

論文

予測学習と深層学習によるダム流入量予測の精度向上

天方 匡純¹ 石井 明² 宮崎 利行² 梁田 信河³Precision Improvement of Dam Inflow Prediction by Prediction Learning and Deep Learning
Yachiyo Engineering Co., Ltd.

Masazumi AMAKATA Akira ISHII Toshiyuki MIYAZAKI Nobuka YANADA

気候変動に伴う降雨外力増大傾向のなか、ダムの有効活用をサポートできるダム流入量の予測精度向上は喫緊の課題である。従来、ダム流入量予測モデルは既往観測データに基づきパラメータ等が最適化され実運用投入されてきた。しかし、実運用時のモデルへの入力予測雨量である。観測データと予測データは特性が異なり、現象再現を追求する従来プロセスでは実運用時の汎用性を期待できない。本稿では、予測データを用いた「予測学習」により実運用時のダム流入量を高精度に予測できること、予測学習には深層学習が効果的であることなどを示す。

キーワード: ダム流入量予測, 降水短時間予報, 予測学習, 深層学習, LSTM

1. はじめに

気候変動の進展に伴い、我が国では短時間強雨の発生回数が全ての地域および季節で増加すると予測されている¹⁾。これを証明するかのように、平成25年10月の大島町土流災害、平成26年8月の広島土砂災害、平成27年9月の関東・東北豪雨、平成29年7月の九州北部豪雨、平成30年7月の西日本豪雨、令和元年10月の東日本台風、令和2年7月の熊本豪雨と、近年、従来経験したことがない大雨の多発により、多くの水災害・土砂災害が発生している。

これらの被害軽減対策の1つとして期待されるのが既存施設の機能向上としてのダムの有効活用である。ダムの貯水能力は一度建設されると柔軟に変えられるものではないが、貯水池運用の工夫により目的ごとの効果の向上が期待できる。現在も洪水時に貯水機能を最大限に活用するため、事前放流操作や異常洪水時防災操作といった運用規定が定められている。

しかし、これらの運用は技術者個人の経験に基づく暗黙知に支えられた人的資源に全面的に依存している。このことは、団塊の世代の引退等に伴う人員不足とそ

の後の人口減少、さらには、従来とは異なる外力の発生頻度の増加に伴い、適切なダム管理を継続するに当たってのウィークポイントとなりつつある。

洪水時のダム管理者の意思決定を支援するツールとしてダム流入量予測モデルがある。ダム流入量予測に利用される手法は、一般的にタンクモデル、貯留関数モデル、分布型流出解析モデルといった物理現象を簡便化したモデルを主体とする。これらは、既往洪水に対してモデル検証してモデルパラメータを最適化する。しかし、入力条件やモデル条件等には数多くの不確実性が含まれ、これらのモデルの実運用場面ではリアルタイムの流入量再現も難しい現実がある。昨今、その不確実性を解消する手法としてベイジアン理論に基づく粒子フィルタ²⁻⁴⁾による状態方程式のデータ同化が適用され始め、予測精度向上が期待される。

一方、上下流の水文量の相関関係からダム流入量を予測する手法として、単相関、重相関、NN (Neural Network) といった手法が存在し、最近では、DNN (Deep Neural Network: 深層学習ネットワーク) を活用した研究も見られる。DNNはNNを多層化したもの

¹ 八千代エンジニアリング株式会社 技術開発研究所 所長

² 八千代エンジニアリング株式会社 技術開発研究所 社会資本空間デジタル化研究室 主任研究員

³ 八千代エンジニアリング株式会社 大阪支店 執行役員 支店長

で、現在、画像認識、音声認識、自然言語処理の分野で積極的に研究が進み、産業界への具体的適用も始まっている。各分野で適応される DNN のモデル構造はさまざまであり、洪水予測の分野でも 4 層の DNN を活用した事例⁵⁾がある。また、自然言語処理のように前後のデータの繋がりを認識する必要がある時系列データ分野の代表的モデルとして LSTM (Long Short-Term Memory)^{6,7)}が挙げられ、これらを活用した事例^{8,9)}も見られる。

しかし、いずれも革新的な予測精度向上には繋がっておらず、実運用では高々数時間先の予測精度を確保するに留まる例が多い。本稿では、従来と異なる予測フレームワークにより 6 時間先のダム流入量予測を高精度に予測できること等を示す。

2. ダム流入量予測の課題

ダム流入量予測に関する既往研究を整理するとともにその課題を整理する。

2.1 既往研究の整理

気候変動による外力変化が想定されるなか、下流域の被害最小化のためにダムの治水・利水ポテンシャルの向上は不可欠であり、ハード整備とともにソフト整備の一層の効果発現が期待される。しかし、ダム下流域で利用される河川水位予測に関わる研究と比べて、ダム流入量予測に関わる研究数は少ない。

ダム流入量予測に関わる研究テーマは大きく 2 つに分けられる。1 つ目は、ダム流入量の予測精度に関わるテーマ、2 つ目は運用に関わるテーマである。前者のダム流入量の予測精度に関わるテーマは、流出解析モデルのパラメータ最適化に関わる研究^{10,11)}、流出解析モデル以外の手法も含めた抜本的な予測手法そのものに関わる研究^{12,13)}に分けられる。一方、運用に関わるテーマは、超過洪水¹⁴⁾、気候変動モデル^{15,16)}、アンサンブル予測雨量^{17,18)}等の外力に応じて被害最小化を目指した運用の研究が進められている。

2.2 ダム流入量予測の課題

上記の既往研究の特徴は、実績データ、あるいは、シミュレーションデータといった確定データに対して予測精度や運用に関する研究を進めている点である。予測精度向上を課題とする研究では、モデル構築時と

モデル検証時で異なるデータを用意する等して、実運用時の未経験データ対応を疑似的に再現する。しかし、実運用時は確定性のあるデータではなく不確定性のあるデータを扱わなければならない。たとえば、6 時間先のダム流入量を予測する場合、ダム上流域で観測されている水位データも雨量データも原則として役に立たない。そのときに利用できるデータは気象庁が提供する降水短時間予報等の不確定性を有する予測データである。

しかし、実運用の予測行為の中で必ず生まれる現象不確定性を想定した研究は限定的であり、予測雨量が実測雨量と同じ精度まで向上した前提での研究が大半である。このような研究内容では実運用時のダム流入量予測の精度向上はいつまでも実現しない。予測が対象とするのは不確定性を持つ未来が大前提である。

