

ダム流入量の予測性能改善を目的としたニューラルネットワークによるタンク・モデルの近似

宮崎 利行¹・石井 明²・天方 匡純²

¹正会員 八千代エンジニアリング株式会社 技術創発研究所

(〒111-8648 東京都台東区浅草橋 5-20-8 CS タワー)

E-mail: ts-miyazaki@yachiyo-eng.co.jp (Corresponding Author)

²正会員 八千代エンジニアリング株式会社 技術創発研究所

ダム流入量予測に使用される機会の増えた AI モデル, 特に深層学習モデルは中身がブラックボックスで, 従来モデルを完全に置き換え可能なのかという疑問が付きまとう. また今後大雨の頻度が増える可能性を考慮すると, 訓練時に経験しなかった大出水に対応できるのかという問題も避けては通れない. 本研究では従来モデルのタンク・モデルを使用して雨量とダム流入量の関係の疑似データを作成し, ニューラルネットワークモデルの訓練・性能評価を行った. その結果訓練期間を長くすると予測誤差が減少し, 性能のばらつきが小さくなる傾向が見られた. 訓練時のダム流入量の最大値の 2 倍を超えるような出水に対しては予測性能が悪化し, 訓練データをダム流入量によって制限せず, 全てのデータを用いて訓練した場合に最善の結果が得られた.

Key Words: dam inflow, tank model, neural network, climate change, surrogate model

1. 目的

ニューラルネットワーク (以下 NN) による河川の流出モデル近似化には既に 25 年以上の歴史がある. Todini が「Brief history of hydrological models」¹⁾の中で取り上げている NN モデルの中で最も古いものは 1997 年の Shamseldin²⁾で, その Shamseldin も過去の NN による流出モデルを参照しているので, 実際にはさらに遡る. 本研究でも議論が盛んに行われている (例えば ³⁾). また Nearing⁷⁾の指摘するように従来型のモデルと AI モデルのベンチマーク比較も数多く行われており, 多くの場合で機械学習モデルの方が物理モデルなどの従来モデルより良い結果となっている. 筆者らも物理モデルの一つであるタンク・モデル⁸⁾と NN の性能比較を行い, 入力データ条件を揃えた場合, おおむね NN の方が性能が良いという結論を得ている⁹⁾.

このように NN による流出モデル近似化については長い歴史があり, おおむね従来型の物理モデルに対する優位性も認識されているが, Todini¹⁾は訓練用データセットに含まれるものよりも水位が高くなるイベントでは予測性能が劣るといった懸念をいくつかの研究例とともに示しており, これが現在でも広く信じられている. しかし筆

者らの検討例¹⁰⁾では訓練用データセットでは経験しなかったレベルの出水を NN モデルで予測できており, NN モデル構築技術の進歩によりこの懸念はある程度解消されている可能性がある. このような未経験レベルの出水に対する予測は, 気候変動により今後増加するおそれがあり¹¹⁾, 今後, 水位予測モデルにとっては重要な課題となるであろう.

また一般に出水量を時系列で観測するとほとんどの時間は平均値付近の値になり, 平均値を大きく上回る時間は短い. このような不均衡なデータでそのまま学習した機械学習モデルは大規模な出水をうまく予想できない事例が多く, 既往の研究では出水量で制限した訓練データを使用したケースが多かった. 例えば一言ら³⁾ははん濫注意水位 (6.0 m) を超えた洪水のみを学習している. このように水位を基準にして制限を加えることで訓練データの偏りを減らし, 大出水時の予測精度を改善することが期待される. 一方, 訓練データを少しでも多くするために制限を設けず, 全てのデータを学習に用いる方が良いという考え方もある.

以上のような NN による水位予測の特性を検討する場合の課題の一つとして, 大規模な出水の事例が少ないため, 訓練・評価に用いることのできるデータが少ないと

いう点があげられる。訓練データが少ない場合の NN モデルは性能にばらつきが大きく、たまたま得られたチャンピオンデータをそのモデルの性能、その時の条件設定を正しい設定として結論付けてしまう懸念がある。そのような問題を回避するために本研究では模擬的に流域の降水を生成し、それを実際の流量データでパラメータを最適化したタンク・モデル⁹⁾に inputs することにより長期間の降水量とダム流入量の関係をシミュレートした。その関係を使って NN を訓練・評価することにより、水位予測をする場合に適切な条件設定を検討した。また評価用の降水データとして、気候変動の影響を考慮して日最大降水量が現在の値よりも大きくなるようなデータセットも作成し、未経験レベルの出水への対応力も検討した。

このように疑似的な降水を用いてダム流入量の予測誤差の影響評価を行った例としては一言ら¹²⁾がある。また Tran ら¹³⁾、Contreras ら¹⁴⁾は大規模な水文シミュレーションの実行時間を短縮する目的でサロゲートモデルの構築を行っている。これらの先行研究と比較すると本研究の降水、流出モデルは単純であるため訓練期間を比較的長くとりやすく、モデル性能の統計的ばらつき、入力データの制限といった疑問点に着目した検討が行えるというメリットがあると考えられる。またこの手法を適用して Read ら¹⁵⁾のように未経験レベルの出水への対応力を高めたモデルを構築するなど宮本¹⁶⁾の「物理的方法論とデータ科学の統合」的なアプローチの足掛かりとしたいと考える。

