

1次元畳み込みネットワークによるダム流入量予測の精度評価

Convolutional Dam Inflow Forecasting

緒方 陸^{*1}
Riku Ogata

岡野 将大^{*1}
Masahiro Okano

泉谷 隆志^{*1}
Takashi Izumiya

山本 茂友^{*1}
Shigetomo Yamamoto

安野 貴人^{*1}
Takato Yasuno

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

Since 2006, rainfall forecasting such as short-range forecasts of precipitation has been provided to prepare for the occurrence of torrential rains and extreme floods. In order to prepare for uncertain floods, it is important for dam managers to improve the accuracy of dam inflow forecasts. In this study, a one-dimensional convolutional network prediction model is proposed for predicting dam inflows up to six hours in advance, using various dam quantities and short-range forecasts of precipitation. We also apply several methods to improve the accuracy focusing on the loss and activation functions. As a result of comparing the accuracy with the baseline MLP, RNN and LSTM models, it is confirmed that the prediction accuracy of the 1D convolutional network is as good as or better than the baseline. Finally, we mention the usefulness of our method in terms of accuracy improvement and issues for future generalization.

1. はじめに

1.1 背景

近年、気候変動の影響により、極端な気象現象に伴う災害が頻発している。国内では短時間強雨による災害が多く発生しており、最近では令和2年7月豪雨や令和3年8月の大雨など、多くの地域で甚大な被害を受けている。大規模な出水への対応として、気象予測に基づくダム洪水調節操作の高度化が求められていることや、将来の維持管理に対する管理職員の減少を踏まえるとゲート操作(下流へ放流する量の調節操作)に対するリスクは高まる傾向にある。この問題に対し、長時間先の河川水位またはダム流入量予測を高精度で行うことは運用技術の底上げに繋がり、上記問題の解決に貢献する。

国土交通省が管理する大河川においては、洪水への早期対応のため、6時間先の水位予測が提供されている。一方、一級河川の指定区間や二級河川および準用河川などの多くの中小河川[中小河川計画検討会 1999]においては洪水予測を実施できておらず、予測手法の確立が課題となっている。この一因として、中小河川では洪水到達時間(基準点の上流に降った雨が基準点に到達するまでの時間)が短いなどにより、洪水予測が難しいことを挙げておく。

1.2 洪水予測に関する既往研究

洪水被害を最小限に抑えるため、過去には様々な洪水予測手法が提案されている。最近では深層学習を用いた河川水位やダム流入量の予測手法開発が盛んに行われており、代表的な手法として MLP (MultiLayer perceptron)や RNN (Recurrent Neural Network), LSTM (Long Short-Term Memory)などがある。

[一言 2018]は大河川である網走川を対象に、MLPの手法により観測データから6時間先の予測を高精度で実現した。一方、[中根 2019]は中小河川である鏡川を対象に、観測データを用いて MLP による水位予測を行っているが、高精度の予測は1時間先までしか実現できておらず、2時間先以降の予測に

は雨量の予報値が必要であると述べている。また、[天方 2019]は、中小河川に位置する道志ダムを対象に、支川筋に設置した複数の水位計データを活用し、LSTMにより2時間先までの流入量を精度良く予測している。

[谷口 2019]は、MLPやRNN、LSTMを用いた流入量予測精度比較を行った。原著の中で、一般的にLSTMはRNNよりも高性能であるとされるものの、その優位さは確認できなかったと報告している。さらに同論文では、MLPは時系列を仮定しないため、流入量の波形が安定しないと述べている。

以上から、モデルや観測地点数等の違いに加え、流域規模による洪水到達時間の違いなど、流域ごとの地域特性も精度に影響を及ぼしている可能性がある。流域特性の一つである降雨の流出過程をモデルにより制御できれば、洪水予測の精度が向上すると考えた。