3. 新しいダム流入量予測のフレームワーク

実運用にてダム流入量を予測するためには、基本的には予測システムへの入力値として予測雨量が必要となる。しかし、予測雨量は不確定性を有し扱いにくいいため、一般的にはダム流入量予測モデルの構築時には予測雨量を利用せず不確定性を考慮しないモデルを構築する。つまり、既に観測された雨量とダム流入量の関係からモデルを構築する。この結果、入力値である予測雨量の不確定性がある程度低減して初めて、構築時に期待した予測精度を実運用時に確保できるダム流入量予測モデル、あるいは、システムができて上がる。このフレームワークでは、予測雨量の精度が向上するまでダム流入量予測は実効力を持たないことになり、気候変動による外力増大が顕著化するなか、さまざまなステークホルダーの QOL (Quality of Life) 向上が先送りとなる。そこで、本稿では予測雨量の不確定性を考慮に入れたダム流入量予測モデルを構築する。

図-1 の上図は従来の予測モデルのフレームワークを示している。可能な限り既往現象の再現性の高いモデルを構築するため、モデル構築のために利用する入力値と出力値はいずれも観測値である。この結果、過去に発生した出水に対しては適合度の高いモデルが構築される。しかし、実運用時に入力値となる不確定性のある予測雨量に対する出力精度は保証されていないモ

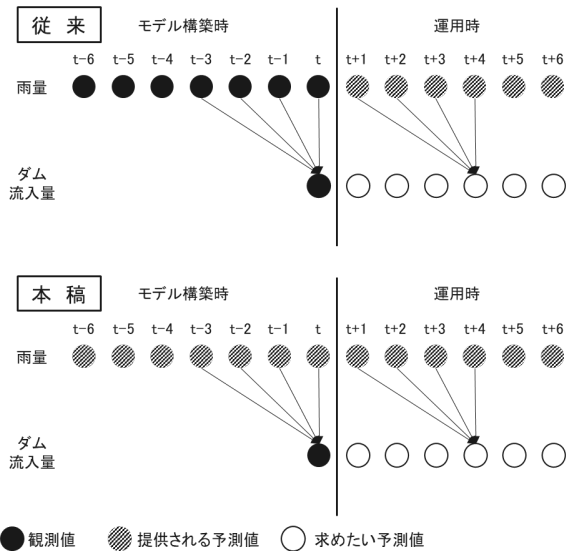


図-1 従来と本稿のダム流入量予測フレームワーク

デルが構築される。

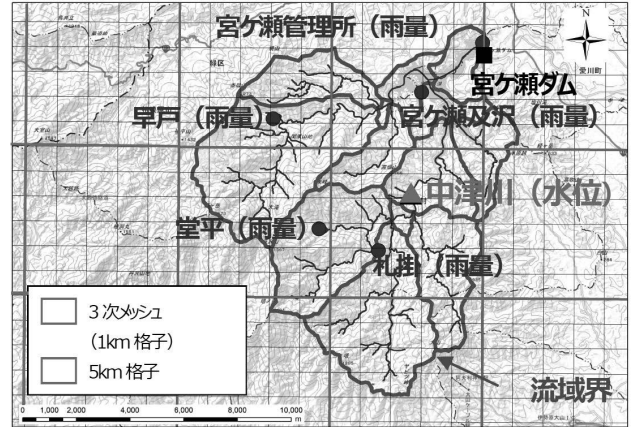
一方、図-1 の下図が本稿での提案フレームワークである。モデル構築時から予測雨量の不確定性と向き合うことで実運用時の予測精度を確保しようとするものである。具体的には、実運用時と同様に不確定性のある予測雨量を入力値とし、観測値であるダム流入量を教師としてモデルを構築する。このため、モデル構築時の入力値が観測値のときと比較してモデル精度は低下する可能性がある。しかし、モデル構築時から予測雨量を活用したダム流入量予測精度確保を目指すため、モデル構築時と実運用時とのデータ環境格差が小さく、モデル構築時と実運用時の予測精度を同様にできる可能性が高まる。このように不確定性を有する予測データを含めてモデル学習・構築する行為を本稿では「予測学習」と呼ぶ。

なお、本稿では、モデル構築にあたり、作業労力が小さく、応用性の高い、NN と DNN を用いる。2 つのネットワークを用いる理由は「予測学習」を進めるに当たり、DNN の有効性を示すためである。

4. 対象流域および利用データ

4.1 対象流域

本稿で取り扱う流域は、神奈川県を流れる一級水系である相模川水系中津川に位置する宮ヶ瀬ダムの上流域である（図-2）。宮ヶ瀬ダムの貯水池は同一水系内の相模川、道志川と相模導水で連携接続されているが、



注)降水短時間予報の5kmメッシュは3次メッシュが縦6つ、横5つと定義される。

図-2 宮ヶ瀬ダム上流域概要図

表-1 本稿で活用した水位・雨量データ

	データ名称	データ種類	空間解像度	観測/予測	時間単位	本稿でのデータ利用期間
1	中津川水位	水位	ポイント	観測	時間	2010/01/01~2019/12/31
2	ダム流入量	流量	ポイント	観測	時間	2010/01/01~2019/12/31
4	レーダー・アメダス解析雨量	雨量	5kmメッシュ	観測	時間	2010/01/01~2019/12/31
5	降水短時間予報	雨量	5kmメッシュ	予測	時間	2010/01/01~2019/12/31

これらを含まない宮ヶ瀬ダム単独流域面積は 101.4 km² である。図-2 に示す通り、対象流域はほぼ円形の放射状流域であり、流域内には水位観測所が 1 箇所、雨量観測所が 5 箇所ある。ダム地点までの洪水到達時間は既往データ整理より約 1 時間程度である。

4.2 利用データ

本稿で活用するデータ諸元を表-1 に示す。2010 年 1 月～2019 年 12 月までを本稿の検討対象期間とする。現時刻 t 以前の確定性のある観測データは水位データとダム流入量データ、そして、レーダー・アメダス解析雨量である。また、不確定性を持つ予測データとして、予測雨量（降水短時間予報）を用いる。レーダー・アメダス解析雨量は、1 km メッシュ単位の毎正時 00 分および 30 分の前 1 時間雨量配信であり、降水短時間予報は、1 km メッシュ単位の毎正時 00 分および 30 分を初期時刻とする 6 時間先までの 1 時間雨量予測値である。本稿では、これらの毎正時 00 分のみ 1 km メッシュ雨量値を平均して図-2 に示す 5 km メッシュ単位として用いる。