2. モデル

本研究では著者らのこれまでの検討⁵⁾⁹⁾¹⁰⁾で NN による予測の経験がある、神奈川県宮ヶ瀬ダムへの流入量を対象とした。これまでの検討から流域で合計した降水量を入力としてダム流入量を予測することが可能であることがわかっているので、本研究でも約 100 km² の流域の平均降水量を模擬した。

(1) 降水モデル

本研究の降水シミュレーションは Burton ら¹⁷⁾を参考に Neymann-Scott Rectangular Pulses model (以下 NSRP モデル) を Python 言語で実装した。ただし流域の平均降水量を検討対象としたので、位置依存性は実装しなかった。

a) モデルの概要

実装した NSRP モデルの概要は以下のとおりである。

1. パラメータ λ の定常ポアソン過程で storm を発生させる (図- 1a)
2. 各 storm について、パラメータ v のポアソン分布で cell を発生させる。それぞれの cell の発生時点は、storm

の時刻からパラメータ β の指数分布に従って決定する (図- 1b)

3. 各 cell の持続時間、および intensity はそれぞれパラメータ η 、および ξ の指数分布に従って決定する (図- 1c) .
4. 全ての cell の intensity を足し合わせたものを total intensity (降水量) とする (図- 1d) .

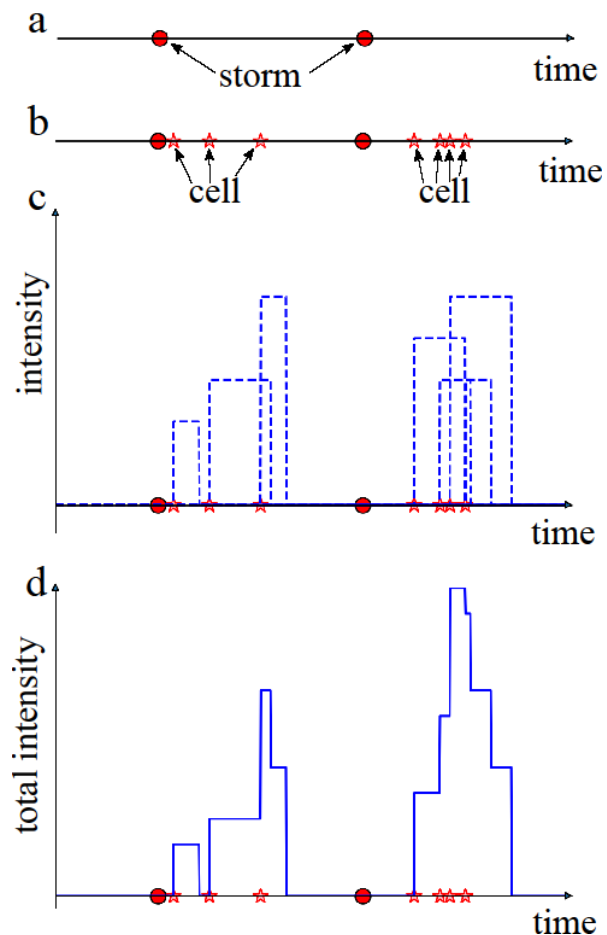


図- 1 本研究の降雨シミュレーションの概念図

b) パラメータの決定

降水モデルのパラメータはシミュレーションで生成した降水量の統計量が実際の値に近くなるように決定する。本研究では日最大降水量が多くなった場合の模擬も考慮して以下の統計量を用いた。

1. 1時間降水量の平均値
2. 1時間降水量の標準偏差
3. 1時間降水量が 30 mm を超えた回数 (1年あたり)
4. 1時間降水量が 50 mm を超えた回数 (1年あたり)
5. 日降水量が 100 mm を超えた回数 (1年あたり)
6. 日降水量が 200 mm を超えた回数 (1年あたり)

以上のパラメータの設定値からの差の絶対値を正規化して足し合わせた和が最小になるよう、Optuna^{注1)}でペイ

ズ最適化した。

気象庁は 21 世紀末の日本では年平均降水量には有意な変化は見られないものの短時間強雨（1 時間降水量 30 mm 及び 50 mm 以上）と大雨（日降水量 100 mm 及び 200 mm 以上）の発生回数が全国平均で約 2 倍以上になると予測している^{注 2)}。そこで本研究では 2006 年から 2019 年までの観測値に近くなるような降雨シミュレーションデータを 400 年分と 10 年間分作成し、それぞれ訓練データ、評価データ A とした。同様に短時間強雨と大雨の出現回数が現在の 2 倍程度、および 2.5 倍程度を目標としたデータセットを 10 年間分ずつ作成し、それぞれ評価データ B、および C とした。なお、生成した降水データについて 1 時間降水量や日降水量の発生頻度を計算すると、必ずしも目標値には届いていない。これは降水モデルの最適化時に全ての拘束条件を満たすことができなかつたためである。生成した降水量から次節の方法でダム流入量を生成したところ、2019 年台風 19 号の降水による最大値に届かなかつた。このケースでは 2019 年 10 月 12 日の一日間に 1 時間当たり降水量 30 mm 以上が 10 回、50 mm 以上が 1 回を記録する大雨となり、24 時間で短時間強雨の年平均値を上回つたためである。2006 年から 2019 年の観測値を 10 倍程度にして生成した降雨でもダム流入量の最大値は再現できなかった。そこで 2019 年 8 月から 10 月までの 3 か月間の降水記録を 1 年あたりの値に変換し、短時間強雨と大雨の発生回数がその 2.5 倍となることを目標としたデータセットを 10 年間分作成し、評価データ D とした。

