

都市中小河川実流域データセットを用いた 深層学習モデルの入力層ノード数および中間層数が降雨流出予測に及ぼす影響特性

東京都立大学 都市環境科学研究科 学生員○ 川野 正裕
 東京都立大学 都市環境科学研究科 正会員 河村 明
 東京都建設局 正会員 藤塚 慎太郎
 東京都立大学 都市環境科学研究科 正会員 天口 英雄

1. はじめに

近年、都市型水害が社会問題となっており、その対策として精度の良い流出予測手法の開発が望まれているが、都市流域特有の流出機構の複雑さにより、流出機構を簡易に精度よくモデル化することは非常に困難な状況にある。また、AI(人工知能)技術の向上により、第三次 AI ブームと呼ばれるほど様々な分野への応用が進められている。土木分野においても AI を用いた検討が数多く行われており¹⁾、降雨流出予測の分野においても過去の降雨流出事例の観測データを用いて、ニューラルネットワークやディープラーニング(深層学習)を用いたモデルの構築が行われている²⁾。しかし、その多くは大河川流域の 1 時間毎の観測データを対象としており、東京都などの都市中小河川での 1 分毎の観測データを活用した深層学習の事例はあまり見受けられない。また著者らは AI 降雨流出ベンチマークテストに向けた都市中小河川実流域データセットを作成³⁾し公開している。

そこで本研究では作成した都市中小河川実流域データセットを用い、深層学習モデルを構築し、深層学習モデルの性能に影響を及ぼす調整可能なパラメータであるハイパーパラメータが降雨流出予測に与える影響特性を確認した。




図-1 モデル構造

2. 使用データおよび深層学習モデル

AI 降雨流出ベンチマークテストに向けた都市中小河川実流域データセットの詳細については文献 3) を参照されたい。データセットは時系列順に 100 洪水整理されており、これを Ev(1)～Ev(100)と呼ぶこととする。

図-1 に中間層数が L の場合の深層学習モデルの概念図を示す。入力層ノード数を N_a とした場合、入力層に現時刻～(N_a-1)分前の降雨を、出力層に現時刻の流出高を入れ、学習を行っていく。本研究では入力層ノード数および中間層数を変化させた場合の再現性を確認するため、表-1 に示すように、入力層ノード数を 30 から 240 に変化させた 5 ケースと、中間層数 1～3 層の 3 ケースを組み合わせた 15 ケースについて検討した。また表-1 にはこの場合の深層学習モデルが同定する未知パラメータの数も合わせて併記している。中間層ノード数の合計は 30 に固定し、各中間層のノード数は 30 を中間層数で除する値とした。その他の学習の設定を表-2 に示す。最適な重みの値は 1,000 エポックまで学習を行ったうち検証 RMSE が最小となったエポックにおける値とした。学習洪水イベントは 1 イベントとし、ケース毎に Ev(1)～Ev(100)で学習を行い、モデルを 15 ケース×100 洪水で 1,500 個構築し、そのうち一番ピークの大きい Ev(46)で学習を行ったモデルを除いた 1,485 個のモデルにおいて Ev(46)で検証精度を評価した。

表-1 ケース毎の入力層ノード数、中間層数とパラメータ数

ケース	入力層ノード数	中間層数	未知パラメータ数
1-A	30	1層(30)	961
1-B		2層(15x15)	721
1-C		3層(10x10x10)	541
2-A	60	1層(30)	1,861
2-B		2層(15x15)	1,171
2-C		3層(10x10x10)	841
3-A	120	1層(30)	3,661
3-B		2層(15x15)	2,071
3-C		3層(10x10x10)	1,441
4-A	180	1層(30)	5,461
4-B		2層(15x15)	2,971
4-C		3層(10x10x10)	2,041
5-A	240	1層(30)	7,261
5-B		2層(15x15)	3,871
5-C		3層(10x10x10)	2,641