対象とする洪水は宮ヶ瀬ダムの洪水量 100 m³/s を超

表-2 29 出水の概要

洪水 No.	ダム流入量が100m ³ /sを超えている期間			備考
	出水開始日時	ピーク流入量 (m ³ /s)	順位	
1	2010/9/23 12:00	139.80	23	学習洪水
2	2010/11/1 4:00	137.19	24	
3	2011/7/19 19:00	348.73	9	
4	2011/9/3 5:00	152.71	22	
5	2011/9/3 20:00	163.37	19	
6	2011/9/21 12:00	655.16	4	
7	2012/6/19 20:00	576.24	5	
8	2012/7/14 4:00	283.18	10	
9	2012/9/30 23:00	115.97	28	
10	2013/4/6 23:00	242.05	13	
11	2013/9/15 10:00	136.71	25	
12	2013/9/16 6:00	278.98	11	
13	2013/10/16 2:00	387.11	7	
14	2014/6/6 20:00	234.32	15	
15	2014/10/6 3:00	373.63	8	
16	2014/10/14 0:00	168.08	18	
17	2015/7/16 8:00	156.54	20	
18	2015/7/17 0:00	174.01	17	
19	2015/9/9 6:00	467.70	6	
20	2015/12/11 9:00	153.09	21	
21	2016/8/22 11:00	765.87	2	
22	2016/9/20 19:00	122.33	27	
23	2017/8/8 1:00	133.53	26	
24	2017/10/22 12:00	702.28	3	
25	2017/10/29 21:00	109.19	29	
26	2018/3/9 0:00	178.35	16	
27	2019/5/21 8:00	274.10	12	検証洪水
28	2019/8/15 21:00	236.26	14	
29	2019/10/12 6:00	1749.78	1	




図-3 本稿で扱うダム流入量ハイドログラフ

過し、かつ、データ欠測等を考慮した 29 出水とした (表-2, 図-3)。なお、洪水量超過期間の前 12 時間と後 6 時間を加えた期間を 1 洪水期間とした。

5. 従来のダム流入量予測

本章では、ダム流入量予測を実施するにあたり、これまでの NN と DNN の慣例的な利用方法を前提に両者

の特性を比較する。図-1 の従来フレームワークではモデル構築時に観測値を、運用時に予測値を用いることとしている。しかし、このフレームワークに従い運用時に予測値を用いると予測精度が悪くなるため、実運用の場面では予測値を用いず観測値のみで予測することが多い。本章ではこの慣例に習い、運用時も観測値のみを用いて予測する。

5.1 従来のダム流入量予測のフレームワーク

NN や DNN を用いる際の従来のダム流入量予測のフレームワークは、現時刻 t の時点で得られる過去を含めた水位や雨量の観測値を入力とし、洪水到達時間を活用してリードタイム分のダム流入量 (出力値) を予測するものである。本章では入力値 (現時刻 t 以前) を中津川水位、ダム流入量、レーダー・アメダス解析雨量とし、出力値 ($t+1 \sim t+6$) をダム流入量とする。また、実運用では既往洪水の学習を経てリアルタイムの予測を迎える現実を踏まえ、ダム流入量予測モデル構築には 2010~2018 年の 26 洪水を用い、検証には表-2 のデータセット上の最新年データ扱いとなる 2019 年の 3 洪水を用いた。

5.2 NN の概要

これまでダム流入量予測や洪水予測に用いられてきた NN は中間層を 1 層とするものが大部分である。NN は、ニューロンと sigmoid 関数を 1 セットとして複数個並べて 1 層を形成し、さらにこれを複数層化することで非線形度を上げることができる。しかし、深層学習が世に出る前は、各ニューロンの重みを決定する backpropagation の計算効果が複数層では適切に機能せず、NN は中間層を 1 層とするのが通例である。そこで、本稿においても NN 構造は図-4 に示す中間層 1 層とし、既往文献¹⁹⁾を参考にニューロン数を 7 個とする。最適化アルゴリズムは Adam ($\alpha=0.001, \beta_1=0.9, \beta_2=0.999, \epsilon=1e-08$) とし、学習回数は 200 回とした。学習回数 200 回未満で過学習傾向を確認した場合は、その直前で定まるネットワーク条件を最適とした。

5.3 DNN の概要

DNN には LSTM ネットワークを用いる。LSTM は時系列データで重要となるデータの前後関係性を保持できる再帰型構造を有する。NN では恣意的に前後関係を保持する入力データセットを準備する必要があるが、

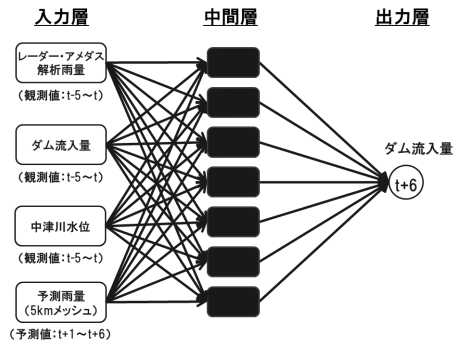


図-4 NN の構造

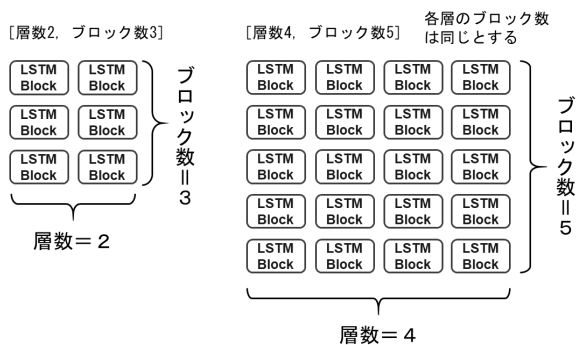


図-5 LSTM ネットワークの構造


LSTM では時系列データそのままを入力とすることができる。ネットワークは複数 LSTM ブロックからなる複数層で構成され、層が追加されるごとに活性化関数を介してネットワーク全体の非線形性が高まり、教師データに応じて情報抽出力が高まる。

ネットワークの層数と LSTM ブロック数の組み合わせに対して最適な組み合わせを検討する。ネットワーク探索は、層数が 1~5、ブロック数が 1~20 の組み合わせ総当たりとし、各層のブロック数は同一とする。たとえば、図-5 に示す層数=2、ブロック数=3 の場合は、中間層が 2 層で各層のブロック数が 3 個のネットワークとなる。この組み合わせは、層数が 1~5、ブロック数が 1~20 の網羅的探索の中で最小 loss の [層数、ブロック数] の組み合わせを選定する。中間層間には活性化関数 relu を配置し、最終中間層と出力層の間のみ恒等関数を配置した。最適化アルゴリズムは NN と同様である。


5.4 両者の比較

ダム流入量予測結果は現時刻 t より先の予測分として t+1~t+6 の 6 時間先までをターゲットとする。ただし、本章では現時刻 t において t+1~t+6 のダム流入量

【予測に観測データのみを活用（従来手法）】



【予測に予測データも活用（予測学習）】



<凡例>
 ■ 現時点以前の実測値 ● T=tで追加される予測値
 ↑ ダム流入量 (t+6) 予測時に利用する予測データの選択

図-6 予測データの利用パターン

を予測する場合、どのリードタイムに対しても現時刻 t 以前の観測データのみを活用する。その際、現時刻 t から遡って活用するデータパターンを考慮した。具体的には図-6（従来手法）に示す通り、パターン 1 からパターン 6 までのデータ形式 6 例を検討する。そして、パターンを考慮した上でダム流入量予測の計算ケースごとに層数、ブロック数、RMSE (Root Mean Square Error (二乗平均平方根誤差)) を整理したものを表-3 に示す。また、ダム流入量予測結果をグラフ化したものを図-7、図-8 に示す。ここでは、実測値と予測値の違いを明確に示すため、1~6 時間先の予測水位を一つのグラフに表現する髭図と呼ばれるグラフ表現ではなく、実測値と予測値の比較グラフを示した。このグラフは、表-3 のリードタイムごとのネットワークの中から RMSE が最小となるネットワークを選定し、その予測結果を