観測値、および作成したデータセットの短時間強雨、大雨の 1 年あたり発生回数を表-1 に示す。

表-1 観測値、および生成したデータセットの短時間強雨、大雨の 1 年あたりの発生回数。「観測値」は 2006 年から 2019 年までの平均値。

データセット	1 年あたりの出現回数 (回)			
	1 時間降水量		日降水量	
	30 mm 以上	50 mm 以上	100 mm 以上	200 mm 以上
観測値	3.2	0.2	3.4	0.5
観測値 (2019 年 8~10 月)	40	4	16	4
訓練データ	3.3	0.2	3.0	0.4
評価データ A	3.2	0.0	3.3	0.3
評価データ B	8.5	0.6	8.2	1.5
評価データ C	10.2	1.1	7.3	1.1
評価データ D	45.7	7.9	23.9	10.1

(2) タンク・モデル

本研究では筆者らの以前の検討⁹⁾でパラメータを決定

した三段のタンク・モデルを使用して降水量に対する流出量を求めた。モデルの概要は付録に記す。表-2 は表-1 の各モデルの降水量をタンク・モデルに入力して求めたダム流入量のまとめである。ただしシミュレーションの時間分解能は 1 時間なので、表のダム流入量が 1 時間継続すると考える。生成した訓練データと評価データではダム流入量の平均値に対して最大値の値が小さいが、これは降水の季節的な偏りを考慮していないため、2、3 層目のタンクからの流出が相対的に大きくなつたためであると考えられる。また前節で述べた通り、降水量の平均値を近年の観測値に設定しただけのモデルではダム流入量の最大値を再現することができなかつた。

表-2 表-1 の各モデルの降水量をタンク・モデルに入力して得られたダム流入量のまとめ。

データセット	ダム流入量 (m ³ /s)	
	平均値	最大値
観測値	7.3	1750
訓練データ	6.2	1051
評価データ A	6.0	784
評価データ B	10.0	905
評価データ C	9.0	1039
評価データ D	21.9	1813

(3) 訓練データのダム流入量による制限

既往の研究では NN の訓練時に洪水前後期間のデータだけを使用しているケースが多い。この件について過去の文献を調査したところ Cameron ら¹⁸⁾が「Consequently, it may be necessary to develop separate neural nets for ‘high’ and ‘moderate-low’ flood events, for example.」と述べており、NN による流出予測が検討され始めた頃から制限したデータで訓練を行う方法が主流だつたようである。しかし著者らの検討では実際のデータを使った流出量予測でも訓練データに制限を加えずに訓練した NN で良好な結果が得られている。そこで本研究ではダム流入量による制限を加えない訓練データを基本として、制限を加えた場合の NN との性能比較を行った。訓練データには一言ら³⁾を参考にして、あらかじめ定めた流出量の閾値を超えた出水のピークから 72 時間前~48 時間後の範囲の値を用いた。

(4) ニューラルネットワーク (NN)

本研究ではニューラルネットワーク (NN) として scikit-learn^{注 3)} (バージョン 0.24.0) の多層パーセプトロン回帰モデル (Multi Layer Perceptron Regressor, 以下 MLPR) を使用した。本研究の入力データの規模では性能的に他の深層学習モデルと大きな違いは見られなかつた。

NN の訓練にはシミュレーションで作成した訓練デー

タを用いた。訓練データは全体で 400 年間分があるが、それを 8 年間分ごとに 50 区間に分割した。NN の訓練には分割した訓練データの各区間を用いたが、訓練期間による NN の性能の違いを見るため、一区間 8 年間分のデータから 1, 2, 4, および 8 年間のデータを抽出した。抽出の際にはそれぞれの区間でダム流入量が最大となる年を含むようにした。これにより 50 区間×4 通りで全 200 パターンの訓練データを準備したことになる。このようなデータ抽出を行ったのは、訓練期間の長さにかかわらずダム流入量の最大値を揃えるためと、訓練データの重複が起こらないようにするためである。

また NN の予測ターゲットは現時点から 12 時間後のダム流入量とし、入力データは現時点のダム流入量と現時点から 12 時間後までの降水量とした。これは筆者らが実データを用いた 12 時間後のダム流入量予測を行っており、その性能向上に本研究の成果を活用するためである。

