

長時間水位予測への深層学習の適用 —学習～検証過程の一般化に向けて—

APPLICATION OF DEEP LEARNING TO LONG-TERM PREDICTION OF RIVER STAGE TOWARD GENERALIZATION OF LEARNING AND VERIFICATION PROCESS

守谷将史¹・辻倉裕喜²・三浦心³・山脇正嗣⁴・金子拓史⁵

Masashi MORIYA, Hiroki TSUJIKURA, Shin MIURA, Masashi YAMAWAKI
and Hirofumi KANEKO

¹非会員 工修 (株)建設技術研究所 大阪本社 (〒541-0045大阪府大阪市中央区道修町1-6-7)

²正会員 工博 (株)建設技術研究所 中部支社 (〒460-0003愛知県名古屋市中区錦1-5-13)

³正会員 工修 (株)建設技術研究所 東京本社 (〒103-8430東京都中央区日本橋浜町3-21-1)

⁴正会員 工博 (株)建設技術研究所 技術本部 (〒103-8430東京都中央区日本橋浜町3-21-1)

⁵非会員 工修 (株)建設技術研究所 技術本部 (〒103-8430東京都中央区日本橋浜町3-21-1)

In this paper has (The authors have) conducted reviews of deep-learning models for the purpose of long-term forecasting necessary for the practical implementation of dams and river management. However, problems arose such as the process of setting the input and hyperparameters, as well as the reproducibility of floods for irregular pattern. The purpose of this study was to predict a river's water level by the generalization process of setting the input and the hyperparameter in deep-learning model. Furthermore, the necessity of cross-validation for accuracy improvement and the effectiveness of iterative learning were examined. As a result, reproducibility was improved by adding the water level of the current time point at the input data. In addition, the applicability of floods with various waveforms and floods with less frequent occurrences were advanced by cross-validation with iterative learning.

Key Words : water-level prediction, deep learning, Artificial Neural Network, input data selection, parameter setting

1. はじめに

近年, AI (人工知能) 技術の活用によりダム流入量や下流地点水位の予測精度の向上を図ろうとする研究¹⁾²⁾³⁾⁴⁾が, 多く見られるようになってきた. 筆者らも, 機械学習の一種であるディープニューラルネットワーク (Deep Neural Network (以下, DNN)) を使用して, ダムや河川管理の実務上必要となるダム流入量及び下流河川水位の長時間予測を行う深層学習モデルを構築しており, 予測雨量として実績雨量を与えた場合には実務的に適用できるレベルの良好な予測精度が得られている⁵⁾. しかし, 深層学習モデルに与える入力項目の設定, 学習の際に事前に設定する必要がある中間層の数や最適化関数, 学習回数等のハイパーパラメータの設定は, 学習の結果

を大きく左右する事項であるが, その設定過程については試行錯誤を重ねている段階である. 本論文では, 入力項目やハイパーパラメータの設定過程を一般化することを検討した. また, 既往研究では十分でなかった様々な波形や経験の少ない洪水に対する予測再現性を高めることを目的として, 多様な洪水による検証の必要性や重複学習の有効性, モデル構造の変更等を検討した.

2. 深層学習モデルの概要

(1) 対象河川・対象洪水

本研究の対象河川は淀川水系の猪名川とした (図-1). 猪名川の流域面積は383km², 幹川流路延長は43.2kmである. 上流部の支川には一庫ダム (流域面積




図-1 猪名川流域図。




図-2 深層学習モデルの予測イメージ (モデル①)。

115.1km²)がある。

検討対象洪水は、1997～2017年に生起した36洪水に、2018年7月洪水を加えた計37洪水とした。

(2) 深層学習モデル

本研究は、出水対応における準備段階を含めて実務的なダム管理等に必要な48時間先までの長時間予測を実施することを目的とした既往研究⁹⁾をベースとしており、本研究においても48時間先までの長時間予測を行った。深層学習モデルは、読み込んだ入力項目をもとに1～48時間後の値を1度に予測するモデルとした(図-2)。

