

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

宮崎 利行¹・石井 明²・宮本 崇³・天方 匡純²

¹ 八千代エンジニアリング株式会社 技術開発研究所

(〒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 技術開発研究所

³ 山梨大学 工学部土木環境工学科

従来、ダム流入量の予測手法としてタンク・モデルなどの物理モデルが使われてきた。物理モデルは実際の現象を近似する関数と考えることができるので、ニューラルネットワークで代替すれば物理モデルと同等以上の性能で予測ができるはずである。そこで本研究ではタンク・モデルとニューラルネットワークとで入力データなどの条件をできるだけ揃えた上でダム流入量予測の比較を行った。本研究のタンク・モデルは直近の観測値を用いた改良を施すことにより大規模出水時の流入量を比較的精度よく予測できた。一方、条件を揃えて訓練したニューラルネットワークはタンク・モデルと同等かそれ以上の予測精度を示した。この結果はニューラルネットワークの予測性能の下限が物理モデルで与えられることを示唆している。

Key Words: dam inflow, tank model, neural network, physical model, universal approximation theorem

1. 目的

近年、ニューラルネットワークをはじめとする AI による河川水位やダム流入量の予測の開発が精力的に進められている (例えば^{1,3)}。一方、AI がさかんに適用される以前からタンク・モデル⁴⁾、貯留関数法⁵⁾といった物理モデルにより水位や流入量の予測が行われてきた (例えば⁶⁾。これらの物理モデルは河川システムを簡略的に表現したものであるが実用的に使用され、その予測精度には一定の評価がある。

物理モデルは降水量や河川水位、あるいはダム流入量を入力とし、将来の水位予測等を出力する関数とみなすことができるから、普遍性定理よりニューラルネットワークにより任意の精度で近似できるはずである。さらに物理モデルが現実の単なる近似に過ぎないことを考慮するならば同条件で訓練したニューラルネットワークはより予測精度が高いと期待される。また物理モデルなどの従来型のモデルとニューラルネットワークを含む機械学習モデルとのベンチマーク比較は重要だという指摘も存在する⁷⁾。

以上の考察から本研究では物理モデルの中でもタン

ク・モデルに焦点を当て、ニューラルネットワークと同条件の入力データでパラメータを調整し、性能比較を行った。タンク・モデルを検討対象としたのは比較的少ないパラメータで表現でき、入力に必要なデータの次元数が少ないため最初の検討に適当であると考えたためである。

2. 入力データ

本研究では神奈川県に位置する宮ヶ瀬ダムへの流入量を対象とした。ダム流入量は国土交通省の公表している 1 時間毎の観測データを用いた。また降水量は降った雨が 60~90 分後にダムに到達する範囲^(3)の図-4)の合計値を用いた。この範囲の面積は約 100 km²である。降水量の観測値はレーダー・アメダス解析雨量の、予報値は 6 時間先までの降水短時間予報の毎正時の値を用いた。

ダム流入量予測の作成にあたっては降水量の観測値のみを用い、完全予報ができたという仮定で学習・検証を行う方法と、予測の基準時刻以前は観測値を用い、それ以降は予想値を用いるという 2 通りの方法が考えられる。

降水量とダム流入量の関係を近似するという観点からは前者の方が望ましいが、後者では誤差を含んだ予測値とダム流入量の関係を近似するため、降水量の誤差に対してより頑健であることが期待される。また実運用に近い環境での性能評価が望ましいと考えたため、本研究では後者の方法でモデルの学習・検証を進めた。

3. モデル

(1) タンク・モデル

図-1 に本研究で検討した三段のタンク・モデルを示す。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。

本研究では流域（約 100km^2 ）を1つのタンクとして取り扱うタンク・モデルを逐次的に実行するシミュレーションプログラムを Python 言語で作成した。

(2) ニューラルネットワーク

本研究ではニューラルネットワークとして scikit-learn (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。ダム流入量予測で使用例の多い tensorflow (Keras) と比較検討したところ良好な結果が得られたためである。