NN のハイパーパラメータの最適化には Optuna を使用し、NN による予想と評価データの差の最大値である Max error を最小化するようにした。これはピーク値が重要となる流出量予測では性能指標として Max error が適当であるという考えに基づく。訓練期間ごとに全てのデータセットで最適化を行う代わりに、訓練期間が 1 年間の 50 通りのデータセットで最適化を行い、訓練期間が 2 年間以上の場合はその期間に含まれる 1 年間のデータで最適化したハイパーパラメータを流用した。別に比較を行ったところ、この手法でも個別にハイパーパラメータの最適化を行った場合と比較して NN の性能に大きな違いは見られなかった。

最適化の際に設定した MLPR のハイパーパラメータの範囲は隠れ層が 2~10 層、ニューロン数が 5~200 とし、活性化関数、および最適化手法はそれぞれ「relu」、および「adam」で固定した。最適化時にはハイパーパラメータの最適化同様、Max error が最小になるようにした。

以上のようにタンク・モデルの出力を訓練データとして訓練した本研究の NN は、表面的にタンク・モデルの挙動をシミュレートするサロゲートモデルである。

(5) 評価データと訓練データの最大値の比

図-2 に本研究の各評価データのダム流入量の最大値を前節で 50 区間に分割した訓練データのダム流入量の最大値で割った比（以下「評価/訓練比」とする）の箱ひげ図を示す。図の縦軸は評価データセット名で、横軸の「評価/訓練比」は値が大きいほど評価データの最大値が大きいことを示す。本研究の箱ひげ図では「箱」は第 1 四分位点から第 3 四分位点までの範囲を、「ひげ」はデータの範囲を表し、最小値、および最大値に「フェンス」を描いた。ただし「箱」から「フェンス」までの

距離が「箱」の幅の 1.5 倍を超えるときには 1.5 倍の点に「フェンス」を設け、それより離れたデータ点は「外れ値」として別に点で表した。また「箱」の内部に垂直に引かれた直線は中央値を表す。

訓練データの一区間は 8 年間であるのに対し評価データの期間は 10 年間と長いため、同じパラメータで生成した評価データ A の最大値は訓練データより大きい場合が多くなり、中央値は 1 より若干大きくなる。

図から、訓練データ A~C ではデータセットの「箱」の範囲が少しずつずれてはいるものの重なりがあるのがわかる。しかしデータセット D は他のデータセットと「箱」の部分の重なりが無い。本研究ではこの 4 種類のデータセットで評価/訓練比が 1~3 の範囲を中心に検討を行った。




図-2 評価データのダム流入量の最大値を訓練データのダム流入量の最大値で割った比（「評価/訓練比」）の箱ひげ図。A~Dは評価データセット名で横軸は評価/訓練比。本研究の箱ひげ図については本文を参照。

3. 結果

(1) 訓練期間 1 年間の場合

50 通りの 1 年間の訓練データで訓練した NN の性能を図-3 に示す。図の横軸は前述の「評価/訓練比」で、値が大きいほど訓練データの最大値が小さい。縦軸は NN による予測誤差を Max error (m^3/s) で示したものである。また A~D は評価に使用した評価データセット名を表す。図から、データセット A~C では全ての NN の Max error が $100 \text{m}^3/\text{s}$ 以下であるのに対し、評価/訓練比が大きいデータセット D では Max error の最大値が $200 \text{m}^3/\text{s}$ を超えていることがわかる。このことより Max error と評価/訓練比には正の相関がみられ、相関係数は 0.35 だった。

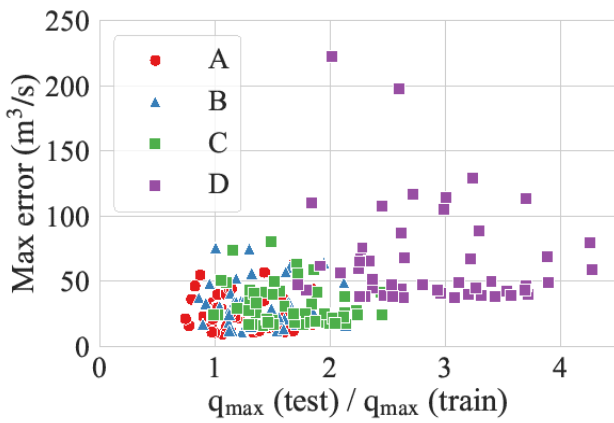


図-3 1年間分の訓練データで学習したNNの性能. 横軸は評価データと訓練データのダム流入量の最大値の比(値が大きいほど訓練データの最大値が小さい). 縦軸はNNによる予測のMax error (m³/s). A~Dは評価データセット名.




図-4 1年間分の訓練データで学習したNNの性能の評価データセットごとの箱ひげ図. A~Dは評価データセット名で横軸はNNによる予測のMax error (m³/s).

図-3の結果を評価データセットごとに箱ひげ図にまとめたのが図-4である. 縦軸のA~Dは評価データセット名を, 横軸はMax error (m³/s)を表している. データセットA~Cでは「箱」も「ひげ」の範囲もほぼ重なっており, 大きな違いは見られない. 一方, データセットDはA~Cと「箱」が重なっておらず, 「ひげ」の広がりも大きくなっている. これらの傾向は図-2と同様である. 一方どのデータセットでも下側の「ひげ」が短く, 下限値が存在しているように見えるのに対し, 上側の「ひげ」は長く, 外れ値も散見される.

