

LSTM を用いた欠測流量補完手法の開発

熊本大学大学院 自然科学教育部 学生会員 永里 趙義

熊本大学 くまもと水環境・減災研究教育センター 正会員 石田 桂

熊本大学大学院 自然科学教育部 学生会員 横尾 和樹

熊本大学大学院 自然科学教育部 学生会員 坂口 大珠

1. 序論

流量データは水資源管理において重要なデータである。しかしながら、観測に基づく流量データは様々な要因により、欠測となることがある。こうした欠測流量に対して、既往研究ではファジィ推論¹⁾、線形回帰および重回帰²⁾など統計的手法を用いた補完方法を検討している。

こうしたなか、水文分野において深層学習手法の高い適応可能性が示されてきている。例えば、深層学習手法の中でも Long Short-Term Memory (LSTM) は降雨-流出モデリングなど、時系列データの解析において成功を収めてきている³⁾。ここで、欠測流量補完において LSTM を用いることにより、高い精度で欠測流量を補完できる可能性がある。

従って、本研究では LSTM を用いた欠測流量補完方法を提案する。入力データとして流量だけでなく、降水量も用いる。降水量も併せて入力することにより、LSTM が欠測時の流況を捉えることが期待される。ここで、欠測時の流量を対象データとする場合、欠測前後のデータを学習に使用することが可能である。したがって、時系列に沿った学習だけでなく、逆方向にも学習を拡張することにより精度向上が期待できる。よって、本研究では単方向 LSTM だけでなく、双方向 LSTM も実装する。

2. 手法

LSTM は再帰型ニューラルネットワークの一種である。LSTM は入力層、隠れ層および出力層から構成される。ここで、隠れ層は LSTM ブロックから成る。LSTM はこの LSTM ブロックを再帰的に用いることで、長期時系列データの入力に対して時系列順序を反映した出力を行う。以上に示した LSTM の順伝播は下式で表される。

$$I(t) = \sigma(W_{ii}x(t) + b_{ii} + W_{hi}y(t-1) + b_{hi})$$

$$O(t) = \sigma(W_{io}x(t) + b_{io} + W_{ho}y(t-1) + b_{ho})$$

$$F(t) = \sigma(W_{if}x(t) + b_{if} + W_{hf}y(t-1) + b_{hf})$$

$$g(t) = \tanh(W_{ig}x(t) + b_{ig} + W_{hg}y(t-1) + b_{hg})$$

$$M(t) = F(t) \cdot M(t-1) + I(t) \cdot g(t)$$

$$y(t) = O(t) \cdot \tanh(M(t))$$

ここで、 I は入力ゲート、 O は出力ゲート、 F は忘却ゲート、 g はセルの状態、 $x(t)$ は時刻 t での入力、 y は隠れ状態、 M はメモリセル、 σ はシグモイド関数、 W および b はそれぞれ重みとバイアスを表す。最終的に LSTM ブロックの出力は重みとバイアスによる線形変換により LSTM の最終的な出力となる。LSTM の学習により調整されるパラメータは LSTM ブロックでの重み、およびバイアスである。ここで単方向 LSTM は順方向に隠れ層を持つ(図-1)。一方で双方向 LSTM は順方向の隠れ層とは別に、逆方向の隠れ層を持つ(図-2)。




図-1 単方向 LSTM




図-2 双方向 LSTM




図-3 学習データの形状

表-1 結果

Case	Method	Training			Validation			Test		
		NSE	RMSE	RMSE99	NSE	RMSE	RMSE99	NSE	RMSE	RMSE99
1	Uni-LSTM	0.987	9.59	53.9	0.921	29.1	235	0.856	48.8	395
2	Bi-LSTM	0.984	10.9	59.7	0.956	21.7	163	0.954	27.5	205
3	Bi-LSTM	0.988	9.32	45.1	0.963	19.9	133	0.952	28.1	159

3. 対象地・データセット

本研究では菊池川流域を対象地とした。毎正時の流量は国土交通省水文水質データベース (WIS) より玉名観測所での観測値を得た。1時間毎の降水量は気象庁の解析雨量より得た。本研究では、この解析雨量から菊池川流域の流域平均降水量を算出し LSTM の入力に用いた。