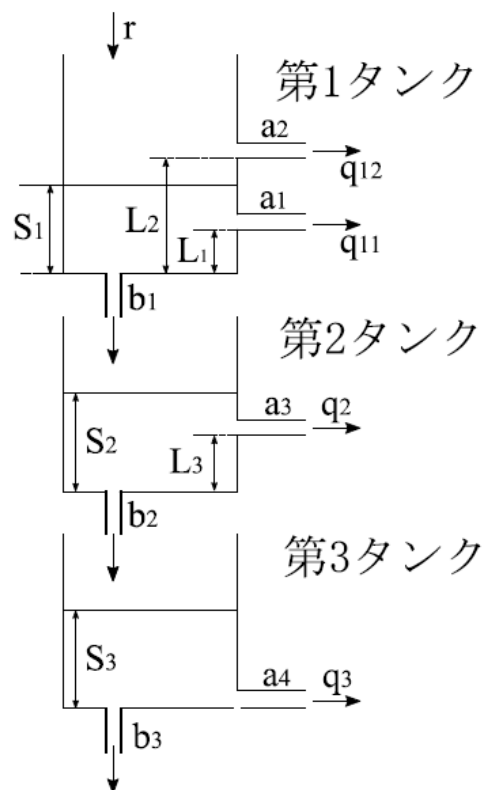


図-1 本研究で検討した3段のタンク・モデル

4. タンク・モデルの最適化

(1) 入力データ

タンク・モデルへの入力値は流域（約 100km^2 ）の降水量の合計値とした。使用したデータの時間分解能は1時間なので1時間毎の降水量を入力値とした。またタンクモデルでは各タンクの水位の初期値を外部から与える必要があるが、本研究のシミュレーションで対象としている期間よりも4年前の2006年1月1日の時点で

$$S_1 = S_2 = S_3 = 0$$

となるように設定した。

(2) パラメーターのチューニング

タンク・モデルのパラメーターのチューニングは様々な方法が提案されている（例えば⁹⁾）が本研究では計算時間と精度を考慮して最適化ツール Optuna⁹⁾を用いてベイズ推定によるパラメーターの最適化を行った。具体的には $a_1 \sim a_4$, $b_1 \sim b_3$, および $L_1 \sim L_3$ を適宜定めて2006年1月1日からタンク・モデルのシミュレーションを繰り返し実行し、2010年1月1日から2018年12月31日の間でダム流入量の観測値が $50\text{m}^3/\text{s}$ 以上だった時刻について、ダム流入量とタンク・モデルのシミュレーション結果との差の最大値 (Max error) が最小になるパラメータ

一を選択した。指標として Max Error を用いたのは Root Mean Squared Error (RMSE), Mean Absolute Error (MAE) などと比較した結果良好な成績が得られたためである。

(3) 結果

最適化の結果得られたタンク・モデルのパラメーターを表-1に示す。このパラメーターを用いて2006年1月1日開始のシミュレーションを行った。ただしタンク・モデルに入力する降水量としては観測値を用いた。検証期間の2019年1月1日から12月31日の結果から、ダム流入量の観測値が50m³/s以上だった時刻を取り出して降水量、ダム流入量と観測値、およびタンク・モデルのシミュレーション結果をプロットしたのが図-2である。しきい値を50m³/s以上に設定したのは検証データ数を十分に確保するためである。また降水量は単位面積あたりの値を示している。

表-1 最適化の結果求められたタンク・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		




図-2 ダム流入量の観測値（灰色線）とタンク・モデルのシミュレーション値（赤線），および雨量の観測値（青，縦右軸）。横軸は相対時刻で縦軸（左）はダム流入量，縦軸（右）は降水量（mm）。

図の横軸は評価期間にダム流入量の観測値が50m³/s以上だった時刻を0から順に並べた相対的な時刻で、縦軸（左側）はダム流入量，縦軸（右側）は降水量である。ダム流入量は灰色線が観測値を，赤線がタンク・モデルによる予測値を表している。相対時刻が50以降で降水量およびダム流入量が急増しているのは2019年台風19号の降水による。この台風19号によるピーク値以外は