示したものであり、横軸に1時間ごとの経過時間を示し、縦軸にダム流入量 (m^3/s) を示している。なお、経過時間は洪水期間を単純に並べたものであり連続時間ではない。また、グラフ中に示す四角囲いの情報は、予測グラフを算出した最適な NN や DNN のネットワーク構造 (LSTM ブロック数、層数) と RMSE を示した。

6. 予測学習によるダム流入量予測

本章では、図-1 の下図に示すフレームワークに従いダム流入量を予測する。

6.1 予測学習のダム流入量予測のフレームワーク

図-1 では予測学習のモデル構築時 (学習時) に予測値のみを用いる記述であるが、本章では予測値の学習効果を明確とするため、予測値に加えて前章の従来手法で用いた現時刻 t 以前の情報も学習してモデル構築する。このため、予測学習時のダム流入量予測のフレームワークは、現時刻 t の時点で得られる過去および未来の水位や雨量の観測値を入力とし、リードタイム先のダム流入量を予測することになる。なお、入力値を中津川水位 (現時刻 t 以前)、ダム流入量 (現時刻 t 以前)、レーダー・アメダス解析雨量 (現時刻 t 以前)、降水短時間予報 ($t+1 \sim t+6$) とし、出力値をダム流入量 ($t+1 \sim t+6$) とする。学習・検証の洪水の考え方や NN と DNN の条件については、5 章と同様とする。

6.2 両者の比較

ダム流入量予測結果は現時刻 t より先の予測分として $t+1 \sim t+6$ の 6 時間先までをターゲットとする。そして、たとえば、現時刻 t において $t+6$ のダム流入量を予測する場合、 $t+6$ から遡って活用するデータパターンを考慮した。具体的には図-6 (予測学習) に示す通り、パターン 1 からパターン 6 までのデータ形式 6 例を検討する。そして、パターンを考慮した上でダム流入量予測の計算ケースごとに層数、ブロック数、RMSE を整理したものを表-4 に示す。また、ダム流入量予測結果をグラフ化したものを図-9 と図-10 に示す。

7. 結果の考察

7.1 従来手法の考察

上下流の観測データの相関関係よりリードタイムを確保する手法では、予測データを用いず洪水到達時間

分のリードタイムを活用することが一般的である。これは、観測データ間の関係を重視するためである。

表-3、図-7、図-8 は観測値のみを活用して、現時刻 t から 1~6 時間先までのダム流入量予測を検討した結果である。図-7 は NN による計算結果、図-8 は DNN による計算結果である。宮ヶ瀬ダム上流域の洪水到達時間は 1 時間程度であるため、観測値のリードタイム効果は 1 時間程度である。これを証明するように、図-7 と図-8 の何れも 1 時間先のダム流入量予測ハイドログラフ形状は、ピーク値は捉えられていないが比較的適切に再現されている。しかし、それ以降はリードタイムが大きくなるにつれて予測精度が劣化する。この様子は図-11 の `orig_method:NN`, `orig_method:DNN` を見ても確認できる。図-11 は横軸にリードタイム、縦軸に各モデルのリードタイムごとの RMSE をプロットしたものである。`orig_method` 系は現時刻までの観測値のみを活用して構築したモデル、`pred_method` 系は予測雨量を含めて構築したモデルを示し、それぞれネットワークの違いとして NN および DNN を区別している。この図-11 より `orig_method` 系の DNN は NN よりも一貫して RMSE が小さくモデル精度が良いことを確認できる。ただし、本稿における RMSE とダム流入量予測ハイドログラフ形状との関係から RMSE は 100 未満が実用的と思われ、2019 年の 3 洪水に対する `orig_method` 系でこれを満たすものは NN も DNN も 1 時間先予測のみである。かつ、1 時間先予測では最小 RMSE の NN と DNN では大きな予測精度の差はない。図-7 と図-8 の 1 時間先予測の NN と DNN の予測ハイドログラフ形状を見ても大きな違いはない。図-12 はリードタイムごとに観測値や予測値を何個活用すれば精度が良いかを確認するための整理であるが、`orig_method` 系において各リードタイムで特別有効なデータ数は確認できない。一方、`orig_method` 系のデータは、2 時間先のリードタイムで RMSE が 100 を越え、リードタイムが大きくなるにつれて RMSE、すなわち、予測精度が悪くなることを確認できる。

7.2 予測学習の考察

これまでリアルタイムの現場で利用できるデータは限定的であり、予測データ精度も未熟であった。この結果、ダム流入量予測モデルは現象再現性が追求され、

表-3 リードタイムごとのネットワーク選定プロセス

[Original Method:NN]

リードタイム	selected time range																								平均値				
	1				2				3				4				5				6								
	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE					
1時間先	1	7	7	86.5	1	7	7	79.4	1	7	7	98.6	1	7	7	93.1	1	7	7	98.8	1	7	7	108.1					94.1
2時間先	1	7	7	142.9	1	7	7	122.9	7	1	146.3	1	7	7	152.2	1	7	7	167.3	1	7	7	151.0					147.1	
3時間先	1	7	7	176.5	1	7	7	164.2	1	7	7	179.6	1	7	7	186.9	1	7	7	192.8	1	7	7	174.5					179.1
4時間先	1	7	7	197.5	1	7	7	188.9	1	7	7	199.6	1	7	7	205.3	1	7	7	209.4	1	7	7	199.2					200.0
5時間先	1	7	7	215.5	1	7	7	204.5	1	7	7	215.0	1	7	7	217.3	1	7	7	218.4	1	7	7	224.4					215.8
6時間先	1	7	7	223.4	1	7	7	213.8	1	7	7	222.6	1	7	7	221.9	1	7	7	229.9	1	7	7	240.6					225.4

[Original Method:DNN]

