

複数の深層学習手法を用いた降雨流出モデリングの高精度化

熊本大学自然科学教育部 学生会員 横尾 和樹

熊本大学 くまもと水環境・減災研究教研究センター 正会員 石田 桂

熊本大学自然科学教育部 学生会員 永里 起義

1. 序論

近年、深層学習手法は画像処理や自然言語処理などの分野での適用が進み、水文学においても様々な事例で適用され始めている。国際的に深層学習手法を用いた降雨流出モデリングをはじめとする物理的解析に対し、深層学習手法を適用した研究が行われている。中でも、Kratzert et al.¹⁾の既往研究では寒冷地を対象とし、深層学習手法の1つであるLSTM(Long Short-Term Memory)²⁾を用いた降雨流出モデリングを行っていた。しかしながら、深層学習手法にはLSTMの他にも多数の手法が存在し、推定対象によっては精度が大きく低下する場合があることを考慮せず、解析を行っているように見受けられる。よって、本研究では寒冷地を対象に代表的な3つの深層学習手法を用いた降雨流出モデリングを行い、流量の推定精度を比較する。その中で、寒冷地を対象とした降雨流出モデリングに適した深層学習手法を探索する。

2. 手法

本研究では寒冷地を対象にLSTM, GRU, Traditional-RNNを用いた日単位の降雨流出モデルを構築する。また各手法の入力には日単位の降水量と気温の気象データを用い、任意の地点における日平均河川流量を出力とする。深層学習手法の学習過程には重みとバイアスの初期値に起因するランダム性により学習結果に差が生じるため、学習を100回行った。Early stoppingが作用した時点で学習を止め、過学習が始まる直前の学習結果のうち、検証期間で最も精度が高いものをモデルとして用いた。本研究では、上述3つの深層学習手法で訓練されたモデルに各気象データ（降水量、気温データ）を入力し、流量の推定精度を比較した。

3. 対象地・データ

本研究では、対象地を石狩川流域とする。石狩川は北海道中央部の大雪山系石狩岳を水源とし、大小70の河川が合流しながら石狩平野を流下し、日本海に流れ込む石狩川水系本流の1級河川である。流路長は268km、流域面積は14,330km²の全国有数の規模を誇る。石狩川流域では、冬の降雪が数ヶ月遅れて春先(およそ3月~5月)に流出し、この期間の流量が大幅に増加する。

降水量データは、Asian Precipitation - Highly Resolved Observational Data Integration Towards Evaluation of Water Resources (APHRODITE)³⁾から取得

表 1. 各種ハイパーパラメータ

ハイパーパラメータ	値・手法
IDL(入力データの長さ)	365
HSL (Hidden Size Layer)	50
バッチサイズ	256
Patience	30
Loss function	MSE
勾配降下法の最適化アルゴリズム	Adam
バッチ要素抽出方法	shuffle

し、石狩川の流域平均日降水量を求めた。APHRODITEは観測データを基にした日降水量グリッドデータである。空間解像度は5kmであり、日本全域においては1900年から2015年の日降水量データが提供されている。また、本対象地において対象期間のデータに欠損がなく、地点観測データより時間的に均質な降水量分布を得ることが可能である。気温データは、気象庁のアメダス⁴⁾から石狩川流域内の全観測点の日平均気温を取得した。本対象地の気温データは空間的にばらつきが小さいことから全観測点の値を算術平均し流域の日平均気温として用いた。流量データは、時間流量を国土交通省の水文水質データベース⁵⁾から取得し、石狩川流域下流に位置する石狩大橋観測点の日平均流量を用いた。また、各種ハイパーパラメータを表1に示す。本研究の対象期間は、モデルの学習に用いる訓練期間、訓練期間を通し、構築されたモデルの過学習をチェックする検証期間、以上の期間を通して構築したモデルを用い最終的な推定を行うテスト期間の3つに分割した。また、上記期間を1998年から2015年とし、訓練期間(1998年~2009年)・検証期間(2010年~2012年)・テスト期間(2013年~2015年)に分割した。