おおむねダム流入量を再現できている。

(4) タンク・モデルの改良

前節のタンク・モデルによるダム流入量のシミュレーション結果はダム流入量の増減は説明できているものの、予測時刻が現時点である点を考慮すると性能面で物足りない。後述のニューラルネットによる1時間予測値と比較しても見劣りする。我々がその原因として考えたのはタンク・モデルの初期値をシミュレーション開始時に固定したことである。これにより各タンクの水位が実際の状況から乖離し、特に降水量が多い場合に誤差の要因となっている可能性がある。そこで本研究ではダム流入量の観測値が50m³/s以上だった時刻について5時間前から降水量の履歴を用いてモデルの改良を行った。具体的には5時間前から現時点までのタンク・モデルのダム流入量が観測値に近くなるよう各タンクの水位の初期値を最適化した。最適化はモデルの予測値と観測値のMax errorが最小になるようOptunaを用いて行った。最適化の開始時刻を5時間前としたのは後のニューラルネットワークの場合と入力データを揃えるためである。以上の改良を施したタンク・モデルによるシミュレーション結果を図-3に示す。図の諸元は図-2と同じで、青棒が降水量、灰色線がダム流入量の観測値を，赤線がタンク・モデルによるダム流入量を表す。タンク・モデルによる流入量は全て観測雨量を用いて計算した現在値である。図-2と比較すると相対時刻70前後の2019年台風19号によるピーク値がより観測値に近づいていることがわかる。




図-3 ダム流入量の観測値（灰色線）とタンク・モデルのシミュレーション値（赤線），および雨量の観測値（青，縦右軸）。横軸は相対時刻で縦軸（左）はダム流入量，縦軸（右）は降水量（mm）。

この改善結果を数値で確認するために観測値とタンク・モデルによるシミュレーション値の代表的なスコアを最適化前と後で比較したのが表-2である。この表では指標としてRMSE, MAE, Max error, および決定係数を用いている。表の値はダム流入量の観測値が50m³/s以上だった時刻の値を用いて計算した。指標のうちRMSE,

MAE, および Max error は値が小さいほど (最小値は 0), 決定係数は値が大きいほど (最大値は 1) シミュレーション値が観測値に近いことを示している。表よりいずれの指標でも最適化後の方がシミュレーション結果が観測値をより良く説明していることがわかる。

表-2 初期値最適化前と最適化後のタンク・モデルと観測値の比較。ダム流入量が 50m³/s 以上の時刻だけを取り出して比較している。RMSE は Root Mean Squared Error, MAE は Mean Absolute Error の略で, RMSE, MAE, および Max error の単位は m³/s。

	MSE	MAE	Max error	決定係数
最適化前	101	66.8	744	0.820
最適化後	84.7	47.7	416	0.874

(5) 改良型タンク・モデルによるダム流入量の予測

前節で作成した改良型のタンク・モデルに予測降水量を入力してダム流入量の予測を行った。手順としては表-1 のパラメーターで作成したタンク・モデルを, 前節で説明した手法で最適化した。最適化した期間は 2019 年 1 月 1 日以降である。最適化したタンク・モデルに 1 時間後から 6 時間後までの降水量の予報値を入力してダム流入量の予測を行った。




図-4 改良型タンク・モデルによるダム流入量の予測値。横軸は相対時刻で縦軸はダム流入量。灰色線は観測値, 赤線は 1 時間予測, 青線は 3 時間予測。

図-4, および図-5 に改良型タンク・モデルによるダム流入量の予測結果を示す。どちらの図も横軸はダム流入量の観測値が 50m³/s 以上だった時刻で縦軸はダム流入量 (m³/s) を表し, 灰色線が観測値を示している。また図-4 の赤線は観測時刻の 1 時間前に予測した 1 時間後のダム流入量を, 青線は観測時刻の 3 時間前に予測した 3 時間後のダム流入量を示している。同様に図-5 の赤線は 6 時間前に予測された 6 時間後のダム流入量を示している。