1.3 本研究の目的

本稿では、国・県が管理する観測所データと雨量予測値のみを用い、高知県内の中小河川に位置するダムAを対象に、深層学習を用いてダム流入量予測を行う。対象地点は洪水到達時間が1~2時間程度と短いため、目的変数と説明変数の短期的な時系列の依存関係を学習し予測することが重要である。

ここで、1次元畳み込みネットワーク(Conv1D)は、音声認識や振動ベースの構造的損傷検出等、時系列解析の手法として広く用いられている[Kiranyaz 2021]。また、Conv1DはRNNやLSTM等と比べネットワーク構造がシンプルであり、結果の解釈がしやすい。そのため、ダム流入量予測の実運用にあたっても有効な手法であると考えた。

ダム流入量予測において、畳み込み層のフィルタは時系列データの非線形変換と見なすことができ、時系列データを畳み込むことは、時系列データの移動平均をとるとも言い換えられる。これらの特徴から、パラメータ設定により時系列情報の依存関係を考慮した予測が可能となり、降雨流出過程の時間的制御を行えると考えた。

本研究では、Conv1Dおよび先述の3手法(MLP, RNN, LSTM)を用いてダム流入量予測精度の比較によりConv1Dの有用性を示し、流入量予測汎用化に向けた今後の課題について言及する。

2. 実験概要

2.1 学習データ

[天方 2021]は、予測雨量が実測雨量と同程度の精度という前提での研究が大半であることを指摘し、不確定性を持つ予測データを含めて学習を行う「予測学習」の有用性を示している。本研究では「予測学習」を適用し、高知県より受領した 30 分単位 (10 分単位で提供されるデータを 30 分毎に抽出) のダム諸量データ (雨量データ[mm/h]:4 地点+流域平均雨量, 水位データ[m]:1 地点) に加え、予測雨量 (降水短時間予報:30 分単位) を学習・テストデータに用いた。データの収集期間は予測雨量が提供されている 2006 年 3 月以降のうち、出水期間 (学習:11 出水, テスト:4 出水) のみとした。

2.2 実験

(1) カーネルサイズとストライドの違いによる精度影響

本研究で扱う時系列予測の場合、カーネルサイズおよびストライドは、それぞれ時間方向の移動平均期間長さと移動平均期間の重複数/スキップ数を表していると言い換えられる。

ここで、対象ダムの流域に降った雨は、時間経過とともに浸透や流出を行い、これに伴い土中の水分量も変化する。土中水分量は降雨流出時間にも影響を与えることから、カーネルのパラメータ設定による時間制御は精度に影響を及ぼすと考えた。

本稿では、カーネルサイズ 5 ケース (1~5) とストライド 5 ケース (1~5) の組み合わせによる感度分析を行い、Conv1D のパラメータを決定した。

(2) 代表的手法と Conv1D の比較

1.2 節で紹介した代表的手法である MLP, RNN, LSTM と、提案手法である Conv1D の精度比較を行った。各手法は 1~3 層のブロックの後ろに、共通して Batch Normalization (BN) 層、全結合層を加えた構造としている。各ブロックは以下の構造を取っており、複数層の場合はこれらの層を重ねている。

- MLP : 全結合層+ドロップアウト層
- RNN : SimpleRNN+ドロップアウト層+全結合層
- LSTM : LSTM+ドロップアウト層+全結合層
- Conv1D: 一次元畳み込み層+ドロップアウト層+全結合層

Conv1D のカーネルサイズおよびストライドは前節の検討により値を決めた。なお、いずれの手法もドロップアウト率は 0.3、ノード数は 256 で固定とし、各層の活性化関数には ReLU を、損失関数には MSE (Mean Square Error) を用いた。また、最大エポック数は 200 とし、40 イテレーションのうちに最高精度の更新が無い場合には、その時点で計算打ち止めとした。