リードタイム	selected time range																								平均値				
	1				2				3				4				5				6								
	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE					
1時間先	2	10	100	80.2	1	16	16	69.5	4	15	50625	61.9	2	15	225	67.4	2	20	400	68.9	3	12	1728	70.8					69.8
2時間先	2	5	25	122.3	1	4	4	111.4	4	3	81	110.1	5	20	3E+06	118.7	2	10	100	109.2	4	20	2E+05	116.0					114.6
3時間先	3	20	8000	144.9	2	3	9	144.0	2	14	196	146.5	5	12	2E+05	132.4	3	7	343	146.5	3	17	4913	153.5					144.6
4時間先	2	16	256	180.0	3	3	27	172.7	3	16	4096	149.1	4	20	2E+05	164.2	2	3	9	179.7	4	16	65536	180.2					171.0
5時間先	3	19	6859	187.9	3	19	6859	180.2	4	18	1E+05	192.3	5	4	1024	198.9	1	4	4	200.8	4	14	38416	194.9					192.5
6時間先	2	20	400	202.9	4	1	1	204.2	3	16	4096	205.8	3	15	3375	208.4	4	12	20736	208.3	4	18	1E+05	197.0					204.4

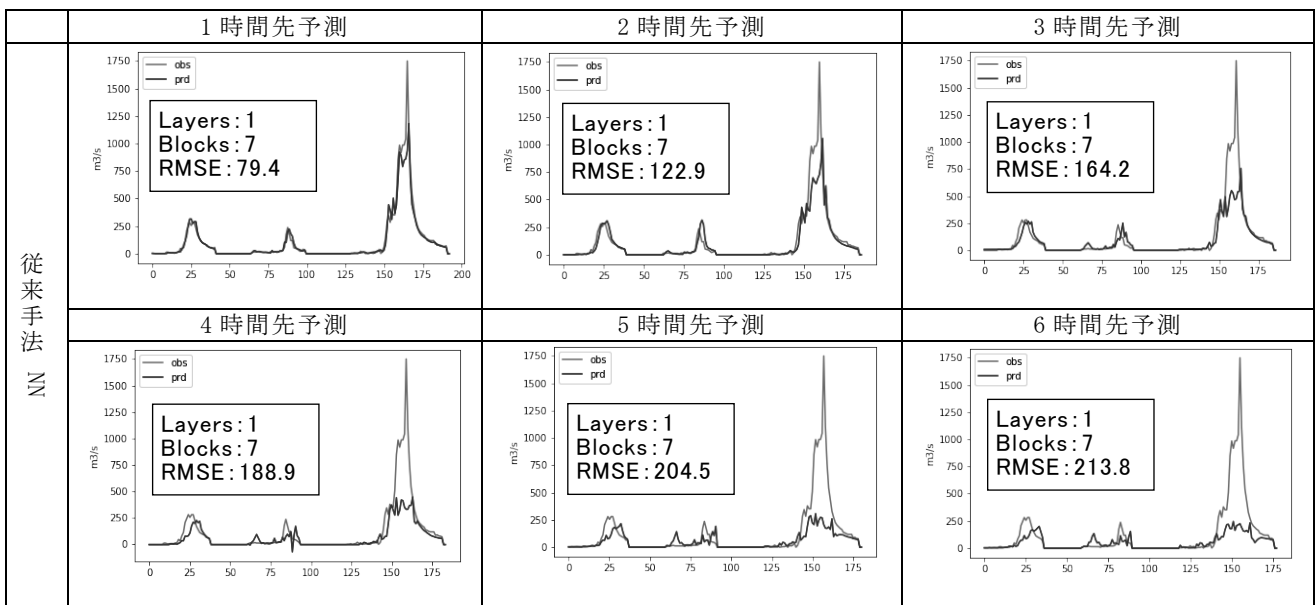


図-7 予測時間ごとのダム流入量予測（従来手法 NN）[縦軸：流量（m³/s），横軸：時間（1hrピッチ）]

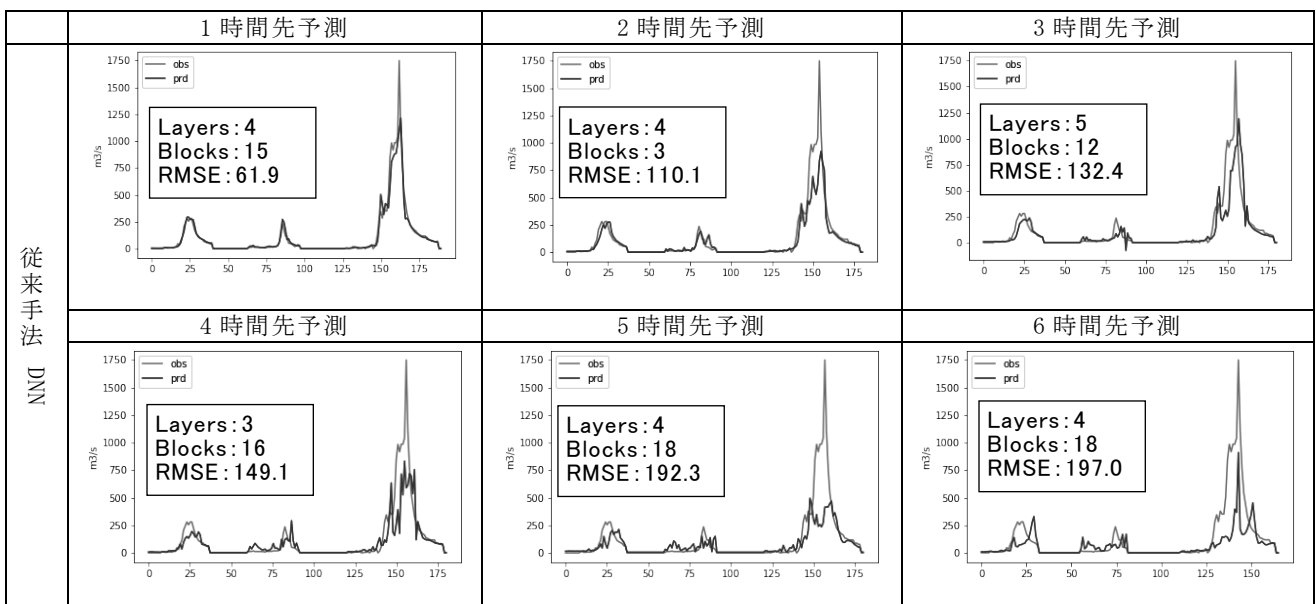


図-8 予測時間ごとのダム流入量予測（従来手法 DNN）[縦軸：流量（m³/s），横軸：時間（1hrピッチ）]

表-4 リードタイムごとのネットワーク選定プロセス

[Prediction Learning:NN]																									
リードタイム	selected time range																								平均値
	1				2				3				4				5				6				
	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	
1時間先	1	7	7	81.4	1	7	7	75.4	1	7	7	76.2	1	7	7	82.1	1	7	7	84.0	1	7	7	78.8	79.6
2時間先	1	7	7	109.8	1	7	7	102.6	1	7	7	94.7	1	7	7	107.4	1	7	7	97.4	1	7	7	94.0	101.0
3時間先	1	7	7	104.1	1	7	7	107.7	1	7	7	90.0	1	7	7	101.9	1	7	7	85.6	1	7	7	102.0	98.5
4時間先	1	7	7	107.8	1	7	7	92.1	1	7	7	89.9	1	7	7	96.0	1	7	7	90.5	1	7	7	91.2	94.6
5時間先	1	7	7	126.3	1	7	7	119.7	1	7	7	102.0	1	7	7	100.3	1	7	7	94.4	1	7	7	96.2	106.5
6時間先	1	7	7	171.2	1	7	7	125.6	1	7	7	108.6	1	7	7	90.7	1	7	7	90.1	1	7	7	93.6	113.3