このMax errorの下限値, および外れ値について調べたのが図-5である. この図は訓練期間1年間で学習したNNを評価データDに適用して予測した場合の最善ケース(青線)と最悪ケース(赤線)を示している. 図の横軸は相対時刻(1時間単位)を表し, 図-5上は真値(灰色線)との比較で, 縦軸はダム流入量(m³/s)を示す. 図-5下はそれぞれの予測の真値との差で, 縦軸はダム

流入量の残差(m³/s)である. また矢印はそれぞれ最善予測ケース(青), および最悪予測ケース(赤)の予測誤差最大点を示す. 図に示した期間は評価データでダム流入量が最大(1813 m³/s)になった時点を含んでおり, 最善ケースでも最悪ケースでも誤差が最大になったのはこの図に含まれる期間であった. 最悪ケースで誤差が最大になったのはダム流入量のピーク付近(図-5下の赤矢印)で, 誤差(Max error)の大きいNNは同様の傾向のものが多かった. 最善ケースで誤差が最大になったのはダム流入量がピークから0に戻る「裾」に相当する部分(図-5下の青矢印)だった. 最悪ケースを含む他のNNや後述の訓練データが長い場合でも同様の誤差は見られ, 図-4の下限はこの部分をうまく再現できないことによって生じている. この問題はNNの隠れ層やニューロン数を増加しても解消しなかった. 本研究では原因の追究を行わなかったがMLPRの表現力の限界による可能性があり, 今後検討したいと考える.

同様の傾向は訓練データA~Cでも見られ, 出水のピーク時からの回復を完全には再現しきれず, それがMax errorの下限値に対応する. ただし評価データA~Cの場合の下限値は約20 m³/sと評価データDの場合の50 m³/sよりも小さい.

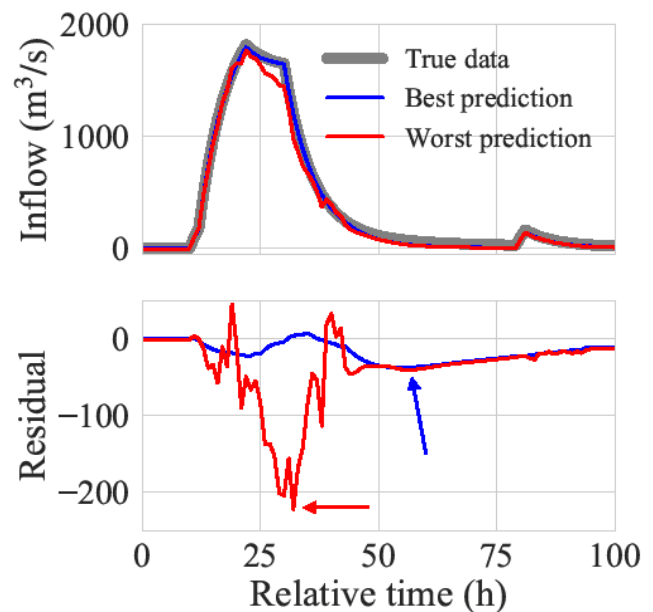


図-5 1年間の訓練データで学習したNNによる評価データDの予測値と真値の比較. 横軸は相対時刻(1時間単位). (上図)縦軸はダム流入量(m³/s)で真値(灰色)と最良予測(青), および最悪予測(赤)の比較. (下図)最良予測(青)と最悪予測(赤)の真値からの差(m³/s). 矢印はそれぞれ最善予測ケース(青), および最悪予測ケース(赤)の予測誤差最大点を示す.

図-2と図-4を比較すると、本研究で使用したMLPRでは評価/訓練比が1を超える未経験洪水で予測性能が急速に悪化するという事は無い。しかし評価/訓練比が大きくなると予測誤差が大きくなり、評価/訓練比が2を超える場合に予測誤差が大きくなる傾向が見られた。

(2) 訓練データの長さによる性能の違い

次に訓練データの長さによるNNの性能の違いについての結果を示す。なお前節で評価データセットA, B, およびCの結果には大きな違いが見られなかったこと、また訓練データの長さを変えてもその傾向に違いは見られなかったことから、本節では評価データセットA~Cの結果をまとめて取り扱う。

図-6は1, 2, 4, および8年間の訓練データ（それぞれ50通り）で訓練したNNを評価データセットA~Cに適用した場合の性能を箱ひげ図で表したものである。図の縦軸は訓練データの長さ（年）を、横軸はNNによる予測性能をMax error (m^3/s) で表している。図から、訓練データの長さが長くなるとMax errorの中央値が減少し、箱ひげ図の「箱」、 「ひげ」とも幅が小さくなることがわかる。しかし下限値に大きな変化は見られず、「箱」および「ひげ」の上限が減少している。また訓練データ長を長くしても外れ値は無くならない。訓練データを8年間にした場合のMax errorの平均値は24 m^3/s 、中央値は19 m^3/s だった。




図-6 1, 2, 4, および8年間の訓練データで学習したNNを評価データセットA~Cに適用した場合の性能の箱ひげ図。縦軸は訓練データの長さ（年）で横軸はNNによる予測のMax error (m^3/s)。

