

深層学習を活用した特定のダム流域における長期雨量予測モデル構築の試み

四電技術コンサルタント 法人会員 ○小田原光希, 正会員 白鳥実, 香川和久
 ハイドロ総合技術研究所 非会員 黒木秀和, 渡辺啓生

1. 背景と目的

利水容量を有するダムには、安定的に用水を供給する使命があり、渇水時にも利水容量が枯渇しないよう、ダムの貯水率に応じてダムからの取水量を減じて運用されることが多い（以下「取水制限」という）。ここで、もし、1か月先の長期的なダム流域の雨量予測が可能となった場合、取水制限の強化や緩和を早期に実施でき、利水運用の高度化を図ることができる。しかし、現状の1か月先の雨量予測は、気象庁が公表している西日本太平洋側という広い範囲かつ降水確率が「平年並みか否か」という大まかな情報しかない。そこで本研究では、深層学習を活用し、特定のダム流域（以下「Aダム流域」という）において、1か月先の長期的な雨量を予測するモデルの構築を試みた。

2. 海面水温と渇水との関係

降雨の原因となる水蒸気の大半は海面からの蒸発によって供給されることから推察されるように、海面水温の変動は降雨量に多大な影響を及ぼしうる。また、海面水温の変化に関連するエルニーニョ/ラニーニャ現象は、日本の天候に影響を与えると示唆されている¹⁾。そこで、まずエルニーニョ/ラニーニャ現象とAダム流域における渇水の傾向を分析した。なお、対象期間は、データの存在する1982年以降とした。その結果、ラニーニャ現象発生時に比較的大規模な渇水が発生している傾向があった（図-1）。




図-1 エルニーニョ/ラニーニャ現象と

(a) 第3次取水制限以上の渇水頻度 (b) 第4次取水制限以上の渇水頻度
 ※取水制限レベルは、自主～第5次まで

3. 深層学習を用いた長期雨量予測モデルの構築

(1) モデルの概要

機械学習アルゴリズムは収集されたデータから法則性を見つけ出す手法であり、人工知能ブームの基盤となっている技術である。中でも、深層学習を用いたニューラルネットワークの発展は著しい。本研究では、ある日の海面水温から向こう1か月先の雨量を予測するのではなく、1か月前から現在までの海面水温の上昇や下降傾向をもとに1か月先の雨量を予測する。そのため、画像識別と時系列データの学習の両方が必要となる。採用したネットワーク

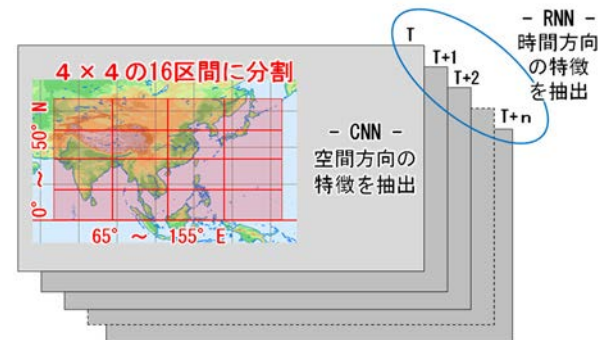


図-2 モデルの概略図および計算区間

表-1 採用した各ニューラルネットワークの特徴

構造は、画像識別において代表的な畳み込みニューラルネットワーク (CNN) と時系列情報を処理するリカレントニューラルネットワーク (RNN) を組合せた CRNN (Convolutional Recurrent Neural Network) を採用した（図-2、表-1）。こ

畳み込みニューラルネットワーク (CNN)	
特徴	画像認識において「特徴量の抽出」を効率的に行える
役割	主に画像をカテゴリごとに分類する作業で価値を発揮
本研究での必要性	「海面水温」と「海面更正気圧」の特徴を抽出
リカレントニューラルネットワーク (RNN)	
特徴	文章や時系列データなどの連続的な情報を利用でき、過去の一連の情報から次に得られる情報の予測を行える
役割	主に時系列情報を考慮した予測で価値を発揮
本研究での必要性	「海面水温」と「海面更正気圧」の時間的な変化傾向を抽出

