



LSTMモデルを用いた利水ダムにおける実用的放流量 予測モデルの構築

メタデータ	言語: Japanese 出版者: 農業農村工学会水文・水環境研究部会 公開日: 2024-07-19 キーワード (Ja): 利水ダム管理, 放流量予測, 紀の川, 大迫ダム キーワード (En): LSTM, irrigation dam operation, reservoir release prediction, Kino River, Ohsako Dam 作成者: 高岡, 新, 堀野, 治彦, 中桐, 貴生, 櫻井, 伸治 メールアドレス: 所属:
URL	http://hdl.handle.net/10466/0002001049

LSTM モデルを用いた利水ダムにおける実用的放流量予測モデルの構築 Development of a Practical Reservoir Release Forecasting Model for Irrigation Dams Using LSTM Networks

高岡新*・堀野治彦**・中桐貴生**・櫻井伸治**

*大阪府立大学大学院生命環境科学研究科 (〒599-8531 大阪府堺市中区学園町 1-1)

**大阪公立大学大学院農学学術研究科 (〒599-8531 大阪府堺市中区学園町 1-1)

TAKAOKA Arata*, HORINO Haruhiko**, NAKAGIRI Takao**, SAKURAI Shinji**

*Graduate School of Life and Environmental Sciences, Osaka Prefecture University
(1-1 Gakuen-cho, Naka-ku, Sakai, Osaka, 599-8531)

**Graduate School of Agriculture, Osaka Metropolitan University
(1-1 Gakuen-cho, Naka-ku, Sakai, Osaka, 599-8531)

(Received 25 November 2022, Accepted 17 February 2023)

Abstract

One of the concerns in the operation of irrigation dams is that the operation is based on the experience of the dam managers. In this study, LSTM model was used to forecast reservoir releases from 1 to 48 hours ahead. The results indicated that the model could be applied efficiently to forecast the discharges up to 24 hours ahead, with a forecast error of less than 30% in MAPE. Moreover, the MIMO-based model showed high applicability for forecasting the discharges up to 24 hours ahead, with an overall MAPE of 15.3% and it was only 2.0% for low flow conditions. These results are particularly important for water use management. In addition, the results of the contribution ratio of each feature to the model output showed that (1) the contribution ratio of the dam discharge was remarkably high in the short forecast, but the share decreased in the longer forecast, and (2) the meteorological data in downstream contributed to reducing the forecast error for the long-term ahead forecast.

Key words: irrigation dam operation, reservoir release prediction, LSTM, Kino River, Ohsako Dam

要 旨

ダムの利水運用において管理者の経験に基づく操作が不安材料の一つとなっている。本研究では、機械学習手法の一つである LSTM を用いて利水ダムにおける 1~48 時間先の放流量予測を試みた。その結果、24 時間先程度までであれば推定精度は平均絶対パーセント誤差 (MAPE) で 30%未滿と、モデルの適合性は十分に高いと思われた。また、24 時間先までを予測対象とした場合、時系列を出力する MIMO 手法により MAPE が 15.3%、利水管理上特に重要となる低流量時では MAPE が 2.0%と高い適合性を示した。加えて、各特徴量の重要度を求めた結果、①短時間先予測では自己特徴量 (ダム放流量) の寄与割合が顕著に高いが、より長い先行時間の予測ではその占有率が低下する、②長時間先の予測においてはダム諸量や上流の降水量のみならず下流の気象情報が予測誤差の軽減に寄与する、といったことが明らかとなった。

キーワード: 利水ダム管理, 放流量予測, LSTM, 紀の川, 大迫ダム

1. はじめに

国内外を問わず水田灌漑においては、用水の大半を河川に依存しているケースがほとんどである。特に水田開発が進んだ流域では、流域規模での農業水利システムが構築され、河川上流に設置された利水ダムによって適宜河川流量が増強され、中下流に設けられた取水堰を通じて低平部に広がった農地へと用水の安定供給が図られている。しかし、流域規模が大きい場合、利水ダム地点から水が取水地点に到達するまでに長い時間を要し、そのためダム管理者は経験的判断に基づいて数時間~数日先の河川流量や水需要を予測し、利水操作を行うことを余儀なくされる。こうした現状は、①将来的に予想される職員数の減少による後継者不足、②渇水時における 24 時間体制での繊細な水管理、③下流における水不足の回避を意識した過剰な放流決定 (無効放流の増大)、といった問題を内包しており、