いずれの予測でも台風 19 号によるダム流入量の最大値の予測は誤差が大きくなっており, これが後述の Max

error を決定している。また 6 時間予測では相対時刻 40 付近のピークを過剰に予測している。




図-5 改良型タンク・モデルによるダム流入量の予測値。横軸は相対時刻で縦軸はダム流入量。灰色線は観測値, 赤線は 6 時間予測。

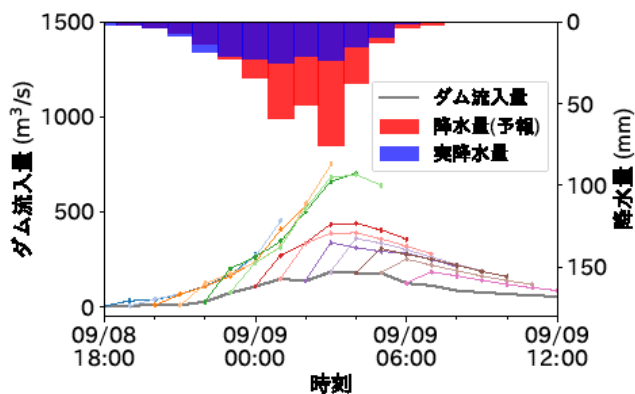


図-6 改良型タンク・モデルによるダム流入量の予測例。横軸は時刻で縦軸 (左) はダム流入量。灰色線は観測値で色付きの線は各時刻での 6 時間先までの予測。縦軸 (右) は降水量で青が実際に観測された値, 赤はその時刻に対応する降水量の 6 時間先予報値

図-5 の相対時刻 40 付近に対応するダム流入量の実績値, 予測値, および単位面積あたりの降水量を示したのが図-6 図-6 である。この図の横軸は実時刻を表している。縦軸 (左) はダム流入量で, 灰色線が実績値, 色付きの線は各時刻での 6 時間先までの予測を表す。縦軸 (右) は単位面積あたりの降水量で青が実績値, 赤がその時刻に対応する 6 時間先予報値を示す。ダム流入量の予測はどの時刻でも実績を上回っており, 過剰予測となっていることがわかる。一方降水量は 6 時間予報値が実績値より最大値で 2 倍以上となっており, これがダム流入量の予測値を過大にした原因であると考えられる。




図7 改良型タンク・モデルによるダム流入量の予測例。横軸は時刻で縦軸(左)はダム流入量。灰色線は観測値で色付きの線は各時刻での6時間先までの予測。縦軸(右)は降水量で青が実際に観測された値、赤はその時刻に対応する降水量の6時間先予報値

2019年の台風19号時について図-6と同様にプロットしたものを図-7に示す。この図でも青の降水量は実績値、赤の降水量はその時刻に対応する6時間予報値を表している。図より実降水量が最大になっている時刻で降水量の予報値が実際のより小さくなっている。このことが原因でタンク・モデルによるダム流入量の予測値が観測値よりも少なくなったと考えられる。




図8 改良型タンク・モデルによるダム流入量予測の数値評価。横軸は予測時間を表す。赤線(左軸)はMax errorを、青線(右軸)は決定係数を表す。

改良型タンク・モデルによる予測の指標による評価例を図-8に示す。この図では評価の代表的な指標としてモデルの最適化に使用したMax errorと決定係数を用いている。図の横軸は予測時間を示している。例えば「3」では3時間前に予測した3時間後の予測値と実際のダム流入量の観測値との間の指標値を計算している。赤線(左軸)はMax error (m³/s)を、青線(右軸)は決定係数を表す。Max errorは値が小さいほど、決定係数は値が大きいほど予測値が観測値に近いことを示しているため、どちらの指標でも予測時間が短いほど予測の精度が高く、

予測時間が長くなると予測精度が低くなることを示している。ここには示していないがRMSE, およびMAEについても同様の結果が得られた。

5. ニューラルネットワークの結果

本章ではタンク・モデルと比較するために作成したニューラルネットワークによるダム流入量の予測結果について示す。本研究では最大で6時間後までの予測を行ったが、1時間後～6時間後について個別のニューラルネットワークを作成して適用した場合より、1時間後を予測するニューラルネットワークを繰り返し適用した場合の方が予測精度が高いという、²⁾とは逆の傾向が見られた。