ネットワークへの入力値は、6 時間前~現時刻までの 30 分単位の諸量データに加え、30 分毎に現時刻に更新される 1 時間~6 時間先予測雨量データを用いた。また、モデルは予測時間を分割することで精度が向上したため、1~2 時間先、3~4 時間先、5~6 時間先の 3 つを構築し、各出力は 30 分間隔で 4 シーケンス (2 時間分) とした。それぞれ出力評価指標には RMSE (Root Mean Square Error)、決定係数 R^2 を用い、精度比較を行った。

(3) Conv1D の精度向上に向けた検討

損失関数

損失関数の違いによる Conv1D の精度比較として、2.2(2)節で最高精度を発揮した予測時間ごとの Conv1D に対し、MAE (Mean Absolute Error) loss, Huber loss, Log-cosh loss を適用し、3 つの精度比較を実施した。

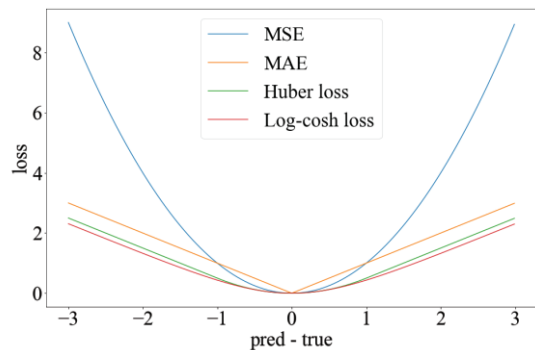


図 1 損失関数比較

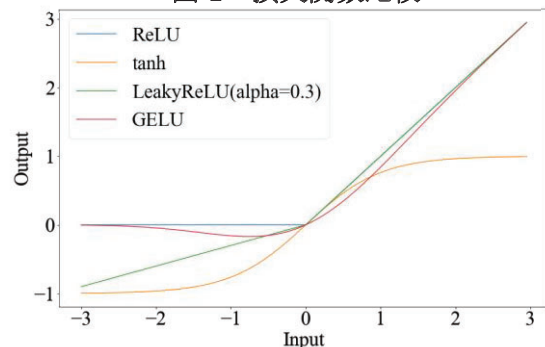


図 2 活性化関数比較

MSE は予測値・正解値の差分の二乗で評価するのに対し、MAE は予測値と正解値の差の絶対値で損失を評価するため、損失が大きいくほど、MSE に比べて MAE の方が小さい値をとる。Huber loss および Log-cosh loss は MAE, MSE を足し合わせた機能を持つ。双方ともに損失が大きいく場合に MAE に、損失が小さい場合には MSE と同様な機能を果たす。Huber loss と異なる点として Log-cosh loss は全範囲で 2 回微分が可能であり、学習が効率的に進む。(図 1)

活性化関数

活性化関数の違いによる Conv1D の精度比較として、損失関数の比較で最高精度を発揮した予測時間ごとの Conv1D に対し、tanh, Leaky ReLU, GELU [Hendrycks 2020] を適用し、3 つの精度比較を実施した。

tanh は出力値を -1~1 の範囲に収めるため、入力が極限に近くなると勾配が消失する恐れがある。Leaky ReLU および GELU は、ReLU をベースとした関数である。Leaky ReLU は正負両側で一次関数となり、入力値がマイナス値でも出力側に値を返す。GELU は ReLU と同様の形をとるが、入力値がゼロ付近で非線形となる。(図 2)

3. 結果と考察

3.1 カーネルサイズとストライドの違いによる精度評価

カーネルサイズとストライドの違いによる精度評価結果を図 3 に示す。なお、Conv1D の計算条件は 2.2(2)節と同様とし、評価指標には RMSE および決定係数を用いた。図中の箱ひげ図は評価指標ごと、予測時間ごとに、カーネルサイズまたはストライドを固定して評価した結果を示している。固定したパラメータ以外の影響で指標のばらつきも大きいため、ここでは各指標の中央値に着目し、議論する。