利水運用において管理者の意思決定を支援しうる実効性の高い制御システムや支援ツールの開発が望まれる。

ダム放流操作のような、自然事象のみならず栽培管理などを鑑みた人の意思が介在する複雑な現象を物理モデルにより再現することは困難であり、古くからこうした問題に対するアプローチとして、ファジィ理論やエキスパートシステムを用いた研究がなされてきた。例えば、猿渡ら（1991）は灌漑用水供給のための水利施設における送配水操作をとりあげ、利水管理者による意思決定過程をファジィ推論によりモデル化している。一方で、近年では AI 技術の進歩とともに、深層学習をはじめとする機械学習モデルを用いた研究も数多く報告されており、特に洪水時のダム流入量や河川水位予測をはじめとする治水関連分野での適用例が多くみられる。例えば、一言ら（2016）は深層学習を用いた河川水位予測手法を提案し、その適用性を確認している。また、田村ら（2018）は洪水時のダム運用に着目し、正確な予測雨量が得られるという条件下ではあるが、48 時間先までのダム流入量予測における深層学習モデルの有用性を明らかにした。

一方、こうした洪水予測研究に比べ、利水管理支援を目的とした機械学習モデルの適用事例は少ない。これは、大規模な流域における利水ダムの場合、洪水調節を目的としたダム管理に比べ対象とすべき先行時間が長く、また人為的判断による影響の大きい水需要も考慮する必要があり、モデル化がより複雑で困難であることがその一因になっていると考えられる。そこで本研究では、対象とすべき予測先行時間が長い利水ダムにおいても実用的となりうる手法として、時系列事象の連続性や長期傾向を学習できる機械学習モデルの一種である Long Short-Term Memory (LSTM) を用い、利水ダムにおける長時間先までの放流量予測モデルを構築し、その実効性を検討した。

2. 研究方法

2.1 対象地概要

本研究では、紀の川の上流域に位置する大迫ダムを対象として利水ダム放流量の予測を検討した。紀の川流域の概要を Fig. 1 に、大迫ダムに関する諸元は Table 1 に示す。大迫ダムは、「十津川・紀の川総合開発事業」において灌漑用水および水道水の供給を目的として造成された利水ダム

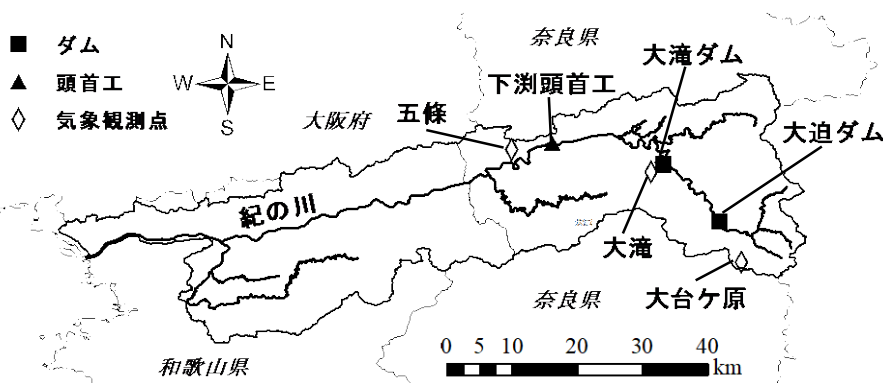


Fig. 1 対象流域の概要

であり、国営ダムとして現在も近畿農政局南近畿土地改良調査管理事務所によって管理されている。紀の川本川は、源流部に全国有数の多雨地帯である大台ヶ原を擁し、奈良県および和歌山県を貫流する幹川流路延長 136 km、流域面積 1750 km² の一級河川で、大迫ダムはその最上流部に位置する。また、大迫ダム下流には洪水調節機能を担う大滝ダムが造成され、2013 年からその運用が開始

Table 1 大迫ダムの諸元

河川名	紀の川水系紀の川		
形式	不等圧ドームアーチダム		
堤高	70.5 m	総貯水量	27750 千 m ³
堤長	222.3 m	有効貯水量	26700 千 m ³
流域面積	114.8 km ²	計画洪水量	2300 m ³ /s
湛水面積	107.0 ha	常時満水位	398.0 m

されている。同年からは、灌漑期に合わせて大滝ダムのドローダウンを行うなど、両ダム間で人為的判断による連携操作もなされている。

なお、実際の利水操作において、ダムから放流された水が下流の頭首工地点に到達するまでに長い時間を要する場合、将来的な河川流況の予測的判断に基づいてダム管理者が放流量を決定する必要がある。例えば、大迫ダムにおいては下流の下流頭首工（Fig. 1）に到達するまでに12時間以上、最下流の頭首工に至るまでには24時間以上を要する。そのため、本研究ではこの現状をふまえ、実用的な範囲を想定し1~48時間先までの放流量予測を試みることにした。

2.2 使用データおよびデータセットの作成

本研究では、近畿農政局南近畿土地改良調査事務所よりダムおよび頭首工の管理記録の提供を受け、これらをもとにデータセットを作成した。加えて、国土交通省が公開している水文水質データベースから得られた大滝ダム流入量と両ダム近傍2地点での降水量データを用いた。また、下流での水需要を考慮するた