(1) 入力データ

タンク・モデルと入力値をそろえるため、降水量は流域(約100 km²)の合計値を用いた。また改良型のタンク・モデルと条件を揃えるために5時間前から現在までのダム流入量、および降水量の観測値と1時間後の予想降水量を入力して1時間後のダム流入量を予測するニューラルネットワークを作成した。2時間後のダム流入量はこのニューラルネットワークに4時間前から現在までのダム流入量、降水量の観測値、1時間後と2時間後の降水量の予報値、および1時間後のダム流入量の予測値を入力して予測した。以下この手順を再帰的に繰り返して6時間後のダム流入量まで予測した。

また学習の条件も揃えるため、2010年1月1日から2018年12月31日の間でダム流入量の観測値が50 m³/s以上だった時刻のデータを用いてニューラルネットワークを訓練し、2019年のデータで評価を行った。なお降水量、およびダム流入量は訓練期間の最大値が1、最小値が0になるように正規化した。訓練期間のダム流入量の最大値は約800 m³/sだった。

(2) モデル

前述のとおりニューラルネットワークとしてscikit-learnの多層パーセプトロン回帰モデル(MLPR)を用いた。ハイパーパラメーターはダム流入量の観測値が50 m³/s以上だった時刻のMax errorが最小になるよう、Optunaでチューニングした。他にもRMSE, MAE, および決定係数を最適化するようなチューニングを行ったが、Max errorを最小化した場合の結果が最も良好だった。MLPRモデルの主なハイパーパラメーターを表-3に示す。同様の予測をtensorflow(Keras)でも行ったが、本研究の範囲ではMLPRの方が最適な隠れ層の数が増える傾向が見られた。

表-3 作成したニューラルネットワーク（多層パーセプトロン）のパラメータ。

隠れ層	9
ニューロン数	195
activation	relu
solver	lbfgs

(3) 結果

タンク・モデルの図-4、および図-5と同様に1時間予測、3時間予測、6時間予測を比較した結果を図-9、および図-10に示す。いずれの図でも横軸はダム流入量の観測値が50 m³/s以上だった時刻を、縦軸はダム流入量 (m³/s) を表す。またどちらの図でも灰色線が観測値を示している。また図-9の赤線は観測時刻の1時間前に予測した1時間後のダム流入量を、青線は観測時刻の3時間前に予測した3時間後のダム流入量を示している。同様に図-10の赤線は6時間前に予測された6時間後のダム流入量を示している。




図-9 ニューラルネットワークによるダム流入量の予測値。横軸は相対時刻で縦軸はダム流入量。灰色線は観測値、赤線は1時間予測、青線は3時間予測。

改良型タンク・モデルの場合（図-4）と比較すると1時間予測、3時間予測ではニューラルネットワークの方がより観測値に近い値を再現できている。特に相対時刻で70付近の2019年台風19号によるピーク値はタンク・モデルよりもより観測値に近い。このピーク値は訓練期間の最大値の約2倍なので、訓練期間に経験しなかったダム流入量も予測できていると言える。一方、タンク・モデルの場合と異なり相対時刻80付近にはピークからのオーバーシュートのような現象が見られる。また、6時間予測では相対時刻45付近の比較的小さな山をニューラルネットワークは1000 m³/sを超えると予測している。この過大予測の原因はタンク・モデルの場合同様、降水の予報値が実際より大きかったためであると考えられる。




図-10 ニューラルネットワークによるダム流入量の予測値。横軸は相対時刻で縦軸はダム流入量。灰色線は観測値、赤線は6時間予測。

ニューラルネットワークによる予測の図-6、および図-7に相当するプロットを図-11、および図-12に示す。図-11のケースでは予報降水量が実際よりも大きかったため、タンク・モデルの場合同様、ダム流入量を過大に予測している。2019年の台風19号に相当する図-12の場合では予報降水量のピーク値が実際よりも少なかったためダム流入量も少なめに予測されているがタンク・モデルの場合よりは改善されている。




図-11 ニューラルネットワークによるダム流入量の予測例。横軸は時刻で縦軸（左）はダム流入量。灰色線は観測値で色付きの線は各時刻での6時間先までの予測。縦軸（右）は降水量で青が実際に観測された値、赤はその時刻に対応する降水量の6時間先予報値。