[Prediction Learning:DNN]																									
リードタイム	selected time range																								平均値
	1				2				3				4				5				6				
	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	layers	blocks	index	RMSE	
1時間先	4	3	81	72.9	4	6	1296	52.3	3	18	5832	55.0	1	11	11	57.8	2	13	169	60.8	2	13	169	52.4	58.5
2時間先	4	18	1E+05	91.8	3	10	1000	77.8	5	18	2E+06	70.8	2	18	324	78.5	2	11	121	62.5	4	9	6561	67.3	74.8
3時間先	1	20	20	99.7	4	7	2401	76.7	3	3	27	73.6	3	11	1331	71.3	2	5	25	66.2	2	8	64	61.3	74.8
4時間先	1	11	11	102.0	3	10	1000	76.0	3	3	27	65.2	2	11	121	62.0	1	5	5	61.2	1	11	11	64.1	71.8
5時間先	1	17	17	106.5	4	4	256	90.9	2	2	4	69.7	4	1	1	78.9	1	8	8	74.9	2	4	16	67.3	81.4
6時間先	1	17	17	149.2	4	1	1	101.8	2	5	25	88.9	1	15	15	72.9	1	19	19	85.7	2	1	1	79.5	96.3




図-9 予測時間ごとのダム流入量予測 (予測学習 NN) [縦軸：流量 (m³/s), 横軸：時間 (1hrピッチ)]




図-10 予測時間ごとのダム流入量予測 (予測学習 DNN) [縦軸：流量 (m³/s), 横軸：時間 (1hrピッチ)]