Table 2 使用データの詳細

カテゴリー	項目	単位	入手元
水利諸量	大迫ダム放流量	m ³ /s	近畿農政局 南近畿土地改良調査事務所
	大迫ダム流入量	m ³ /s	
	大迫ダム貯水量	m ³	
	下流頭首工流量	m ³ /s	
水文水質データベース	大滝ダム流入量	m ³ /s	水文水質データベース (国土交通省)
	大台ヶ原地点降水量	mm	
	大滝地点降水量	mm	
気象情報	五條地点降水量	mm	過去の地点気象データ (気象庁)
	五條地点気温	°C	
	五條地点風速	m/s	

め、気象庁から配信されている過去の地点気象データを用い、五條地点（Fig. 1）における気象情報もデータセットに加えた。使用したデータの詳細はTable 2に示した通りである。なお、いずれの項目についても2013年1月~2018年9月までの時間単位のデータを用い、本研究ではこれらの期間のうち2013年1月~2016年9月までをモデル学習時のパラメータ決定に用いる訓練期間、2016年10月~2017年9月までをハイパーパラメータチューニングに用いる検証期間、2017年10月~2018年9月までをモデルの性能評価に用いるテスト期間として、3つの期間に分割して利用した。

2.3 モデル概要

2.3.1 モデル構造

機械学習モデルは、基本的にデータセットを与える入力層、与えられたデータセットの演算処理を行う中間層、演算結果を所定のデータセットとして出力する出力層から構成される。本研究では、複数提案されているモデルのうち、時系列事象の予測に適しているとされるRecurrent Neural Network (RNN) 型を採用し、中間層には、特に長期的な依存関係を学習することができるLSTMを適用したもの（以下、LSTMモデル）を用いた。

LSTMは、RNNの欠点であった長期記憶を保存できないという問題を緩和する手法として提案されたゲート構造付きのRNNである。LSTMの内部構造はFig. 2のような構造をとる。まず、過去の記憶を保持する役割を担う記憶セルが存在し、セル内で新旧データの追加・更新が行われる。また、新しい記憶の追加割合を決定する入力ゲート、過去の記憶の忘却割合を決定する忘却ゲート、記憶された情報の出力内容への反映割合を決定する出力ゲートの計3つのゲートが存在し、これらのゲート制御により記憶セルに長期的な依存関係が保持される。時刻*t*におけるLSTMブロック内での各ゲートと記憶

セルでの処理を式として表すと、以下ようになる。

$$\left. \begin{aligned} f_t &= \sigma(h_{t-1}W^{(f)} + x_tW^{(f)} + b^{(f)}), & i_t &= \sigma(h_{t-1}W^{(i)} + x_tW^{(i)} + b^{(i)}) \\ o_t &= \sigma(h_{t-1}W^{(o)} + x_tW^{(o)} + b^{(o)}), & g_t &= \tanh(h_{t-1}W^{(g)} + x_tW^{(g)} + b^{(g)}) \\ C_t &= f \odot C_{t-1} + i \odot g, & h_t &= o \odot \tanh(C_t) \end{aligned} \right\} \quad (1)$$

ここで、 σ はシグモイド関数、 W は学習する重み、 b はバイアス、 x は入力データ、 h はLSTMブロックから出力される隠れ状態、 f, i, o はそれぞれ忘却ゲート、入力ゲート、出力ゲートの処理を表す関数で、 g はブロックへの入力情報である。また、 C_t は時刻 t における記憶セルを表し、直前の記憶セルに対して不要な情報を処理した後、選別された情報を追加する。

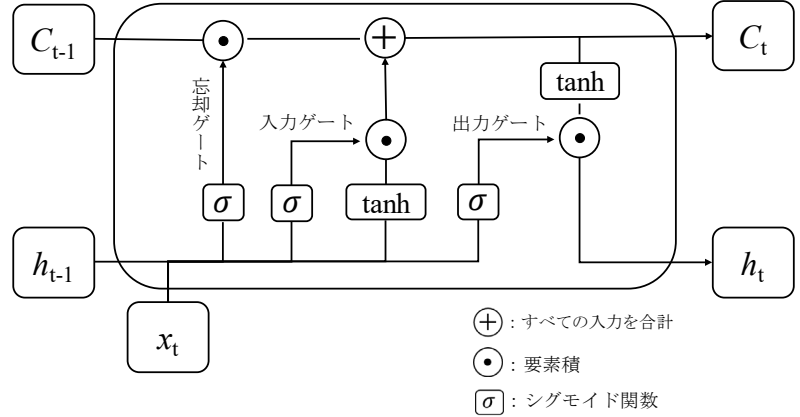


Fig. 2 LSTMブロックの構造

これら一連の制御構造により、

LSTM ブロックは記憶を忘却・更新し、長い時系列データの特徴を考慮できるとされている (Hochreiter and Schmidhuber(1997)).本研究で採用したモデルにおける中間層は多層構造のLSTMとし、中間層から出力された隠れ状態を処理する出力層は単層の全結合層とした。