同様の箱ひげ図を評価データセットDについて作成したのが図-7である。全体の傾向は評価データセットA~Cと同じだが、Max errorの下限が図-6の場合より大きく、外れ値の広がりも大きい。訓練データを8年間にした場合のMax errorの平均値は55 m^3/s 、中央値は41 m^3/s だった。

図-6, および図-7のどちらのケースでも訓練データの

長さが4年の場合と8年の場合で大きな違いは見られず、本研究の条件では訓練データ長は4年間で十分であると言える。




図-7 1, 2, 4, および8年間の訓練データで学習したNNを評価データセットDに適用した場合の性能の箱ひげ図。縦軸は訓練データの長さ（年）で横軸はNNによる予測のMax error (m^3/s)。

図-4~図-7に見られる外れ値は訓練期間を8年にしても無くならなかった。これらは図-5の最悪ケースからも明らかのように訓練に失敗して見当違いの予想をするモデルになっているわけではない。NNによる流量予測の黎明期に Gaume and Gosset¹⁹ですでに指摘されていたように、NNは内部パラメータを乱数で初期化するため、同じデータセットで学習しても初期化の違いで性能にばらつきが生じる。これによりNNの性能にばらつきが生じた可能性があるとして著者らは考えており、現在 Gaume and Gossetの提案しているように初期値を変えたNNを複数作成することにより性能のばらつきを抑えることができないか検討を進めている。

(3) ダム流入量で制限した場合

次にダム流入量を制限した訓練データで学習したNNの性能について述べる。図-8はダム流入量を制限した訓練データ1年間分で学習したNNを、評価データセットA~Cに適用した場合の性能(Max error)の箱ひげ図である。縦軸はダム流入量を制限する際の閾値を、横軸はMax error (m^3/s)を表す。前節の同様、評価データセットA~Cの結果には大きな違いが見られなかったのでまとめて結果を示している。また閾値0は前節のモデルによる結果である。

図から、「箱」も「ひげ」も閾値0の場合が最も値が小さく幅も狭かった。従って訓練データにダム流入量による制限を設けず、全てのデータを使って学習の方が良い結果が得られると言える。なおダム流入量制限モデルのNNのハイパーパラメータは流入量を制限しない1

年間の訓練データで最適化したものと同じ値を用いたが、流入量を制限した訓練データでハイパーパラメータを最適化した場合も同様の結果が得られている。




図- 8 ダム流入量を制限した 1 年間の訓練データで学習した NN を評価データセット A~C に適用した場合の性能の箱ひげ図。縦軸はダム流入量の制限値 (m^3/s) で横軸は NN による予測の Maxerror (m^3/s)。

図- 9 は評価データセット D について同様にプロットしたものである。ただし横軸の最大値は図- 8 が $250 \text{ m}^3/\text{s}$ だったのに対し図- 9 では $600 \text{ m}^3/\text{s}$ になっている。評価データセット A~C の場合と同様、ダム流入量に制限を加えないデータで訓練した場合の性能が最も良かった。

訓練データのダム流入量を閾値 $20 \text{ m}^3/\text{s}$ で制限した場合について、訓練データの期間を 2, 4, および 8 年にして同様の性能評価を行ったところ、閾値が無い場合同様、訓練期間が長くなるに従って性能に改善が見られたが、いずれの場合も制限無しで同じ訓練期間の性能を上回ることには無かった。

以上より本研究の範囲では訓練データのダム流入量による制限は行わない方が NN の性能は良いといえる。これは従来の定説とは逆の結論である。定説とは逆の結果になった理由としては NN モデルや計算能力の進歩などが考えられるが、今後、観測値を用いた場合でも同様の結果が得られるのか検討を進める予定である。




図- 9 ダム流入量を制限した 1 年間の訓練データで学習した NN を評価データセット D に適用した場合の性能の箱ひげ図。縦軸はダム流入量の制限値 (m^3/s) で横軸は NN による予測の Maxerror (m^3/s)。

4. 結論

本研究ではダム流域の降水を模擬的に作成し、その出力を実際のダムを模擬したタンク・モデルに入力することにより 400 年間にわたる降水量とダム流入量の関係の疑似データを作成した。この疑似データを 50 分割し、訓練期間を 1~8 年間で変えて訓練した NN を、同様の手法で作成した評価データセットに適用することで訓練データと NN の性能の関係を調べた。気候変動による影響も考慮するため、短時間強雨や大雨の発生確率を現在値より大きくした評価データセットも用意した。

訓練期間を長くすると NN の予測誤差の中央値が減少し、ばらつきも小さくなる傾向が見られた。しかし学習期間が 4 年間と 8 年間では性能に大きな差は見られず、本研究のデータセットでは訓練期間は 4 年間で十分であると言える。しかし学習期間を長くしても予測誤差が外れ値のように大きくなるケースは無くならなかった。この原因に関しては観測値を用いた場合も含めて検討したいと考えている。

評価データセットのダム流入量の最大値を訓練データのダム流入量の最大値で割った「評価/訓練比」を指標とした場合、「評価/訓練比」が 2 以下のケースでは顕著な性能の差は見られなかったものの、2 以上のケースでは性能が悪化する傾向が見られた。