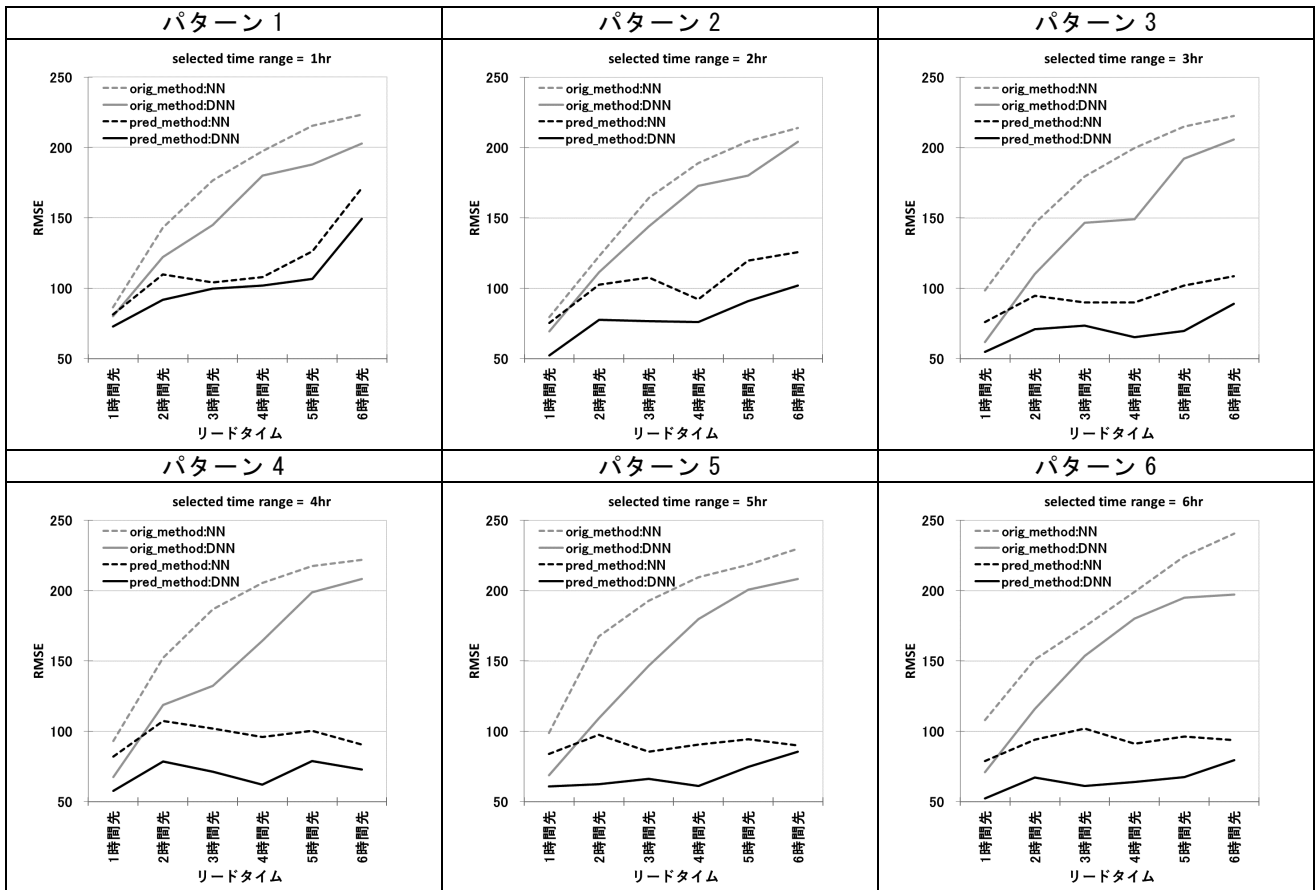


図-11 データパターンごと (図-6 参照) のリードタイムと RMSE の関係

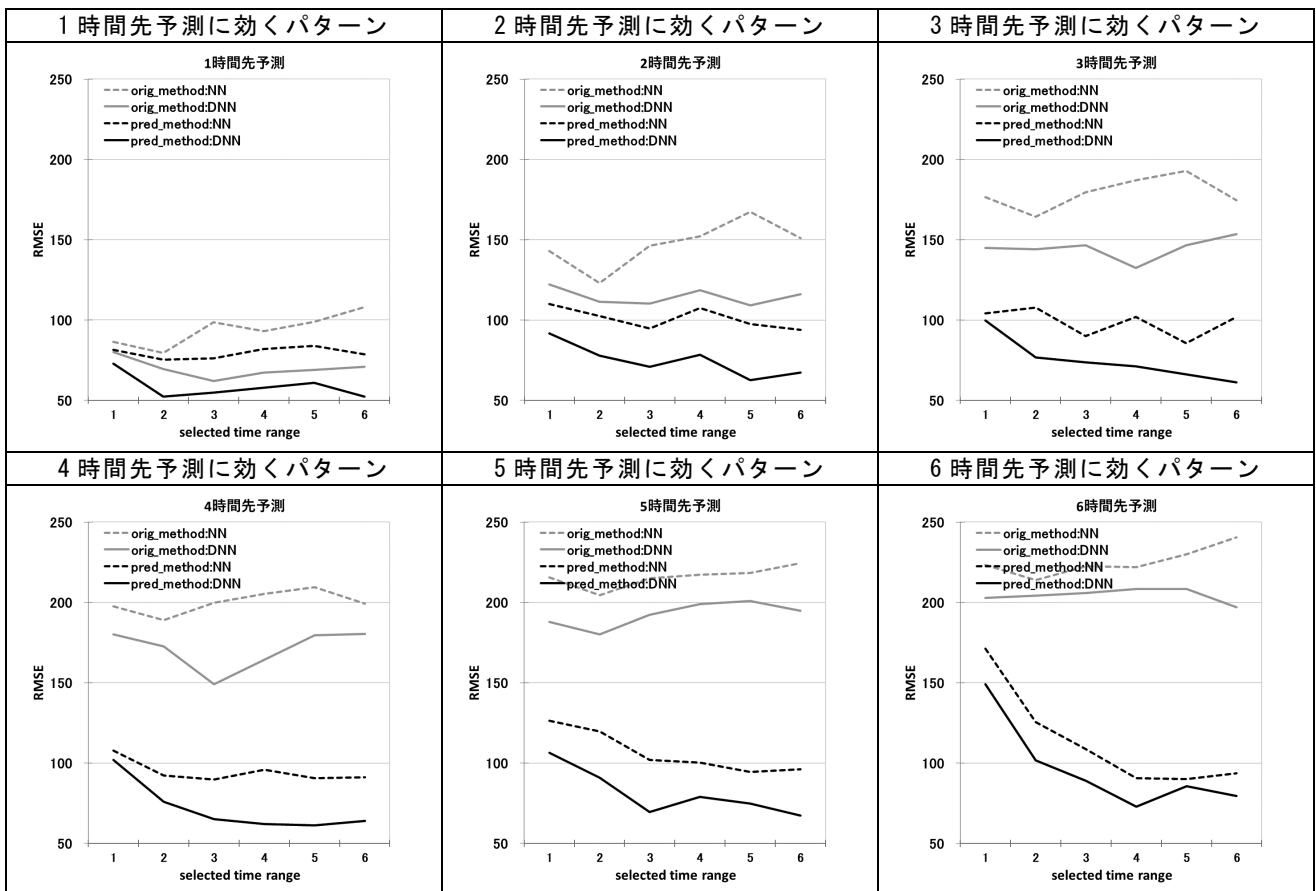


図-12 各リードタイムの予測精度に関するデータパターン (図-6 参照) と RMSE の関係

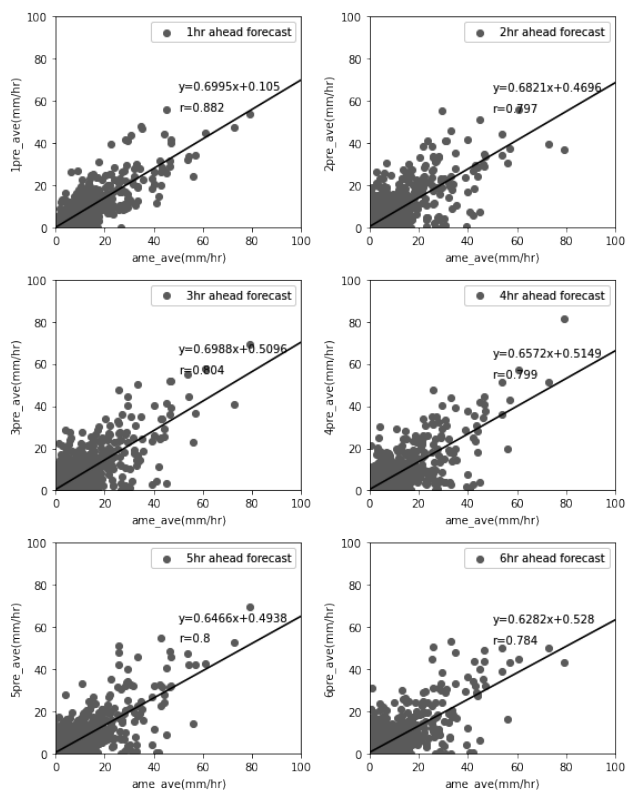


図-13 降水短時間予報 (mm/hr) とレーダー・アメダス解析雨量 (mm/hr) の関係

そのモデルを予測に活用するプロセスが主となった。このプロセスは、現象再現で活用するデータと予測で活用するデータが同質・同等であれば合理的である。しかし、実現現象を刻印した観測値と気象シミュレーション等で表現される予測値とでは、そもそもデータとしての特性が大きく異なる。つまり、現象再現と予測で活用するデータの同質性・同等性は保持されない。図-13 は予測値である降水短時間予報 (mm/hr) を縦軸に、観測値であるレーダー・アメダス解析雨量 (mm/hr) を横軸にして、散布図として比較したものである。互いに宮ヶ瀬ダム流域に関わるメッシュ雨量を単純平均して流域平均雨量とし、表-1 に整理した 29 洪水を対象とした。縦軸の降水短時間予報は 1~6 時間先ごとの予測雨量を示し、1~6 時間先の予測雨量ごとにグラフを変えている。グラフ中の文字は、降水短時間予報とレーダー・アメダス解析雨量の近似式と相関係数を示している。リードタイムが大きくなってもレーダー・アメダス解析雨量と降水短時間予報の相関が大きく悪化することはないが、両データ間には必ず誤差が介在している。このように観測値と予測値は異なる

ものであることを認識し、観測値と予測値を異なるデータとして扱うことが合理的である。

この合理性を無視して、従来手法に則って予測データを扱った場合、機械学習分野でいう所の汎化性の確保が難しい。機械学習分野では汎化性を確保するために最大限の努力を払い、汎化性を確保するためのさまざまな工夫が考えられている。ただし、その本質的な所は、学習データとテストデータの同質性・同等性を確保する所である。その考え方を重視したものが本稿で示す「予測学習」である。

