

LSTM を活用した解析雨量とダム流入量の関係に関する研究

Study on the relationship between Radar AMeDAS analysis rainfall and dam inflow using LSTM

天方匡純*¹ 安野貴人*¹ 藤井純一郎*¹ 吉田龍人*¹ 大久保順一*¹
 Masazumi Amakata Takuto Yasuno Junichiro Fujii Ryuto Yoshida Junichi Okubo

*¹ 八千代エンジニアリング株式会社
 Yachiyo Engineering Co., Ltd.

Abstract: To reduce heavy rain disasters, to use existing dams effectively becomes a topic. One of the effective uses of existing dams is to optimize quantitative PDCA cycles for dam management. Therefore we try to improve the prediction accuracy of dam inflows using radar rainfalls. Radar rainfalls have real-time rainfalls and predicted rainfalls. It is difficult to use predicted rainfalls for us because predicted rainfall accuracy is improved every year. Therefore we study the possibility of dam inflow accuracy improvement using Radar AMeDAS analysis rainfall which is a representative of real-time radar rainfalls. The way which predicts dam inflows is that we extract the relationship between radar rainfalls and dam inflows by LSTM and predict several hours ahead dam inflows from radar rainfalls. In this article, we study the effect which input conditions to LSTM, ranges, data representation and data summation of radar rainfalls give dam inflow prediction accuracy.

1. はじめに

気候変動による地球温暖化の影響を受け、各地方でこれまで経験したことが無い外力や事象に起因する水・土砂災害に苦しんでいる。低頻度確率規模の水・土砂災害の発生頻度の増大により、従来の治水対策の在り方を抜本的に見直さざるを得ない状況も想定されるが、まずは人命を救うための可能な限り迅速で正確な情報提供が求められる。

洪水時のダム管理に当たっても、下流側の資産集積地の被害軽減やダム自体の安全性確保の観点から、洪水関連情報の早期取得・利用は死活問題であり、その一つのツールであるダム流入量予測の精度向上は喫緊の課題である。

2. ダム流入量予測の原理

ダム流入量予測は、図 1 の通り、主に2つの方法がある。雨量から流入量への流出過程を疑似的に再現する方法と、上流側の雨量や水位から下流側の流入量を予測する方法である。前者はモデルの説明責任を果たせる伝統的合理的手法であるが、データ同化等の技術を駆使しても入力データやモデル構造等のバイアスを低減することが難しい。一方、後者は上流側と下流側のデータ相関を活用する手法であり、確保できるリードタ

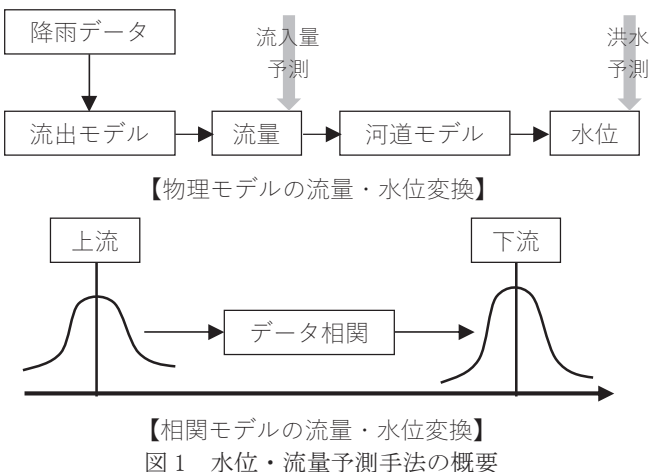


図 1 水位・流量予測手法の概要

イム(上流側から下流側への洪水到達時間)が短く、また、説明責任を果たせないブラックボックス手法と考えられているが、洪水到達時間内予測精度は前者よりも高い。本稿では、後者の原理に基づくダム流入量予測モデルのうち、雨量とダム流入量の関係に特化して検討を進めた。なお、上流側水位・流量とダム流入量に特化した関係については、ニューラルネットワーク[竹村 13]、LSTM[天方 19, 天方 20]、GBDT[天方 20]等を活用し示している。