予測対象は、猪名川の洪水予報観測所である小戸地点の水位とした。なお、既往検討では一庫ダム流入量及び銀橋地点における水位の予測を行っている。

(3) 予測値の取り扱い

本研究では、深層学習モデルの精度を、雨量予測の精度を除いた形で評価するために、以下で入力項目として与える雨量及びダム放流量の予測値には実績値を用いた。




図-3 深層学習モデルにおける入力項目の検討イメージ。

表-1 入力項目の検討ケース。

入力項目	入力数	基本ケース						検討ケース					
		1	2	3	4	5	6	1	2	3	4	5	6
ダム放流量 (現時刻～48時間後)	49	○	○	○	○	○	○	○	○	○	○	○	○
(5日前～現時刻)	120	○	○	○	○	○	○	○	○	○	○	○	○
(3日前～現時刻)	72	○	○	○	○	○	○	○	○	○	○	○	○
(1日前～現時刻)	24	○	○	○	○	○	○	○	○	○	○	○	○
流域平均雨量 (実績)	1	○	○	○	○	○	○	○	○	○	○	○	○
120時間累積 (現時刻)	1	○	○	○	○	○	○	○	○	○	○	○	○
120時間累積 (5日前～現時刻)	120	○	○	○	○	○	○	○	○	○	○	○	○
指数平滑化移動平均 (降り始め～現時刻)	120	○	○	○	○	○	○	○	○	○	○	○	○
(1～48時間後)	48	○	○	○	○	○	○	○	○	○	○	○	○
120時間累積 (1～48時間後)	48	○	○	○	○	○	○	○	○	○	○	○	○
指数平滑化移動平均 (1～48時間後)	48	○	○	○	○	○	○	○	○	○	○	○	○
予測地点水位 (現時刻)	1	○	○	○	○	○	○	○	○	○	○	○	○
(6時間前～現時刻)	7	○	○	○	○	○	○	○	○	○	○	○	○
(24時間前～現時刻)	25	○	○	○	○	○	○	○	○	○	○	○	○
上流地点水位 (現時刻)	1	○	○	○	○	○	○	○	○	○	○	○	○

○：入力項目として設定した項目、■：最適ケース

3. 入力項目の検討

(1) 入力項目の設定

河川水位を予測する深層学習モデルにおける入力項目を体系的に検討するにあたって、図-3に示すように「流出」及び「流下」の過程はDNNにより実績データから学習することを期待し、まずは最低限必要な入力項目として「流域平均雨量(実績・予測)」と「一庫ダム放流量(予測)」のみを与えることとした。次に、精度を向上させるための工夫として、以下のような入力項目を検討した。入力項目検討ケースの一覧を表-1に示す。

- 雨量やダム放流量だけでは、基底流量を表現できないことを想定し、「予測対象地点の水位」を与え、初期水位として学習することを期待する。(ケース2)
- 与える実績雨量の期間を変更する。(ケース3)
- 雨量の与え方の工夫として、「累積雨量」や「指数平滑化移動平均雨量(雨量を水位の波形に近づける)」

を与える。（ケース4）

- ・「上流地点の水位」を与えることで、予測対象地点までの流達時間分の予測精度向上を図る。（ケース5）
- ・流達時間の違いを考慮するため、「小流域（観測所）毎の雨量」を与える。（ケース6）

(2) モデルの設定

ここでは、入力項目の違いによる予測精度の違いを感度分析することを主目的に、検討対象37洪水のうち2017年10月洪水の1洪水のみをテストデータとし、残る36洪水を学習データとして、予測精度の検証及びハイパーパラメータの設定を行った。テストデータとする洪水は以下の観点で選定している。

- ・対象洪水の内、最大ピーク流量と最小ピーク流量の中間程度のピーク流量を持つ
- ・降雨及び洪水波形が1山（精度確認のため、2山洪水など複雑でない洪水を対象とした）

ハイパーパラメータの検討パターンと設定値を表-2に示す。ハイパーパラメータは、全ての組み合わせの試行はせず、パラメータを網羅的に検討した既往検討⁵⁾の設定値をベースに1項目ずつ変化させて、その中から最適な設定値を探索した。

表-2 ハイパーパラメータ設定値。

ハイパーパラメータ		検討パターン	設定値
中間層	重み初期値	①Heの初期値 (活性化関数がReLUの場合) ②Xavierの初期値 (活性化関数がSigmoid、tanhの場合)	②Xavier
	層数	①2層、②3層	②3層
	ノード数	①10、②100、③500 ※1つの入力層に対して	②100
	活性化関数	①ReLU関数、②Sigmoid関数、③tanh関数	③tanh関数
パラメータの更新方法	最適化関数	①Adam関数、②SGD関数、③RMSprop関数	①Adam関数
	最適化関数学習係数	①0.1、②0.01、③0.001、④0.0001、⑤0.00001	③0.001
	ミニバッチサイズ	①10、②30、③100、④300、⑤1000	③100
	学習回数	①10、②100、③1000	②100
その他	データ入力層正規化	①標準化、②正規化、③正規化処理なし	①標準化
	中間層Dropout率	①Batch Normalization、②正規化処理なし	①BN
	Dropout率	①0.1、②0.3、③0.5、④0.8	②0.3

(3) 入力項目の検討結果

最も基本的な「流域平均雨量（実績・予測）」と「一庫ダム放流量（予測）」のみを与えるケース1では、波形はおおむね再現できているが、全体的に大きく値がずれる結果となった（図-4）。120時間程度の実績雨量だけでは、基底流量を表現するのが難しいと考えられる。

予測対象地点である小戸地点の現時刻水位を入力項目として加えたケース2-1では、ねらい通り初期水位として学習され、ケース1と比較して大きく予測精度が向上した（図-5）。

入力項目の検討ケース毎のRMSEによる精度評価結果を図-6に示す。雨量を指数平滑化移動平均として与えたケース4-4では、ケース2-1と比較してやや精度が低くなる状況がみられたが、その他の予測対象地点水位の期間を変更したケース2-2、2-3や、実績雨量の期間を変更し




図-4 2017.10洪水 水位検証結果 入力項目ケース1.