4. モデルの実装

実際に流量データが欠損している場合、モデルの学習および評価が出来ない。従って、流量データのみ本研究では欠測していない期間のデータを 0 と置き換え、これを欠測データとした。ここで、対象データは 0 に置き換えられる前の流量である。本研究では欠測値補完の対象とする期間を 12 時間とした。また、入力欠測データ 12 時間および、その前後 12 時間 (計 36 時間) とした。降水量は流量と同期間の 36 時間とした (図-3)。

ネットワークの構造について、単方向 LSTM, 双方向 LSTM とともに隠れ層は 1 層とした。単方向 LSTM は many to one で実装した (case1)。一方、双方向 LSTM は many to many で実装した。双方向 LSTM の出力に用いる隠れ状態について、欠測時に対応する 2 方向の隠れ状態を連結し、それぞれ線形変換する場合 (case2) を検討した。加えて、順方向、逆方向それぞれ最後の隠れ状態を連結し線形変換する場合 (case3) も検討した。

データセットはモデルパラメータの調整を行う訓練期間 (2006-2008)、過学習が生じていないか確認する検証期間 (2009-2010) モデルの推定精度の評価を行うテスト期間 (2011-2012) の 3 つに分けた。本研究では LSTM の学習におけるバッチ選択やパラメータの初期値に起因するランダム性を考慮し、各条件につき 50 回ずつ学習を行った。その後 50 回の学習結果のうち、検証期間の中で最も loss が小さい場合の学習結果を抽出した。モデルの評価指標に関して、水文モデルの評価に広く用いられる NSE および、RMSE を用いた。以上に加え、ピーク時での推定精度として、対象データが 99 パーセンタイル以上のときの推定値との RMSE (RMSE99) も算出した。

5. 結果・考察

単方向 LSTM と双方向 LSTM の推定精度を表-1 に示す。結果から、テスト期間において双方向 LSTM は単方向 LSTM よりも推定精度が高いことが示された。特にピーク時の推定精度は双方向 LSTM を用いることで単方向

LSTM と比較して $\Delta RMSE99 = -236 \text{ m}^3 \cdot \text{s}^{-1}$ の精度向上がみられた (case1⇒case3)。以上より欠測流量補完において双方向 LSTM の有用性が示された。また、時系列に対して逆方向の長期依存性を考慮することの重要性が示唆された。テスト期間での case2 と case3 を比較すると、NSE, RMSE に関しては case3 の方が僅かに高かった。しかし、いずれの精度の差は $\Delta NSE = 0.02$, $\Delta RMSE = 0.6 \text{ m}^3 \cdot \text{s}^{-1}$ 程度であり、両者に明確な精度の差は認められなかった。一方でピーク時の推定精度は case3 を用いることで case2 と比較して $\Delta RMSE99 = -46 \text{ m}^3 \cdot \text{s}^{-1}$ の精度向上が見られた。

本研究は隠れ層を 1 層としたが、隠れ層の追加により更なる精度向上が期待される。また、隠れ状態の統合についても、より適切な方法がある可能性が考えられる。従って、今後の課題としてネットワーク構造に関するより詳細な検討が挙げられる。

6. 結論

本研究では、双方向 LSTM を用いた欠測流量補完手法の提案を行った。入力データは毎正時の流量、および毎時間の流域平均降水量とした。対象データについて、モデルの学習・評価のため、本研究では流量データの欠測していない部分を 0 と置き換えることで疑似的に生成した。結果から、双方向 LSTM の欠測流量補完への高い適用可能性が示された。

参考文献

1. Mfwango, L. H., Salim, C. J. & Kazumba, S. Estimation of Missing River Flow Data for Hydrologic Analysis: The Case of Great Ruaha River Catchment. (2018) doi:10.4172/2157-7587.1000299.
2. KOJIRI, T., PANU, U. S. & TOMOSUGI, K. Complement Method of Observation Lack of Discharge with Pattern Classification and Fuzzy Inference. J. Japan Soc. Hydrol. Water Resour. 7, 536-543 (1994).
3. Kratzert, Frederik, et al. "Rainfall-runoff modelling using long short-term memory (LSTM) networks." Hydrology and Earth System Sciences 22.11 (2018): 6005-6022.