3. 観測データの特徴

ダム流入量と相関性が高い一般的な上流側データは、水位データと雨量データである。水位は雨量が地面に到達した後の水文過程の結果であるため、よりダム流入量との関係が濃厚である。しかし、上流側水位観測地点から下流側ダム流入量地点までの洪水到達時間は流域規模に制約され、一般的に洪水時のダム管理に必要なリードタイムを確保することは難しい。そこで、よりリードタイムを確保できる雨量データに着目する。

3.1 雨量データの特徴

リアルタイムの雨量観測方法は幾つか存在する。一つ目は、古くから実施されてきた雨量観測所でのポイント観測であり、国県等の公的には概ね 50km² に一地点を目安に整備されている。他にも民間企業が独自に整備した観測網も存在する。二つ目は、レーダー雨量観測である。レーダーの種類によってデータ特性・条件に違いがあるが、現在ではレーダー・アメダス解析雨量や XRAIN 等が一般的である。レーダー雨量の一番の特徴は面的に雨量を捉えられる点であり、雨量観測所よりも遥かに多くの情報量を取得できる。本稿では、レーダーで捉えた雨量を地上観測所雨量で補正されたレーダー・アメダス解析雨量を用いる。レーダー・アメダス解析雨量は 1 km² のメッシュ雨量であり、30 分毎の 1 時間雨量が配信されている。

3.2 ダム流入量データの特徴

ダム流入量は、そのデータ特性上、観測可能なダム放流量とダム貯水位から間接的に推定されることが一般的である。ただし、洪水時には大量の水が流れ込むことによる衝撃波等で貯水池は大きく振動し、貯水位も大きく振動する。この結果、貯水位から間接的に変換したダム流入量も大きく振動する。10 分単位の

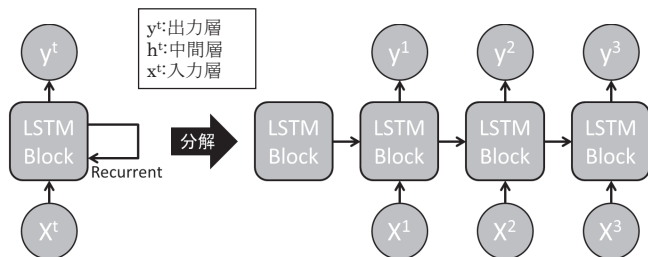


図2 LSTMの基本構造

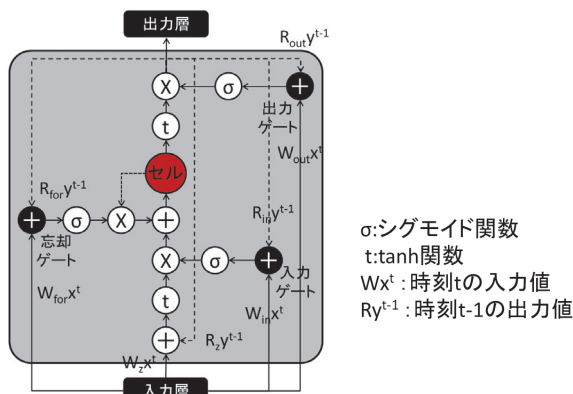


図3 LSTMブロックの詳細図

短時間間隔の計測結果を用いた場合、上記振動に留意する必要がある。しかし、本原稿では60分単位のダム流入量観測結果を用い、ダム流入量形状の概ねの再現を目指す。

4. アーキテクチャーの検討

現時刻以前の情報を再帰的に次のステップの予測に役立てることができるDNN(Deep Neural Network)であるRNN系のLSTM(Long Short-Term Memory)を活用し、ダム流入量の予測精度を高めるアーキテクチャーを検討する。

4.1 LSTMの概要

これまで、我々が洪水予測等に利用してきたニューラルネットワーク[竹村 13]は、中間層を1層(1層当たりニューロン7個)とし、活性化関数にシグモイド関数を用いてきた。しかし、このネットワークは入力データの前後関係を保持する機構を持たず、時系列データを扱う場合は、時刻 t の入力データと時刻 $t+\Delta t$ の出力データの関係を学習することにより、時刻 t のデータから時刻 $t+\Delta t$ のデータを予測する。また、入力データに時刻 t 、時刻 $t+1$ 、時刻 $t+2$ 、…、時刻 $t+\Delta t$ のデータを揃えることで時系列関係を保持しながら出力データとの関係を構築することも可能である。しかし、数日先のように予測スパンが長くなる、XRAINに代表されるメッシュ雨量データが細くなる場合には、元々のデータセット自体が巨大となるため、上記のデータセットの冗長は避けたく、入力データ構造として限界がある。