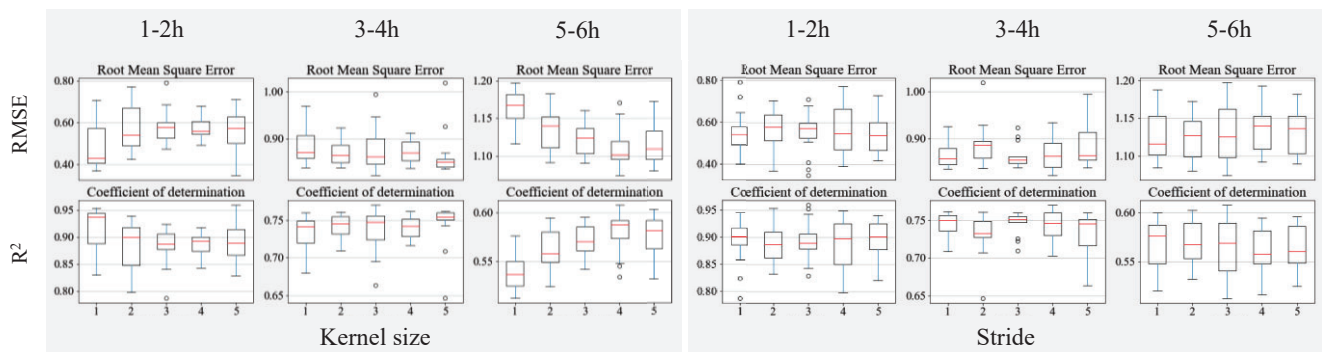


図3 Conv1D精度比較 (左: カーネルサイズによる違い, 右: ストライドによる違い)

表1 代表モデルとConv1Dの比較結果

予測時間	モデル	層数	カーネルサイズ	ストライド	RMSE	R ²
1-2h	MLP	3	-	-	0.435	0.936
	RNN	1	-	-	0.342	0.960
	LSTM	1	-	-	0.401	0.945
	Conv1D	3	1	5	0.418	0.940
3-4h	MLP	1	-	-	0.873	0.740
	RNN	1	-	-	0.871	0.742
	LSTM	3	-	-	1.029	0.640
	Conv1D	2	5	3	0.840	0.760
5-6h	MLP	2	-	-	1.210	0.502
	RNN	1	-	-	1.141	0.557
	LSTM	1	-	-	1.174	0.531
	Conv1D	2	4	1	1.084	0.600

まず図3左を見ると、カーネルサイズが増加するにつれ、1-2h先予測では右肩下がり、5-6h先予測では右肩上がり、3-4h先予測では1-2h先・5-6h先予測の中間の傾向をとっている。この傾向はカーネルサイズが増加するにつれ、長時間先の予測を可能としていると考えた。ここで、降雨の流出プロセスを考えると、地上に降った雨は地表を流れてそのまま流出する水と、一度地中に浸透し、再度地表に表れて流出する水に分けられる。よって、カーネルサイズによりこれらの時間差を適切に捉えることが、精度向上に寄与していると推察した。また、予測雨量は長時間先ほどノイズが大きい。カーネルサイズはこのノイズを平準化する役割も担っていると考えた。

一方図3右を見ると、カーネルサイズの違いと比較してストライドの違いによる明瞭な傾向は読み取れない。この差から、ストライドよりもカーネルサイズの寄与が大きいと考えた。また、本研究では入力データ(観測雨量、観測水位、予測雨量)を全て同じフィルタで処理を行ったため、この処理が明瞭な傾向が読み取れない原因となった可能性もある。よって、属性値ごとに異なるストライドを用いると、より明瞭な違いを確認できる可能性がある。カーネルサイズにおいても同様のことが言え、これを明らかにするには属性値ごとに異なるフィルタを用いた検討が必要となる。異なるフィルタの属性値ごとへの適用は今後の課題とする。

本稿では、対象地域の特性を適切に表すことができたと判断した、RMSEおよび決定係数の両指標で中央値が最も高い精度を示したカーネルサイズとストライドの組み合わせを用い、次節の検討を行った((kernel size, stride) = 1-2h:(1,5), 3-4h:(5,3), 5-6h:(4,1))。