また図-12ではダム流入量の予測値が最大になる時刻は実際より1時間遅れている。これは実際の降水量が短時間に急増したことに降水量の予報が追いつかなかったため、降水量の予報値を入力とするニューラルネットワークの予測に時間的な遅れが生じてしまったためであると考えられる。

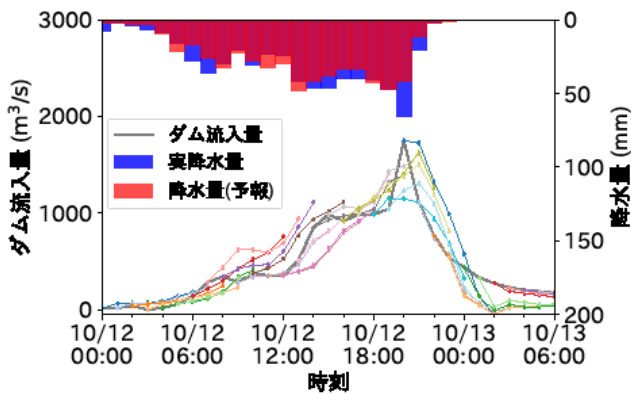


図-12 ニューラルネットワークによるダム流入量の予測例。横軸は時刻で縦軸（左）はダム流入量。灰色線は観測値で色付きの線は各時刻での6時間先までの予測。縦軸（右）は降水量で青が実際に観測された値、赤はその時刻に対応する降水量の6時間先予報値。

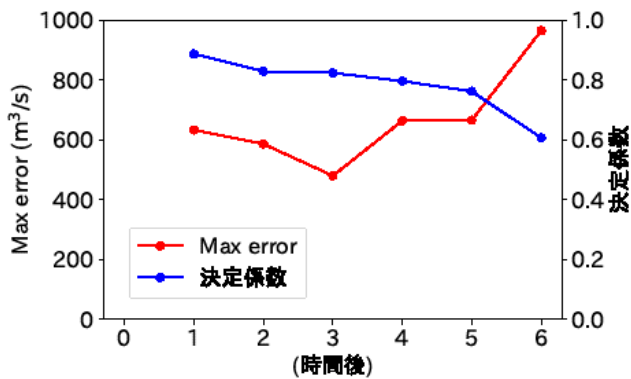


図-13 ニューラルネットワークによるダム流入量予測の数値評価。横軸は予測時間を表す。赤線（左軸）はMax errorを、青線（右軸）は決定係数を表す。

ニューラルネットワークによる予測の指標による評価を図-13に示す。タンク・モデルの場合（図-8）と同様にMax error (m³/s)と決定係数を示した。タンク・モデルの場合とは異なり、現時点の予測値は無いため1時間後から6時間後までの値を示している。タンク・モデルの場合同様、短時間の予測ほど精度が良く、6時間後の予測の精度が最も悪い。

6. タンク・モデルとニューラルネットワークの比較

本章ではタンク・モデルとニューラルネットワークによる予測結果の比較を行う。図-14に改良型タンク・モデルとニューラルネットワークによる3時間予測の比較を示す。図の横軸は2019年にダム流入量の実測値が50 m³/s以上だった時刻を、縦軸はダム流入量を表す。また図の灰色線は実測値を、赤線は改良型タンク・モデルに

よる予測値を、青線はニューラルネットワークによる予測値を示す。

この比較ではニューラルネットワークの方が降水量のピーク値をより良く予測できる傾向にある。一方、ニューラルネットワークでは2019年の台風19号によるピーク値の直後にダム流入量の予測値がオーバーシュートし負の値になっている。タンク・モデルでは原理上ダム流入量が負の値になることはありえない。




図-14 改良型タンク・モデルとニューラルネットワークによるダム流入量の3時間予測の比較。横軸は相対時刻で縦軸はダム流入量。灰色線は観測値、赤線はタンク・モデルによる予測、青線はニューラルネットワークによる予測。

同様に6時間予測の比較を図-15に示す。図の諸元は図-14と同様である。6時間予測でも2019年台風19号によるダム流入量のピーク値はニューラルネットワークの方が観測値に近いのに対し、相対時刻40付近のピーク値はニューラルネットワークの方が過剰に予測している。これは図-6、図-11のような雨量の過大な予報値に対し、ニューラルネットワークの方が誤差を拡大する傾向にあるためであると考えられる。