4. 結果・考察

図1(IDL=180日)、図2(IDL=365日)に各深層学習手法(LSTM, GRU, Traditional-RNN)を用いた流量の推定精度を示す。上述に示すように各深層学習手法でそれぞれ100回ずつ学習を行っている。そのため、各100回の学習結果を箱ひげ図で示している。ただし、箱ひげ図では定量的な精度の比較が困難であるため、ここでは各中央値を基準に比較する。図1, 2における各期




図 1.各深層学習手法による流量の推定精度
(IDL=180)




図 2.各深層学習手法による流量の推定精度
(IDL=365)

表 2. 各深層学習手法における流量推定精度の中央値

	LSTM	GRU	Traditional-RNN
Training	0.844	0.842	0.709
Validation	0.854	0.859	0.726
Test	0.754	0.794	0.718

表 3. 各深層学習手法における流量推定精度の中央値

	LSTM	GRU	Traditional-RNN
Training	0.842	0.847	0.712
Validation	0.858	0.855	0.728
Test	0.775	0.805	0.720

間における NSE の中央値を表 2, 3 に示す。表 2 において LSTM, GRU, Traditional-RNN の訓練期間の NSE はそれぞれ 0.844, 0.842, 0.709 である。検証期間の NSE は 0.854, 0.859, 0.726 である。テスト期間の NSE は 0.754, 0.794, 0.718 である。全ての手法において訓練期間よりも検証期間の精度が向上していたが、テスト期間では明らかに精度が低下していた。ゆえに多少のか学習を引き起こしている可能性があった。また、テスト期間の精度は、GRU, LSTM, Traditional-RNN の順に高かった。ここで、GRU は LSTM より計算量が少なく、学習時間の大幅な削減が見込まれる手法であり LSTM の内部を単純にしたものであるが、より単純な内部構造を持つ深層学習手法でも高い推定精度を誇る場合も見受けられた。また本研究で用いた深層学習手法のうち、Traditional-RNN の精度は他の手法と比べ精度が低く、データの長期的な特徴を学習できない可能性があった。

表 3 において LSTM, GRU, Traditional-RNN の訓練期間の NSE はそれぞれ 0.842, 0.847, 0.712 である。検証期間の NSE は 0.858, 0.855, 0.728 である。テスト期間の NSE は 0.775, 0.805, 0.720 である。よって、本研究で用いた深層学習手法の中で、最も複雑な構造をもった手法である LSTM が最も精度とは限らず、逆に LSTM より簡略化された構造を持つ GRU を適用することにより、より高精度な流量推定を行う事ができる可能性が示唆された。

5. 結論

本研究では、寒冷地を対象に LSTM, GRU, Traditional-RNN の 3 つ深層学習手法を用いた降雨流出モデリングを行なった。結果より、本研究で用いた 3 つの深層学習手法はそれぞれ高い精度を誇るが、最も複雑な構造を有した LSTM を用いた場合にも、推定精度が低下しており、寒冷地を対象に降雨流出モデリングを行う場合、単純な構造を持った GRU を用いることにより高精度な推定ができることが明らかとなった。

6. 参考文献

- 1) Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M.. Rainfall-runoff modelling using long short-term memory (LSTM) networks. Hydrol. Earth Syst. Sci, 22.11: 6005-6022., 2018
- 2) LSTM-PyTorch master documentation
<https://pytorch.org/docs/master/generated/torch.nn.LSTM.html>
- 3) APHRODITE: Asian Precipitation—Highly Resolved Observational Data Integration Towards Evaluation of Water Resources
- 4) Amedas from Japan Meteorological Agency
(<https://www.jma.go.jp/jp/amedas>)
- 5) Water Information System from the ministry of land, infrastructure, transport, and tourism