3.2 代表的手法とConv1Dの比較

MLP, RNN, LSTMとConv1Dの精度比較結果を表1に示す。なお、表中には各手法、モデルごとに各ハイパーパラメータの組み合わせによる最高精度の結果を載せている。結果から、予測時間1-2hでは、Conv1DはLSTMおよびRNNにやや劣るものの、決定係数で0.9以上の精度を発揮している。また、予測時間3-4hおよび5-6hでは、Conv1DはRMSEおよび決定係数でRNN, LSTMを超える精度を発揮した。

一方、各評価指標において、MLPはいずれの予測時間においても精度を発揮できていない。MLPは全結合層のみで構成されるため、時間的な位置情報を仮定しておらず、予測流入量の波形が不安定なため、精度に悪影響を及ぼしたと推察した。

RNNやLSTMは、構造上短・長期の情報を記憶できるとされるが、長期記憶を保持していないとの指摘もある[Zhao 2020]。これらのモデルは短期記憶である直近の情報を保持することで、1-2h先予測の精度を高めた一方で、3時間以降の予測精度は発揮できていないと考えた。

本実験より、Conv1Dはカーネルサイズとストライドにより短・長期の情報を制御でき、適切なパラメータ設定により流入量予測精度向上が可能となったと推察した。シンプルなネットワークほど表現力が乏しくなるが、これを畳み込み層のフィルタでカバーしているとも言え換えられる。現状では提供される降雨予測精度が充分でないため、短時間先予測と比較して長時間先の予測精度が低いものの、Conv1Dは代表的手法と同等以上の精度を発揮している。また、属性値ごとのフィルタ設定により時間制御可能なことが明らかになれば、さらなる精度向上が望める。さらにRNNおよびLSTMと比較してシンプルなネットワーク構造で説明性も優れる。以上より、本節ではダム流入量の予測において十分に有用であることを示した。

3.3 損失関数と活性化関数

前節で精度を発揮したConv1Dに対し、損失関数と活性化関数の違いによる精度比較を行った。結果を表2および表3に示す。

表2より、1-2h先予測では比較的水ピークを表現できているため、いずれの損失関数を用いても大きな差は見られなかった。一方3時間以降の予測においてはピーク表現が劣化するため、MSEが優位となったと推察した。以上から、洪水のような稀有な事象の予測においてはMSEが有効であると判断した。

表3より、1-2h先予測では活性化関数にGELUを用いたケースが最高精度となった。GELUはReLUよりも入力値ゼロ付近の表現力が増すため、この表現力が精度に寄与したと推察した。また、3-4h先予測および5-6h先予測ではReLUとLeakyReLUの精度が同程度であり、入力値ゼロ以上の恒等関数が精度に寄与しているものと判断した。tanhは極限付近の出力値の表現が乏しいため、精度が低くなったと考えた。

以上の結果から、予測時間ごとに最高精度を発揮した損失関数・活性化関数の組み合わせで予測を行った結果(表3)と、Conv1Dの次に高い精度を得たRNNの予測結果の一部を図4に示す。図より、1h先予測は大差なく、5h先予測はどちらも精度は低い。3h先予測で違いが表れており、RNNに比べ、Conv1Dの方がピークを良く捉えられ、波形も比較的安定している。

4. おわりに

4.1 本研究の成果

本研究では中小河川を対象とした洪水予測において Conv1D の適用可能性を検討した。既往モデルとの流入量予測精度比較の結果、本数値実験に関する限りにおいて、Conv1D が高い精度を発揮し得る知見を得られた。また、学習条件と閾値設定による精度の感度分析結果から、適切な条件設定が精度向上に繋がることを明らかにした。さらに、シンプルなネットワーク構造である Conv1D は説明性にも優れている。以上から、Conv1D はダム流入量予測において有用であることを示した。