図-5 2017.10洪水 水位検証結果 入力項目ケース2-1.




図-6 入力項目の検討結果（RMSEによる精度評価）。

たケース3、雨量の与え方を工夫したケース4-1～3、上流地点水位を与えたケース5、小流域別の雨量を与えたケース6では、ケース2-1と同程度の精度であった。ケース5の上流地点水位やケース6の小流域別の雨量については、猪名川流域の流域面積が比較的小さいため精度向上につながらなかった可能性があり、流域面積が大きい地点を予測対象とする場合には精度向上に寄与する可能性があると考えられる。

上記のような入力項目は小戸地点の水位予測を行う深層学習モデルにおいては不要であったと考えられるが、不要な入力項目を与えたケースでも精度の低下は生じない結果になっており、同様の結果がKIMら⁹⁾によっても示されている。

4. 多様な洪水による検証の必要性検討

(1) 多様な洪水による再現性の確認

上記では、検討対象洪水37洪水のうち、1洪水のみを

テストデータとして入力項目及びハイパーパラメータを設定したため、テストデータ以外の洪水では十分な再現性を得られない場合があると想定された。このため、37洪水全てに対してleave-one-out交差検証を行い、上記で設定した入力項目（ケース2-1）及びパラメータを用いた場合の精度検証を行った。（検討対象洪水37洪水のうち1洪水をテストデータ、残る36洪水を学習データとする計算を、テストデータを入れ替えて37回行った。）

RMSEによる精度評価の結果を図-7に、水位検証結果の例を図-8に示す。この結果、想定されたとおり、再現性が不十分な洪水が複数みられた。




図-7 交差検証結果 (RMSEによる精度評価)。

(2) パラメータの見直し

上記のような未知のデータに対する予測精度の向上を図るため、検討対象洪水37洪水から多様な波形を含むように選定した検証対象8洪水（2004.10洪水、2013.9洪水、2014.8洪水、2014.10洪水、2015.7洪水、2016.9洪水、2017.10洪水、2018.7洪水）による検証を行ったうえでハイパーパラメータを設定した。検証は、検証対象洪水8洪水のうち1洪水をテストデータとし、検討対象洪水のうち残る36洪水を学習データとする計算を、テストデータを入れ替えて8回行った。検証対象洪水を図-10に示す。

(3) 多様な洪水での検証による精度向上の結果

多様な8洪水をテストデータとして検証を行ったうえでハイパーパラメータを設定した結果、表-2に示すハイパーパラメータのうち、入力項目のデータ正規化を「①標準化」から「②正規化」に変更することで多様な洪水に対する予測精度が向上した（図-9）。このようにハイパーパラメータの設定時には、多様な洪水による検証が必要である。

なお、このハイパーパラメータを用いて、改めて表-1に示すケースで入力項目を変更した場合について多様な洪水による検証を行ったが、精度向上はみられなかった。ある程度精度を確保できる入力項目を選定できていれば、入力項目の設定時には多様な洪水による検証の必要性は低い可能性がある。




図-8 2018.7洪水 水位検証結果 1洪水のみで検証。




図-9 2018.7洪水 水位検証結果 多様な洪水で検証。




図-10 検証対象洪水 (8洪水)。

5. 重複学習の有効性検討

(1) 重複学習の方法

多様な洪水による検証を行ったうえでハイパーパラメータを設定することで、多様な洪水に対する精度が向上したが、訓練データの数が少ない二、三山の洪水で、まだ予測精度が低い傾向がみられた（図-9）。このた

め、KIMらによって有効性が示されている重複学習⁹⁾を用いて、データの数が少ない二山及び三山の洪水の精度が向上するかを確認した。重複学習では、同じ洪水を重複して学習データとして入力することでデータの不足を補い、精度向上を図る。

学習データを重複させる洪水は、二、三山洪水を中心とした5洪水（1997.8洪水，2014.8洪水，2015.7洪水，2016.9洪水，2018.7洪水）とし（図-11），それぞれ5回，または10回重複して学習させた。ただし，上記洪水がテストデータとなる場合は重複も含めて学習データから省いた。