RNN系ネットワークは、入力データの前後関係を保持する機能が整備され、入力データを必要最小限としてデータの前後関係の特徴量を捉え、出力データとの関係を構築することができる。RNNは図2のように時刻 $t-1$ 以前の中間層を時刻 t の中間層に紐づけ、入力データの前後関係を保持している。更に、LSTMは、図3のように中間層をニューロンではなくLSTMブロックと呼ばれるメモリセルと3つのゲート(忘却ゲート、入力ゲート、

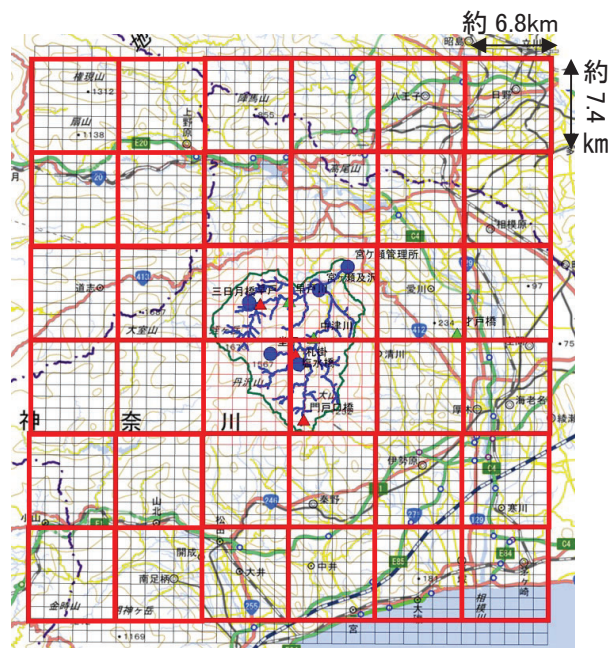


図4 対象とするメッシュ雨量範囲

ト、出力ゲート)を持つブロックに置き換え、データの前後関係の長期依存性[Bengio 94]を高めている。

4.2 取り扱うデータ内容

降った雨が60~90分後にダム貯水池に到達する100km²程度のダム流域を選定し、メッシュ雨量範囲を設定した。メッシュ雨量範囲は当該流域に着目するだけでなく、数時間先のダム流入量を予測することを想定し、図4に示す通り大きめに設定した。また、1メッシュ(約1km²)毎のデータを扱うのではなく、25メッシュ毎(5メッシュ×5メッシュ)に統合した数値を1つのデータとして扱った(図4参照)。

そして、2006年~2019年の100m³/s以上のピーク流入量を発生した42洪水を学習対象(validationデータ含む)とし、2019年に発生した2洪水をテストデータとした。

5. おわりに

発表では、メッシュ雨量データの範囲を変えた場合、データの一部をネグレクトした場合、累積雨量を考慮した場合等のネットワークへの入力条件である雨量データの特性を変えた結果、ダム流入量予測精度にどのような影響を与えるかを示す。

参考文献

- [竹村 13] 竹村仁志, 眞間修一, 吉田武司, 石上尚: 中流域に洪水調節ダムを有する河川における洪水予測システムの精度検証, 河川技術論文集, 土木学会, 2013.
- [天方 19] 天方匡純, 安野貴人, 藤井純一郎, 嶋本ゆり, 大久保順一: IoTを想定したダム流入量予測精度向上に関わる研究, 水文・水資源学会誌, 2019.
- [天方 20] 天方匡純, 梁田信河, 藤井純一郎: LSTMを活用したダム流入量予測に関する研究, 電力土木, 2020.
- [天方 20] 天方匡純, 藤井純一郎, 梁田信河: Gradient Boostingの適用によるダム流入量予測の精度向上, ダム工学, 2020.
- [Bengio 94] Yoshua Bengio, Patrice Simoard, and Paolo Frasconi: Learning Long-Term Dependencies with Gradient Descent is Difficult, TRANSACTIONS ON NEURAL NETWORKS, IEEE, 1994.