図-15 改良型タンク・モデルとニューラルネットワークによるダム流入量の6時間予測の比較。横軸は相対時刻で縦軸はダム流入量。灰色線は観測値、赤線はタンク・モデルによる予測、

青線はニューラルネットワークによる予測。

改良型タンク・モデルとニューラルネットワークによる予測結果を指標で比較したのが図-16～図-19である。図-16はMax errorを比較している。図の横軸は予測時間を、縦軸はダム流入量の観測値と予測との間のMax Error (m³/s)を示しており、値が小さいほど成績が良い(最小値は0)。ただし評価には2019年のダム流入量が50 m³/s以上だった期間のデータを用いている。赤線は改良型タンク・モデルの、青線はニューラルネットワークの結果である。タンク・モデルは現在値以降の予測を行っているので0時間後以降の成績があるが、ニューラルネットワークは1時間後以降の成績である。Max errorによる評価では1～3時間後はニューラルネットワークの成績が良いのに対し、4時間後以降はタンク・モデルの成績が良い。これは図-15の相対時刻40付近のピークを過大に評価していることによる。




図-16 改良型タンク・モデルとニューラルネットワークのダム流入量予測のMax errorの比較。横軸は予測時間を、縦軸はMax errorを表す。赤線はタンク・モデルの、青線はニューラルネットワークの結果を表す。

図-17では同様に決定係数の比較を行っている。この図の諸元は図-16と同様であるが、決定係数は値が大きいほど成績が良い(最大値は1)。1～5時間後はニューラルネットワークの方が成績が良いが、6時間後は改良型タンク・モデルの成績の方が良い。理由はMax errorの場合と同様である。




図-17 改良型タンク・モデルとニューラルネットワークのダム流入量予測の決定係数の比較。横軸は予測時間を、縦軸は決定係数を表す。赤線はタンク・モデルの、青線はニューラルネットワークの結果を表す。

図-18, および図-19にRMSE, およびMAEの比較結果を示す。どちらもMax errorと同じく流量の次元を持つが、評価期間を通しての平均値になるので期間最大値のMax errorより小さな値になる。どちらの指標の比較でもニューラルネットワークの方がわずかに良い成績を示しているが、予測期間が長くなるほど差が小さくなり、顕著と言えるほどの性能差は無い。これは2019年の台風19号によるピーク値の再現においてはニューラルネットワークの方が優れているが、図-6, および図-11に見られるような予報雨量値の誤差に対しては改良型タンク・モデルの挙動の方が安定していることによる。




図-18 改良型タンク・モデルとニューラルネットワークのダム流入量予測のRMSE (Root Mean Squared Error)の比較。横軸は予測時間を、縦軸はRMSEを表す。赤線はタンク・モデルの、青線はニューラルネットワークの結果を表す。




図-19 改良型タンク・モデルとニューラルネットワークのダム流入量予測の MAE (Mean Absolute Error) の比較. 横軸は予測時間を, 縦軸は MAE を表す. 赤線はタンク・モデルの, 青線はニューラルネットワークの結果を表す.

7. 結論

本研究では相模川水系の宮ヶ瀬ダムについて, 入力データを流域雨量の合計値とダム流入量に限定してタンク・モデルとニューラルネットワークで最大 6 時間のダム流入量予測の比較を行った. 雨量には 1 時間毎の観測値と 1~6 時間後の予報値を使用し, 予測の基準となる時刻以前は観測値, それ以降は予報値を用いて予測を行った. ニューラルネットワークでは降水量は予測対象の時刻まで含めて 7 点, ダム流入量は予測対象の 1 時間前までの 6 点の値を入力して予測を行った. タンク・モデルでは通常, 過去のダム流入量の実績値は活用しないため, ニューラルネットワークと条件を揃えるために予測の基準時刻から 5 時間前までの 6 点の降水量, ダム流入量の観測値を用いて直前のタンクの水位を最適化する改良を施した.