また本研究の NN には近似の限界があり、特に大きなピークの立下り部分の近似誤差が性能の限界となっていた。これも「評価/訓練比」が 2 以上のケースでは顕著で、未経験洪水への対応の問題の一例であると言える。

NN による流量予測の初期の時代から、訓練データに制限を設けて流量が小さい場合のデータを学習に用いない事例が多かった。その是非についても検討を行ったと

ころ、訓練データを流量で制限せず、全てのデータを訓練に用いた場合の性能が最も良いという結論を得た。これは近年の NN の進歩、計算能力の向上などが理由である可能性もあるが、今後慎重に検討を進めたいと考えている。

本研究でデータを生成したタンク・モデルはあくまでも現実を単純化したものである。従ってそれを訓練データとした NN の予想能力は限られたものであると考えられ、実際の観測データの予測に適用した場合の性能は今後評価を進める予定である。また実際の観測データを訓練データとして NN を訓練した場合に本研究と同様の結果が得られるかは今後検討を進める予定である。

謝辞：国土交通省関東地方整備局相模川水系広域ダム管理事務所の皆様には、データ提供等の協力を賜りました。深く感謝の意を表します。

付録 タンク・モデル

図-10 に本研究で使用した三段のタンク・モデルを示す⁹⁾。最上段の第1タンクが地表付近に相当し、降水 r はこのタンクに加わる。第1タンク側面には流出孔が2つあり、水位 S_1 が第1流出孔の高さ L_1 より低い場合には第1タンクから外部への流出は起こらず、第2タンクへの流出孔（流出係数は b_1 ）を通して水は第2タンクへ流出する。また $L_2 > S_1 \geq L_1$ のときには流出係数が a_1 の第1流出孔から、 $S_1 \geq L_2$ のときには第1流出孔と流出係数が a_2 の第2流出孔の両方から流出が起こる。

第2タンクについても同様で、水位 S_2 が L_3 より低い場合には流出係数 b_2 の流出孔を通して第3タンクへの流出のみが起こる。 $S_2 \geq L_3$ の場合には流出係数 a_3 の側面の流出孔から流出が起こる。

第3タンクは常時側面と底部から流出が起こっている。流出係数は側面が a_4 で底部が b_3 である。

第1タンクの2つの流出項からの流出量をそれぞれ q_{11} , q_{12} 、第2、第3タンク側面の流出項からの流出量をそれぞれ q_2 , q_3 とするとき、ダム流入量 q は

$$q = q_{11} + q_{12} + q_2 + q_3$$

で表される。

本研究のタンク・モデルのシミュレーションは Python 言語で作成した。モデルの各パラメータは実際の流域に合うように決定しており⁹⁾、表-3のとおりである。

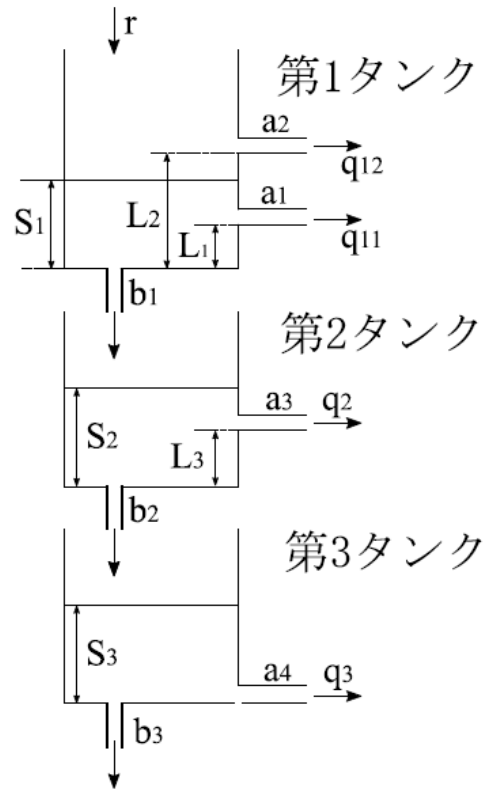


図-10 本研究で使用した3段のタンク・モデル

表-3 本研究で使用したタンク・モデルのパラメーター

a_1	0.0200	L_1	20.7
a_2	0.0181	L_2	77.3
a_3	1.01×10^{-3}	L_3	45.4
a_4	5.98×10^{-4}		
b_1	0.118		
b_2	0.0377		
b_3	0.0371		

NOTES

注1) Optuna : <https://www.preferred.jp/ja/projects/optuna/>.

注2) 地球温暖化予測情報 第9巻 : 気象庁, 2017.

注3) Scikit-learn : <https://scikit-learn.org/>.

