

LSTM による流量欠測値補完方法の検討

岐阜大学 正会員 ○児島 利治

岐阜大学 正会員 大橋 慶介

岐阜大学 非会員 Weilisi

1. はじめに

深層学習, 人工ニューラルネットワーク(ANN)は近年著しい発展をとげ, 水工学分野においても多くの適用例がある. 現在のいわゆる第3次 AI ブームでは, 従来よく用いられてきた3層の階層型 ANN に対し, より複雑な構造の ANN が利用されている. RNN (Recurrent Neural Network)は, 中間層や出力層の状態を一時的に保存し次の入力時に利用する構造を持っており, 時系列データの解析に適していると言われている. 近年では, 勾配消失問題を軽減させるため, LSTM (Long Short-Term Memory)というゲートと呼ばれる情報の取捨選択機構をもった RNN モデルが提案されており, 水工学の分野でも洪水予測の分野で多くの適用例がある^{1),2),3)}. 一方, 河川水位・河川流量は, 河川工事, 河川管理における最も基礎的かつ重要な水文情報であり, 多くの計測データが存在する. 川の防災情報は, 雨量, 水位等の情報をテレメータ等により配信しているが, 2012年の国・府県管理地点における観測種別毎の欠測・未受信, 異常値の発生割合は水位 63.0%, 雨量 8.9%, 水質 11.3%と水位データの欠測・未受信, 異常値の発生割合が多いことが報告されており, 水位データの欠測補完は河川管理においても非常に重要な問題と言える⁴⁾. しかし, 深層学習の適用事例の多い洪水予測に対し, 欠測期間が短い場合には前後の観測値を用いた線形補間が有効な事, 上下流の隣接観測点の観測値を利用した補完が比較的高精度であることから, 欠測値補完への深層学習の適用事例はほとんど無い. 深層学習における水位・流量の予測と欠測補完では, i) 洪水予測は数時間先程度を対象とするが欠測補完は欠測期間に依存するため, 1日~数日先の推定が対象となる, ii) 欠測値補完では未来の観測データを利用可能である, iii) 欠測値補完では推定対象地点とは別地点であれば, 推定対象時刻の観測値を利用可能であ

る事など点で適用方法に違いがある. 本研究では, 流量欠測値の補完に対して時系列情報の処理に適した LSTM⁵⁾を適用し, その精度を検証する.

2. 手法

2.1 対象流域と使用データ

岐阜県高山市の宮川水系大八賀川流域を対象流域とする. 大八賀川流域では, 岐阜県宮川上流河川開発工事事務所によって, 三福寺(集水面積 60km²), 塩屋橋(集水面積 41km²)の2地点で1986年から1時間間隔で水位・流量の計測が実施されている. 本研究では, 両地点で欠測の無い2008年の流量観測データで学習, 2009年の流量観測データで検証を実施する.

2.2 線形回帰分析による補完

2008年の三福寺流量 $Q_{san}(m^3/s)$ と塩屋橋流量 $Q_{sio}(m^3/s)$ を用いて, Q_{san} より Q_{sio} を算出する線形回帰式を推定した. 線形回帰式を用いて2009年の Q_{sio} を推定したところ, Nash-Sutcliffe 係数(NSE)で $NSE=0.903$ と流出予測としては高い精度での推定結果が得られた. しかしピーク流量の過小評価及びピーク低減時と平水時において若干の過小評価が見られた.

2.3 LSTM モデルの概要

入力層のユニット数 24, 出力層のユニット数 5, 隠れ層のユニット数 50 とし, Python3.7.3, Keras2.2.4, Tensorflow1.13.1 を用いて LSTM モデルを実装した. LSTM 内部の活性化関数, ドロップアウト率等の設定はデフォルトのままとした(すなわち, 活性化関数は $\tanh$, ドロップアウト率は 0). 出力層の活性化関数は elu , optimizer は Adam を使用した. 損失関数には $\text{mean_squared_error}$ を用いた. 学習用データはランダムに分割し, 9割を学習データ(Training data), 1割を学習中の検証データ(Validation data)とした. 学習回数(epoch 数)は最大 200 とし, 過学習防止のため, EarlyStopping を用いて学習中の検証データを用いた誤差評価 (val_loss)の減少が止まってから 20 回学習

キーワード 深層学習, RNN, 過学習, 確率的勾配降下法, 欠測値補完

連絡先 〒501-1193 岐阜県岐阜市柳戸 1-1 岐阜大学流域圏科学研究センター TEL 058-293-2070

表-1 学習結果ごとの精度評価.