4.2 今後の課題

本研究の今後の課題を言及する。まず、3.1 節で挙げた雨量・水位等属性値ごとに異なるフィルタの適用検討がある。次に、本研究では同様の条件で各手法の一律比較を行ったのみであるため、各手法の精度を十分に高めた上での比較が必要であると認識している。また、予測対象であるダム流入量は、流域規模や降雨量、地形、地質等の違いにより性質が異なり、さらに水文観測状況もダム毎に異なる。よって、少ないデータで汎化性を高めることが重要であり、多数の流域で本手法を適用検討することも課題として挙げておく。最後に、汎化性を高めるにあたり、水位・流入量予測における統一された予測先行時間毎の指標が無い。そのため、指標確立も重要な課題である。

謝辞

本論文を執筆するにあたり、高知県よりダム諸量のデータ提供をいただきました。厚く御礼を申し上げ、感謝の意を表します。

参考文献

- [中小河川計画検討会 1999] 中小河川計画検討会: 中小河川計画の手引き(案), 1999.
- [一言 2018] 一言正之, 桜庭雅明: 学習事例を上回る大洪水に対する深層学習水位予測モデルの検証, 人工知能学会全国大会論文集, 2018.
- [谷口 2019] 谷口純一, 小島崇, 曾田康秀, 福元秀一郎, 佐藤尚, 町田佳隆, 見上哲章, 永山正典, 錦織俊之, 渡邊明英: Recurrent Neural Network によるダム流入量の予測, 河川技術論文集, 2019.
- [中根 2019] 中根 英昭, 若槻 祐貴, 山本 啓, 武田 拓巳, 端野 典平: 深層学習の河川防災・環境分野への応用 四万十川・鏡川水位、仁淀川大渡ダム流入量について, 高知工科大学紀要, 2019.
- [天方 2019] 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, 32 巻, 6 号, 2019.

- [Kiranyaz 2021] Serkan Kiranyaz, Onur Avci, Osama Abdeljaber, Turker Ince, Moncef Gabbouj e, Daniel J. Inman: 1D convolutional neural networks and applications: A survey, Mechanical Systems and Signal Processing 151, 2021.
- [天方 2021] 天方匡純, 石井明, 宮崎利行, 宮本崇: ダム流入量予測の精度向上を実現する予測学習, AI・データサイエンス論文集, 2021.
- [Hendrycks 2020] Dan Hendrycks, Kevin Gimpel: Gaussian Error Linear Units (GELU), arXiv:1606.08415v4, 2020.
- [Zhao 2020] Jingyu Zhao, Feiqing Huang, Jia Lv, Yanjie Duan, Zhen Qin, Guodong Li, Guangjian Tian: Do RNN and LSTM have Long Memory?, arXiv:2006.03860v2, 2020.

表 2 損失関数の精度比較

予測時間	損失関数	RMSE	R ²
1-2h	MSE (baseline)	0.418	0.940
	MAE loss	0.479	0.922
	Huber loss	0.514	0.910
	Log-cosh loss	0.451	0.931
3-4h	MSE (baseline)	0.840	0.760
	MAE loss	0.898	0.725
	Huber loss	0.935	0.702
	Log-cosh loss	0.986	0.669
5-6h	MSE (baseline)	1.084	0.600
	MAE loss	1.168	0.536
	Huber loss	1.141	0.557
	Log-cosh loss	1.153	0.548

表 3 活性化関数の精度比較

予測時間	活性化関数	RMSE	R ²
1-2h	ReLU (baseline)	0.418	0.940
	tanh	0.569	0.890
	LeakyReLU	0.345	0.959
	GELU	0.329	0.963
3-4h	ReLU (baseline)	0.840	0.760
	tanh	0.895	0.727
	LeakyReLU	0.807	0.778
	GELU	0.864	0.746
5-6h	ReLU (baseline)	1.084	0.600
	tanh	1.124	0.570
	LeakyReLU	1.084	0.600
	GELU	1.103	0.586




図 4 Conv1D 流入量予測結果