表-2 深層学習のその他の設定

種別	設定内容
評価関数	RMSE (二乗平均平方根誤差)
活性化関数	ReLU関数
勾配法	Adam
ドロップアウト率	0%
ミニバッチサイズ	50

キーワード 人工知能、深層学習、都市中小河川、ベンチマークデータ、ハイパーパラメータ

連絡先 〒192-0397 東京都八王子市南大沢 1-1 首都大学東京 E-mail : kawano-masahiro@ed.tmu.ac.jp

3. 結果および考察

図-3 に一番ピークが大きい洪水イベント Ev(46)において学習精度が一番良かったケース 5-A および一番悪かったケース 1-C の学習洪水の再現ハイドログラフを、図-4 a) に検証精度が一番良かったケース 3-C および学習洪水が同じで一番精度が悪かったケース 1-C の検証洪水の再現ハイドログラフを示している。また検証精度が一番悪かったケースでは RMSE が 0.415 と他のケースと比較し大きく外れており、外れ値であると考えられる、図-4 b) には検証精度が二番目に悪かったケースおよび学習洪水が同じで一番精度が良かったケースの検証洪水の再現ハイドログラフを示す。図-5 に各ケースのパラメータ数と学習洪水および検証洪水の RMSE の比較を示す。

図-3 より、一番精度が良かったケース 5-A(図中赤線)はベンチマークハイドログラフ(図中黒線)と重なっている。また、1-C(図中黄線)でもおおむね重なっており、大変精度よく学習できていることがわかる。図-4 a) より、全体で一番検証精度が良かった Ev(17)で学習したケース 3-C(図中赤線)ではおおむねハイドログラフを再現できているが同じ Ev(17)で学習したケース 1-C(図中緑線)では全く再現できていない。図-4 b) より、全体で2番目に検証精度が悪かった Ev(56)で学習したケース 1-C(図中緑線)では全く再現できておらず、同じ Ev(56)で学習したうち一番検証精度が良かったケース 3-C(図中赤線)でも精度よく再現できているとは言い難い。図-5 より、ケース 1・2 と 3~5 を比較すると、学習(オレンジ)、検証(青)ともに入力層ノード数が 60 以下では 90 以上と比べ予測精度が悪くなっており、今回の場合では現時点から 60 分以下のデータでは予測精度が悪くなることが考えられる。また、学習精度を見るとパラメータ数の増加に伴い、精度が良くなる傾向にあるが、ケース 5-C(パラメータ数 2,641)と 4-B(パラメータ数 2,971)等、パラメータ数が近い場合は3層のモデルにおいて精度が良くなっている傾向にある。更に検証精度を見るとケース 3-C(パラメータ数 1,441)において中央値の精度が一番良くなっており、そこからパラメータ数の増加に伴って、精度が悪化している傾向にある。

以上より、入力層ノード数が 30 以上であれば学習イベント数が 1 イベントでも精度の良い学習は可能であり、精度はパラメータ数の増加に伴って良くなる。また、検証ではケース 3-C(パラメータ数 1,441)の際に一番精度が良くなっており、パラメータ数が 1,441 より増えると精度が悪化する傾向であった。しかしケース 3-C であっても RMSE が 0.1 を超えているような図 4 a) のケース 1-C と同程度のハイドログラフの再現精度のモデルもあり、学習イベント数が 1 イベントでは検証の性能に限界があると考えられ、今後は学習イベント数を増やした場合の再現精度について検討する必要がある。

4. まとめ

本研究では、都市中小河川実流域データセットを用い、深層学習モデルの入力層ノード数および中間層数が降雨流出予測に及ぼす影響特性を確認するため、実流域データセットを用いて深層学習モデルを構築した。その結果、今回の場合、パラメータ数の増加に伴い学習精度が向上すること、パラメータ数が近い場合は3層のモデルにおいて精度が良くなっている傾向にあることがわかった。しかし学習用洪水が1洪水の場合では、検証精度に限界があることもわかった。今後は学習イベント数を増やした場合や、その他のハイパーパラメータを変更した場合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, 石原成幸: AI 降雨流出ベンチマークテストに向けた都市中小河川実流域データセットの作成, 水文・水資源学会 2019 年度研究発表会要旨集, pp.28-29., 2019. (<http://www.comp.tmu.ac.jp/suimon/kanda/> よりダウンロード可能)




図-3 学習洪水の再現ハイドログラフ




図-4 検証洪水の再現ハイドログラフ




図-5 ケース毎のハイドログラフの再現精度