学習結果	NSE	loss	val_loss
1	0.932	7.88×10^{-5}	2.40×10^{-5}
2	0.902	8.70×10^{-5}	1.96×10^{-5}
3	0.463	6.80×10^{-5}	2.15×10^{-5}




図-1 学習結果の精度評価値の比較.




図-2 学習回数と NSE の関係

を行い停止するよう設定した。24 時間前～48 時間前までの Q_{sio} 、推定対象時～24 時間前までの Q_{san} を入力データとし、推定対象時～5 時間前までの Q_{sio} を出力データとして学習を行った。

3. 結果と考察

ANN の最適化は、一般的に確率的勾配降下法 (Stochastic Gradient Descent; SGD) と呼ばれる初期値や学習過程にランダム性を取り入れた手法が用いられるため、学習によって得られるモデル係数は学習毎に少しずつ異なる。例えば表-1 に学習結果を 3 例示す。NSE は検証用データ(2009 年のデータ)で評価した NSE、loss と val_loss はそれぞれ Training data, Validation data の損失関数である。loss や val_loss の値がほとんど変わらなくとも検証データへの適用精度である NSE が低い場合がある。これはいわゆる過学習の効果である。図-1 に独立に 1000 回学習を行った際の val_loss と NSE の比較を示す。val_loss は値が低い方が NSE は値が 1 に近い方が高精度である。検

証データの NSE と学習データの val_loss に相関は無く、学習時の精度で過学習が発生しているかどうかを発見することは困難である。

次に、1000 個の学習結果からランダムに N 個抽出した学習結果を用いてハイドログラフを推定し、N 個のハイドログラフの平均ハイドログラフの精度を評価した。算出する平均ハイドログラフの数を 40 として、N=1~50 までの平均ハイドログラフの NSE の平均値と標準偏差を求め、上側 95%点の変化を調べた(図-2)。NSE の平均値では、N $\geq$ 2 の平均ハイドログラフで線形回帰式の精度 0.903 を超えているが、上側 95%点では 0.829 と線形回帰式の精度を下回る場合が多い。上側 95%点の NSE は、N=1 の 0.768 から N=10 の 0.903 と急激に増加し、その後少し増減した後、N $\geq$ 20 で NSE=0.904 を常に超過する精度を示すようになった。

4. おわりに

確率的勾配降下法では、平均的に良い学習結果を高速で得ることができる一方で、得られる学習結果にばらつきが生じる。一般的にその差異は無視しえるほど小さいとされているが、適用対象によっては学習時の精度は高いが別のデータに適用した際に十分な精度が得られない場合がある。流量欠測値の補完という本研究の適応対象では、1000 回の学習を行ったところ無視し得ないばらつきがある事が示唆された。しかし、20 回以上の学習結果の平均ハイドログラフは、比較対象である線形回帰式より良好な精度が得られる事が示され、ハイパーパラメタのチューニング等の詳細な試行錯誤を多数実施せずとも、十分な推定精度を得る方法が提案できた。

参考文献

- 1) Kratzert, F. *et al.*, Rainfall-Runoff Modelling using Long Short-Term Memory (LSTM) Networks, *Hydrology and Earth System Sciences*, 22, 6005-6022, 2018.
- 2) Hu, C. *et al.*, Deep Learning with a Long Short-Term Memory Networks Approach for Rainfall-Runoff Simulation, *Water*, 10, 1543, 2018.
- 3) Le, X. *et al.*, Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting, *Water*, 11, 1387, 2019.
- 4) 小高茂治, 近畿地方整備局における河川情報の監視と水文観測データの品質照査について, 平成 25 年度近畿地方整備局研究発表会論文集, 2013.
- 5) Gers, F. A. *et al.*, Learning to Forget: Continual Prediction with LSTM, *Neural Computation*, 12(10), 2451-2471, 2000.