に与え、深層学習モデルを構築し、深層学習モデルのエミュレーション性能を評価した。

2. 使用データおよび深層学習モデル

著者らはすでに深層学習モデルに入力するための流出モデルに与える模擬の入力降雨(バーチャルハイトグラフ(以下、VH とする))と、模擬の入力降雨を都市貯留関数(USF)モデルに与えた場合の流出量(バーチャルハイドログラフ(以下、VQ とする))を作成し<sup>4)</sup>、公開している。VH・VQの詳細については文献<sup>4)</sup>を参照されたい。VHは対象期間を24時間とし、ランダムカスケードモデルを用いて1分雨量の時間分布を発生させている。また、VQはVHを都市貯留関数(USF)モデルに入力し、流出計算を実施した結果を用いている。USFモデルは都市貯留関数モデルであり、流出機構が複雑な都市中小河川の予測に適した集中型概念モデルである。VH・VQは模擬発生データであるため、入力データ(洪水イベント数)の増減が容易であり、学習洪水イベント数と精度の関係を把握することができる。VHおよびVQは100洪水作成し、80洪水はキャリブレーション(学習、テスト)データに使い、20洪水はバリデーション(検証)データとして使用することとした。データの偏りをなくすため、VQのピーク流出高を基準に、20洪水毎に様々な規模の洪水が入るように並び替えを実施したものをVQ(1)~VQ(100)とし、それに対応したVHをVH(1)~VH(100)としている。

深層学習モデルは図-1に示すように中間層を2層とした深層学習モデルとし、入力層は180ノード(VHのうち現時刻~179分前の1分間雨量)、出力層は1ノード(VQのうち現時刻流出高)とし、中間層1・




図-1 モデル構造

表-1 その他の学習の設定

種別	設定内容
目的関数	RMSE
活性化関数	ReLU関数
勾配法	Adam
ドロップアウト	しない
ミニバッチサイズ	50

表-2 CASE 毎の学習洪水数

ケース	学習洪水数
CASE1	60 (VQ(1)~(60))
CASE2	40 (VQ(1)~(40))
CASE3	20 (VQ(1)~(20))
CASE4	10 (VQ(1)~(10))
CASE5	1 (VQ(1))

2はそれぞれ90ノードで設定した。その他の学習の設定は表-1に示すとおりである。本研究では学習洪水数を減少させた場合のエミュレーション性能を確認するため、表-2に示ようにCASE1の60洪




図-2 CASE3 と CASE5 における検証用洪水 (VQ(81)) の再現波形

水をベースとして、学習洪水数を減少させた 5 ケース設定した。また、学習は 1 万エポック (1 エポック=入力データを 1 通り学習) 実施した。

### 3. 結果および考察

図-2 の(a)および(b)に各ケースの学習モデルのうち CASE3 と CASE5 の、検証用洪水のピーク流出高が最も大きい VQ(81)の再現波形を示す。また、図-3 に学習洪水数と RMSE (二乗平均平方根誤差) および Nash-Sutcliffe 係数 (以下、NS 係数とする) の関係を示す。




図-3 学習洪水数と誤差の関係

目視による波形の確認の結果、図-2 (a) の場合 (CASE3・20 洪水学習) は VQ と深層学習モデルの再現波形はほとんど一致しており、図-2 (b) の場合 (CASE5・1 洪水学習) でも若干ピーク流出高を過小評価してはいるものの、深層学習モデルで都市流出モデルを精度良くエミュレーションできていることがわかった。図-3 より学習洪水数と精度の関係を見ると、まず学習用洪水である洪水イベント 1 の再現結果 (図中●○) では学習洪水数の減少に従い RMSE が上昇し (NS 係数が低下し)、精度が低下している傾向であった。特に学習洪水数が 20 洪水未満の場合はそれ以上の洪水数と比較し、精度の低下が見られた。ただし、CASE5 では学習用洪水の精度が向上しており、これは学習した 1 洪水に最適化された過学習の状態であると考えられる。次に、検証用洪水である洪水イベント 81 の再現結果 (図中▲△) においては、同様に学習洪水数の減少に従い、精度が低下している傾向であった。ただし、RMSE の値は CASE5 でも 0.040 以下と流出規模に比較して非常に小さく、十分にエミュレーションできているといえる。

以上より、学習用洪水が 1 洪水でも深層学習モデルで都市流出モデルをエミュレーションすることが可能であるが、入力データが 20 洪水ごとに偏りが無いことを考慮すると、様々な規模を一通り学習できる 20 洪水程度学習することで、非常に精度良くエミュレーションすることが可能であると考えられる。

### 4. まとめ

本研究では、深層学習モデルを用いた都市流出モデルのエミュレーション性能を確認するため、VHとVQを用いて深層学習モデルを構築した結果、学習用洪水が20洪水以上の場合に非常に精度良く、また1洪水の場合でも精度良く、深層学習モデルで都市流出モデルをエミュレーションすることが可能であった。今後はその他のハイパーパラメータを変更した場合のエミュレーション性能について研究を実施していく予定である。

### 参考文献

- 1) 深層学習は土木を変える？-AI活用の可能性を探る-, 土木学会誌, Vol.103, No.2, pp.7-37, 2018.
- 2) 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), 72 巻, 4 号, p. I\_187-I\_192, 2016.
- 3) 高崎忠勝, 河村明, 天口英雄, 荒木千博: 都市の流出機構を考慮した新たな貯留関数モデルの提案, 土木学会論文集B, Vol.65, No.3, pp.217-230, 2009.
- 4) 藤塚慎太郎, 河村明, 天口英雄, 高崎忠勝: AI を用いた都市流出モデルエミュレーションのためのベンチマーク模擬ハイドログラフの構築, 第46回土木学会関東支部研究発表会講演集, CD-ROM版, 2019. (VH・VQ: <http://www.comp.tmu.ac.jp/suimon/virtual/>よりダウンロード可能)

キーワード : AI, Deep Learning, urban runoff, emulation, benchmark data