REFERENCES

- 1) Todini, E. : Hydrological catchment modelling: past, present and future, *Hydrol. Earth Syst. Sci.*, 11 (1), pp.468-482, 2007.
- 2) Shamseldin, A.Y. : Application of a neural network technique to rainfall-runoff modelling, *Journal of Hydrology*, 199, pp.272-294, 1997.
- 3) 一言正之, 櫻庭雅明, 清雄一 : 深層学習を用いた河川水位予測手法の開発, *土木学会論文集 B1 (水工学)*, 72巻4号, pp.I_187-I_192, 2016.
- 4) 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 -ダム防災

- 操作の効率化を目指して一, 土木学会論文集 B1 (水工学), 74 巻 5 号, pp.I_1327-I_1332, 2018.
- 5) 天方匡純, 藤井純一郎, 吉田龍人, 安野貴人, 大久保順一: 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, 人工知能学会全国大会論文集, JSAI2020 巻, p.1M3GS1305, 2020.
 - 6) 三浦奈都, 宮本崇, 天方匡純, 安野貴人, 石井明: ベイズ深層学習を用いた予報雨量の不確実性を考慮したダム流入量の確率的予測, AI・データサイエンス論文集, 2 巻 J2 号, pp.933-943, 2021.
 - 7) Nearing, G. S., Kratzert, F., Sampson, A. K., Pelissier, C. S., Klotz, D., Frame, J. M., et al.: What role does hydrological science play in the age of machine learning?. *Water Resources Research*, 57, e2020WR028091, 2021.
 - 8) 菅原正巳, タンク・モデル, 地学雑誌, 94 巻 4 号, pp.209-221, 1988.
 - 9) 宮崎利行, 石井明, 宮本崇, 天方匡純: 単流域型タンク・モデルとニューラルネットワークの比較, AI・データサイエンス論文集, 2 巻 J2 号, pp.172-181, 2021.
 - 10) 石井明, 宮崎利行, 天方匡純: 土壌雨量指数の予測学習を活用した洪水予測, 土木学会論文集 B1 (水工学), 77 巻 2 号, pp.I_277-I_282, 2021.
 - 11) 佐山敬洋, 立川康人, 寶馨, 増田亜美加, 鈴木琢也: 地球温暖化が淀川流域の洪水と貯水池操作に及ぼす影響の評価, 水文・水資源学会誌, 21 巻 4 号, pp.296-313, 2008.
 - 12) 一言正之, 澤谷拓海, 植西清: 深層強化学習を用いたダム操作モデルのダム流入量予測誤差に対する影響評価, AI・データサイエンス論文集, 1 巻 J1 号, pp.459-464, 2020.
 - 13) Tran, V. N., Dwelle, M. C., Sargsyan, K., Ivanov, V. Y., and Kim, J.: A novel modeling framework for computationally efficient and accurate real-time ensemble flood forecasting with uncertainty quantification, *Water Resour. Res.*, Vol.56 No.3, 2020.
 - 14) Contreras, M. T., Giron'as, J., and Escauriaza, C.: Forecasting flood hazards in real time: a surrogate model for hydrometeorological events in an andean watershed, *Nat. Hazards Earth Syst. Sci.*, Vol.20 No.12, pp.3261-3277, 2020.
 - 15) Read, J. S., Jia, X., Willard, J., Appling, A. P., Zwart, J. A., Oliver, S. K., Karpatne, A., Hansen, G. J. A., Hanson, P. C., Watkins, W., Steinbach, M., and Kumar, V.: Process-guided deep learning predictions of lake water temperature, *Water Resour. Res.*, Vol.55 No.11, pp.9173-9190, 2019.
 - 16) 宮本崇: 物理的方法論とデータ科学の統合による科学パラダイムの深化, AI・データサイエンス論文集, 2 巻 J2 号, pp.140-151, 2021.
 - 17) Burton, A., Kilsby, C.G., Fowler, H.J., Cowpervait, P.S.P., O'Connell, P.E.: RainSim: A spatial-temporal stochastic rainfall modelling system, *Environmental Modelling & Software*, Volume 23, Issue 12, pp.1356-1369, 2008.
 - 18) Cameron, D., Kneal, P., See, L.: An evaluation of a traditional and a neural net modelling approach to flood forecasting for an upland catchment, *Hydrological Processes*, Vol.16, pp.1033-1046, 2002.
 - 19) Gaume, E., Gosset, R.: Over-parameterisation, a major obstacle to the use of artificial neural networks in hydrology?, *Hydrology and Earth System Science*, Vol.7, pp.693-706, 2003.

(Received June 30, 2022)

(Accepted August 31, 2022)

APPROXIMATION OF TANK MODEL BY NEURAL NETWORK TO IMPROVE PREDICTION PERFORMANCE OF DAM INFLOW

Toshiyuki MIYAZAKI, Akira ISHII, Takashi, and Masazumi AMAKATA

AI models, especially deep learning models, which are increasingly being used for dam inflow forecasting, are black boxes, and the question remains as to whether they can completely replace conventional models. In addition, considering the possibility that the frequency of heavy rainfall will increase in the future, it is inevitable to ask whether AI models can handle large water outflows that have not been experienced during training. In this study, a conventional tank model was used to generate pseudo data on the relationship between rainfall and dam inflow, and the neural network models were trained and their performances were evaluated. The results showed that as the training period increased, the prediction error decreased and the variability in performance tended to decrease. Prediction performance deteriorated when the outflow was more than twice the maximum dam inflow during training, and the best results were obtained when all data were used for training instead of limiting the training data by the dam inflow.