入力項目及びハイパーパラメータは「4. 多様な洪水による検証の必要性検討」で設定したものと同一ものを使用した。




図-11 重複学習対象洪水（5洪水）。




図-12 2018.7洪水 水位検証結果 重複学習あり（5回）。




図-13 2018.7洪水 水位検証結果 重複学習あり（10回）。

(2) 重複学習の結果

重複学習を行った場合の水位検証結果を図-12，13に示す。生起頻度（学習データ）が少ない二，三山洪水の再現性がさらに向上する結果が得られ，重複学習の有用性が確認できた。重複回数5回と10回では，顕著な差はみられなかった。

6. モデル構造の検討

(1) モデル構造

以上の検討では，読み込んだ入力項目をもとに1～48時間後の値を1度に予測するモデル①（図-2）を用いていたが，ここでは現時刻から1時間後，1時間後の計算結果から2時間後・・・を繰り返し48時間後までを予測するモデル②（図-14）の適用性を検討する。

モデル①が波形全体を予測するのに対し，モデル②は1時間毎の予測の積み重ねであるため，二山洪水等の学習データが少ない洪水にも適用性が高くなることを期待して検討を実施した。




図-14 深層学習モデルの予測イメージ（モデル②）。

(2) モデルの設定

ハイパーパラメータは表-2に示すハイパーパラメータのうち活性化関数をSigmoid関数に変更し，最適化関数の学習係数を0.0001としたケースで再現性が高くなった。入力項目は表-1に示すケースのうち最適となったケース4-3を用いた。

(3) モデル構造による違い

1時間毎の予測を繰り返し48時間後までを予測するモデル②の水位検証結果を図-15，16に示す。モデル②は期待したとおり，二山，三山洪水など一部の洪水で予測精度が高い場合もみられるが，全体的にはモデル①の予測精度が高かった。モデル②では，予測誤差が積みあがる構造のため，48時間という長時間予測には不向きである可能性がある。ただし，ハイパーパラメータについて




図-15 2017.10洪水 水位検証結果 モデル②.




図-16 2018.7洪水 水位検証結果 モデル②.

は、すべての組み合わせを検討したわけではなく、さらに最適なハイパーパラメータの組み合わせが存在する可能性はある。

7. おわりに

本研究では、水位の長期予測を目的とした深層学習モデルにおいて、入力項目やハイパーパラメータの設定過程を一般化することを検討するとともに、精度向上に対する多様な洪水による検証の必要性や重複学習の有効性等を検討した。

その結果、以下に示すような知見を得ることができた。

- ・ 入力項目は最低限必要な諸量に予測対象地点の現時刻水位のみを加えることで良好な再現性を得られた。
- ・ 不要な入力項目を与えても精度の低下は生じない。
- ・ 多様な洪水による検証を行ったうえでハイパーパラメータを設定することで、多様な波形の洪水への適用性が向上し、その必要性が示された。
- ・ ある程度精度を確保できる入力項目を選定できていれば、入力項目の設定時には交差検証の必要性は低い可能性がある。
- ・ 重複学習により生起頻度が小さい洪水への適用性が向上することが確認できた。
- ・ 1時間毎の予測を繰り返し48時間後までを予測するモデル②よりも、1～48時間後の値を1度に予測するモデル①の方が、長時間水位予測への適用性は高かった。

参考文献

- 1) 関基, 木村晃, 古山一志, 和田高宏, 金子祐, 穴水秀樹, 眞間修一: 河川特性を反映したニューラルネットワーク洪水予測の精度向上, 土木学会 河川技術論文集, 第19巻, 2013.
- 2) 竹村仁志, 川村一人: 猪名川におけるニューラルネットワークモデルを用いた水位上昇部の予測精度向上, 国土交通省近畿地方整備局 新技術・新工法部門, No.16, pp.1-5, 2016.
- 3) 滝口修司, キムスンミン, 立川康人, 市川温, 萬和: 明ニューラルネットワークを用いた積雪地域の河川流量予測における重要入力因子の抽出, 土木学会論文集B1(水工学), Vol.74, No.4, I_877-882, 2018
- 4) 一言正之, 遠藤優斗, 島本卓三, 房前和朋: レーダ雨量を用いた深層学習によるダム流入予測, 土木学会 河川技術論文集, 第24巻, pp.403-408, 2018.
- 5) 田村和則, 加納茂紀, 三浦心, 山脇正嗣, 金子拓史: ダム流入量長時間予測への深層学習の適用ーダム防災操作の効率化を目指してー, 土木学会論文集B1(水工学), Vol.74, No.5, I_1327-1332, 2018.
- 6) Sunmin KIM, Yasuto TACHIKAWA, REAL-TIME RIVER-STAGE PREDICTION WITH ARTIFICIAL NEURAL NETWORK BASED ON ONLY UPSTREAM OBSERVATION DATA, Annual Journal of Hydraulic Engineering B1(Hydraulic Engineering), Vol.74, No.4, I_1375-1380, 2018.

(2019. 4. 2受付)