その結果, タンク・モデルとニューラルネットワークのどちらでも RMSE で $100 \text{ m}^3/\text{s}$ 程度の性能が得られた. Max error による評価では最悪値で $1000 \text{ m}^3/\text{s}$ 近い誤差があったが, これは降水量の予想値が大きく外れたために, ダム流入量の予測も過大になったと考えられる. およその傾向としてはニューラルネットワークの方が若干性能が良く, タンク・モデルより良い近似になっている.

この結果は同条件の入力データを使う場合にはニューラルネットワークの性能の下限は物理モデルの性能になるという仮説を裏付けるものである. この仮説が正しければ, タンク・モデルの性能を改善するような工夫はニューラルネットワークの性能改善にも役立つであろう.

一方, 雨量の予報値に大きな誤差がある場合にはニュー

ラルネットワークの方がより大きく影響を受け, タンク・モデルとの性能差を縮める要因となった. これは許容可能なモデルが複数存在するという「等結果性理論」¹⁰⁾の一例であると考えられる.

課題としては, 本研究では誤差を含んだ雨量の予想値を学習に使用したため, 予測誤差の原因が降水量予報値の誤差なのか, モデル自体の誤差なのか, あるいはその双方なのか明確にできなかったことがあげられる. 今後は完全予想ができた場合のモデルの性能も併せて評価するなど予測誤差の原因を切り分けやすくする方法についても検討したい.

また, 本研究では流域を一つのタンクとして取り扱ったがもっと細かい面積単位のタンクを組み合わせたり, 本研究より広い領域の降水量を使用した場合の検討, タンク・モデル以外の物理モデルとの比較検討も必要だと考える. 本研究では単純化のためニューラルネットワークとして Multi Layer Perceptron モデルに絞って検討を進めたが, Recurrent Neural Network 等の時系列データに適したモデルの検討も今後進めたい.

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. また合同会社 TYS の大庭哲哉氏にはタンク・モデルの開発で多大なご協力をいただきました. 心より感謝いたします.

参考文献

- 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, 水工学論文集, 72 巻, pp. I_187-I_192, 2016.
- 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 B 1 (水工学), 74 巻, pp. I_1327-I_1332, 2018.
- 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.
- 菅原正巳: タンク・モデル, 地学雑誌, 94 巻, pp. 209-221, 1985.
- 木村俊晃: 貯留関数法の最近の進歩, 水理講演会論文集, 22 巻, pp. 191-196, 1978.
- 白木亨, 中村幾雄, 岩永建夫: 電力ダム操作のための実時間確率出水予測モデルの実用化, 土木学会論文集, 第 399 号, pp.221-230, 1988.
- Nearing, G. S., Kratzert, F., Sampson, A. K., Pelissier, C. S., Klotz, D., Frame, J. M., Prieto, C., and Gupta, H. V.: What Role Does Hydrological Science Play in the Age of Machine Learning?, Water Resources Research, Vol. 57, e2020WR028091, 2021.

- 8) 多田毅 : PSO アルゴリズムによる流出モデルパラメータの最適化, 水門・水資源学会誌, 20 巻, pp. 450-461, 2007.
- 9) Optuna : Preferred Networks, <https://www.preferred.jp/ja/projects/optuna/>
- 10) Beven, K. : A manifesto for the equifinality thesis, Journal of Hydrology, Vol.320, pp.18-36, 2005.

(Received June 30, 2021)
(Accepted August 31, 2021)

A COMPARISON OF SINGLE-BASIN TANK MODEL AND NEURAL NETWORK

Toshiyuki MIYAZAKI, Akira ISHII, Takashi MIYAMOTO, and Masazumi
AMAKATA

Conventionally, physical models such as the tank model have been used as a dam inflow prediction method. Since a physical model can be thought as an approximate function of the actual phenomenon, it should be possible to predict performance equal to or better than a physical model if it is replaced by a neural network. Therefore, in this study, dam inflow predictions of a tank model and a neural network were compared under the conditions that input data were equal. The tank model of this study was able to predict the inflow amount at the time of large-scale flooding with relatively high accuracy by adjusting parameters using the latest observed values. On the other hand, the neural network trained with the same input data showed prediction accuracy equal to or better than that of the tank model. This result suggests that the lower limit of the predictive performance of a neural network is given by physical models.