予測学習の結果を表-4、図-9、図-10 に示した。表-3、図-7、図-8 に示す従来手法よりも明らかに予測精度が向上しており、リードタイムが 6 時間先でもダム流入量のヒドログラフ形状を適切に捉えている。本稿の従来手法と予測学習の違いは、モデル構築・運用時に予測雨量を使わないか使うかであるが、その効果の違いの大きさを確認することができる。図-9 は NN による計算結果、図-10 は DNN による計算結果である。従来手法では洪水到達時間分の予測が精一杯であったが、予測学習では予測雨量の効果を発揮し、6 時間先の予測を可能としている。6 時間先予測でも RMSE は 100 以下であり、十分に実用的である。一方、pred_method 系の NN と DNN の RMSE 差は平均して 25 程度である。この精度の違いは既往最大洪水となる 2019 年 9 月洪水 (2019 年の 3 洪水の最大洪水) のピーク値の再現性に顕著に表れている。このように、予測学習では実用的な予測精度において、NN と DNN の機能差が明確に示された。

図-11 から pred_method 系における NN と DNN の差を確認することもできる。また、pred_method 系は orig_method 系に比較して、リードタイムが大きくなっても予測精度が落ちにくい傾向にあることを確認できる。図-12 からは pred_method 系ではリードタイムが大きくなるにつれて多くの予測データを活用することが予測精度向上に繋がっていることを確認できる。

8. おわりに

ダム流入量予測に NN と DNN を適用するに当たり、観測データのみを用いる従来手法と予測データを用いる「予測学習」を検討し、両者の予測精度等を比較し

た。従来手法は 1~6 時間先のダム流入量予測の中で、リードタイムが大きくなるほど予測精度が低下するが、「予測学習」は予測精度の低下が見られなかった。また、そもそも「予測学習」の予測精度は従来手法を大きく上回り、未学習の既往最大洪水に対してピーク値を伺う予測精度を発揮し、洪水到達時間が 1 時間程度の小流域においても 6 時間先の高精度なダム流入量予測が可能であることを示した。さらに、従来手法の観測雨量等とダム流入量の関係のような観測値と観測値の関係構築では NN と DNN の予測精度は同程度であったが、予測雨量とダム流入量の関係のような予測値と観測値の関係を構築する「予測学習」では DNN は NN よりも格段に予測精度が良かった。また、予測時にはターゲットとする予測時刻前の観測データや予測データを複数活用するが、不確実性のある予測データは数多く用いる方が精度が良くなり、確実性のある観測データは数を多くしても精度向上は見られなかった。

「予測学習」による 6 時間先予測の飛躍的精度向上を確認できたが、予測値に観測値を含めた場合、含まない場合の効果検証が必要である。また、未学習洪水への対応、特に未学習大規模洪水への対応の可能性について検証が必要である。さらに、現在は単一流域での効果確認のみであるため他流域や他期間での検証が不可欠である。

参考文献

- 1) 環境省, 気象庁, 国土交通省, 農林水産省, 文部科学省: 気候変動の観測・予測及び影響評価統合レポート 2018 ~日本の気候変動とその影響~, 環境省地球環境局, 2018
- 2) 工藤亮治, 近森秀高, 永井明博: 粒子フィルタを用いた河川流域における実時間洪水予測, 農業農村工学会論文集, **77**(1), 17-25, 2009
- 3) 立川康人, 須藤純一, 椎葉充晴, 萬和 明, キムスンミン: 粒子フィルタを用いた河川水位の実時間予測手法の開発, 水工学論文集, **67**(4), 511-516, 2011
- 4) 高崎忠勝, 河村 明, 天口英雄, 石原成幸: 粒子フィルタを用いた都市貯留関数モデルによる実時間洪水流出予測特性, 土木学会論文集 B1 (水工学), **68**(4), 511-516, 2012
- 5) 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**(4), 187-192, 2016
- 6) Hochreiter, S. and Schmidhuber, J.: Long short-term memory, Technical Report FKI-207-95, Fakultat fur Informatik, Technische Universitat Munchen, 1995
- 7) Hochreiter, S. and Schmidhuber, J.: Long Short-Term Memory, Neural Computation, **9**(8), 1735-1780, 1997
- 8) 天方匡純, 梁田信河, 藤井純一郎: LSTM (Long Short-Term Memory) を活用したダム流入量予測に関する研究, 電力土木, No.405, 11-18, 2020
- 9) 天方匡純, 安野貴人, 藤井純一郎, 島本ゆり, 大久保純一: IoT を想定したダム流入量予測精度向上に関する研究, 水文・水資源学会誌, **32**(6), 287-300, 2019
- 10) Ishihara, Y. and Kobatake, S.: Runoff Model for Flood Forecasting, Bull. D.P.R.I., Kyoto Univ., **29**(1), 27-43, 1979
- 11) 杉原成満, 福田慎哉, 倉本和正, 荒木義則, 朝位孝二, 古川浩平: SCE-UA 法を用いたタンクモデルの構築とそれを用いた土砂災害発生危険基準線の設定, 土木学会論文集 F6 (安全問題), **67**(1), 1-13, 2011
- 12) 天方匡純, 藤井純一郎, 梁田信河: Gradient Boosting の適用によるダム流入量予測の精度向上, ダム工学, **30**(1), 18-27, 2020
- 13) 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-, 土木学会論文集 B1 (水工学), **74**(5), 1327-1332, 2018
- 14) 沖 岳大, 中津川 誠: 超過洪水による氾濫被害を軽減するための治水施設の総合的な効果分析手法の研究, 土木学会論文集 B1 (水工学), **73**(4), 367-372, 2017
- 15) 川村一人, 中津川 誠, 杉原幸樹: 気候変動による利水への影響を踏まえたダム貯水池群の最適操作に関する研究, 土木学会論文集 B1 (水工学), **68**(4), 1477-1482, 2012
- 16) 野原大督, 鈴木俊亮, 佐藤嘉展: 将来の河川流量変化に伴うダム利水操作への影響の評価と適応策に関する基礎的検討, 土木学会論文集 B1 (水工学), **74**(5), 85-90, 2018
- 17) 猪股広典, 川崎将生, 工藤 俊: アンサンブル予測雨量を用いた洪水時ダム操作における操作決定方法に関する研究, 水文・水資源学会誌, **34**(1), 24-53, 2021
- 18) 猪股広典, 川崎将生, 後藤祐輔, 増田有俊, 荒木千博, 荒木孝之: アンサンブル予測雨量のダム洪水調節操作への適用に関する研究, 水文・水資源学会誌, **28**(6), 278-290, 2015
- 19) 関 基, 木村 厚, 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, 河川技術論文集, **19**, 2013

(2021 年 8 月 23 日 受理)

It is an urgent task to improve the precision of the dam inflow prediction that can support the effective use of dams in the increasing trend of rain as the external force by the climate change. We have made the dam inflow prediction models so far, whose parameters are optimized based on observation data. But in actual management, we have considered input data as prediction data and used those models. We can't expect the effectiveness of the current process that pursues the phenomenon reproducibility in actual management because there is a difference of characteristics between observation data and prediction data. This thesis shows that prediction learning causes the dam inflow prediction to get high precision and needs deep learning.

Key words : dam inflow prediction, precipitation short-term forecast, prediction learning, deep learning, LSTM