れは、CNN による空間方向の特徴量を抽出しつつ、RNN によって時間方向の変化の特徴から将来を予測するものである。なお、基本的な RNN を拡張したもので、近年広く用いられている LSTM (Long Short Term Memory) を採用することで、長期依存学習の問題²⁾を解消した。

(2) 入力・出力データ

モデルの入力データは、海面水温および降雨に影響を与えると考えられる海面更正気圧とし、データ期間は取得可能³⁾な1982年から2020年までの39年分とした。対象期間については、台風や梅雨等により長期予測しづらい降雨期間を除き、比較的雨量の少ない冬と春とした。また、入力データの対象範囲は、万田ら⁴⁾を基に日本の気象に影響を与えるとされる、日本近海の北緯50°～北緯0°、東経65°～東経155°とした。海面水温と海面更正気圧データの入力方法については、対象範囲を分割しない場合、計算負荷が過大となったため、対象範囲を4×4の16区画に分割し、それぞれ別チャンネルとして入力した(図-2)。これらの過去1か月の海面水温と海面更正気圧の情報とAダム流域の先1か月総雨量を関連づけて学習させた(図-3)。




図-3 モデルの入力・出力データおよび学習方法

4. モデルの検証と考察

(1) 学習データとテストデータの設定

テストデータの期間は、「①2004年冬～2005年春」、「②2014年冬～2015年春」の2ケースを設定し、テスト期間以外の期間を学習データとした。なお、学習データとテストデータは、データ不足とならないよう、1日ずらしの1か月総雨量、1か月平均海面水温および海面更正気圧とした。

(2) 検証結果と考察

構築した1か月前の海面水温と海面更正気圧から1か月先のAダム流域月雨量を予測するモデルの汎化性能を確認するため、テスト期間①とテスト期間②の予測値と実績値を整理し、比較検証を行った。その結果、テスト期間①のケースは、流域月雨量の増加および減少傾向は概ね予測できる結果となり、比較的雨量が少ない1月～3月の予測精度が高いことがわかった(図-4a)。一方、




図-4 予測値と実測値の比較

テスト期間②では、流域月雨量の増加および減少傾向が予測できていない結果となり(図-4b)、モデルの汎化性能が小さいことがわかった。また、テスト期間により予測精度にばらつきが生じていることから本研究で構築したモデルは、過学習になっている可能性があると考えられる。具体的には、学習データを1日ずらしのデータとしており、似たようなデータが多く、データが偏っていると推察できる。

5. 今後の課題

本研究では、深層学習を活用した特定のダム流域における1か月先の長期的な雨量予測手法の開発を行い、適用性を検証した。提案手法の結果は、現段階では十分とは言えないが、雨量の傾向を概ね予測できている場合もあり、今後の活用に向けた検討の余地がある。今後は、予測精度向上に向けた過学習の回避やモデルの入力データの追加、入力データ種別の取扱い等を検討する必要がある。

参考文献

- 1) 国土交通省気象庁, 日本の天候に影響を及ぼすメカニズム, https://www.data.jma.go.jp/gmd/cpd/data/el_nino/learning/faq/whatiselnino3.html
- 2) Pascanu, R., Mikolov, T., and Bengio, Y.: On the difficulty of training recurrent neural networks, Proceedings of the 30th International Conference on Machine Learning, Vol. 28 of ICML'13, pp. 1310-1318, 2013
- 3) 一般財団法人 気象業務支援センター: 海況解析データ, JRA-55 長期再解析データ
- 4) 万田敦昌, 茂木耕作: 海水温と豪雨災害の関係について, ながれ, 第40, pp. 9-14, 2021