2.3.2 学習条件

本研究で用いた LSTM モデルの、ハイパーパラメータをはじめとする設定条件を **Table 3** に示す。モデル適用の際、LSTM 層数、LSTM ブロック数、リカレントドロップアウト率、全結合層ノード数、ドロップアウト率の 5 項目については、オープンソースの自動最適化ライブラリ Optuna (T.Akiba, et.al., 2019) を用い、100 回の試行結果の中から損失が最小となるハイパーパラメータの組み合わせを抽出した。なお、エポック数については上限を 500 とし、30 回連続で精度が改善しなければ学習を中断する Early Stopping 方式を用いた。

Table 3 LSTMモデルの各種設定

パラメータ項目	設定条件
バッチサイズ	128
エポック数	Early Stopping (Patience=30)
損失関数	Mean Absolute Error
最適化手法	Adam
LSTM層数	1~5
LSTMブロック数	1~100
リカレントドロップアウト率	0~1
全結合層ニューロン数	1~100
ドロップアウト率	0~1

2.3.3 モデル入出力

複数の時間ステップ先の予測を行う場合には様々な戦略的手法が想定され、予測タスクの性質や利用データの特徴に合わせて最適な手法を選択する必要がある。本研究では、① 予測先行時間に対して個々にモデルを構築する Direct Strategy (DS) (Fig. 3(a)), ② 1 時間先の予測モデルを再帰的に利用する Recursive Strategy (RS) (Fig. 3(b)), ③ 目的とする時間長の時系列を出力するモデルを構築する Multi-Input Multi-Output (MIMO) (Fig. 3(c)) の 3 種を採用し、比較検討を行った。なお、モデルの入力には **Table 2** に示した項目について現時点から 23 ステップ前までの計 24 ステップ (すなわち、24 時間分)

のデータを用いた。

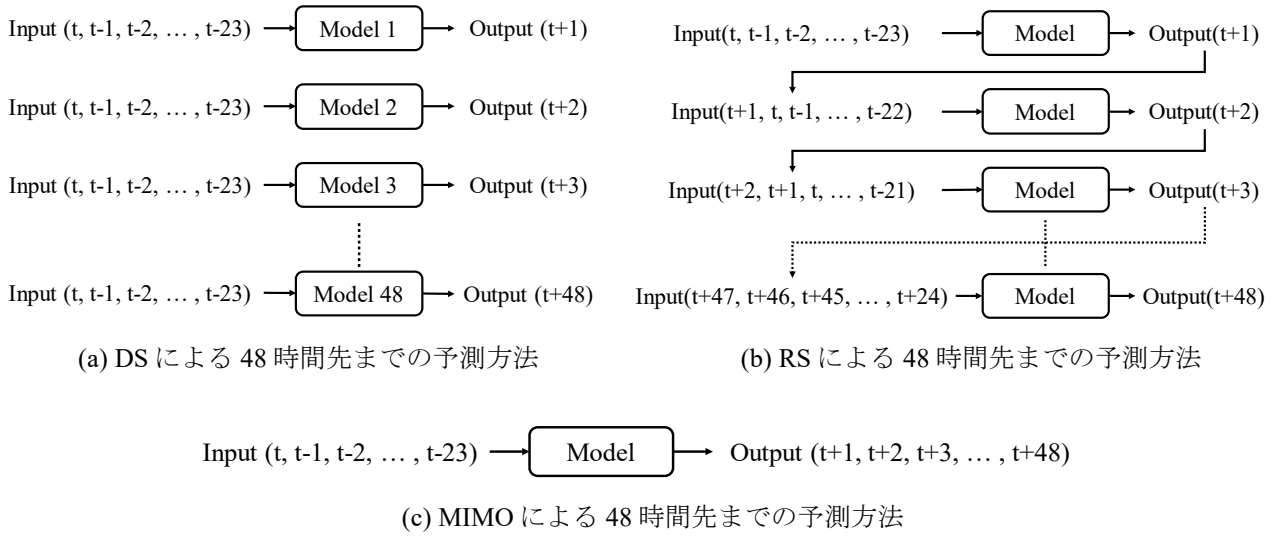


Fig.3 各予測手法におけるモデルの入出力例

3. 結果および考察

3.1 予測手法の比較と LSTM モデルの適用性

テスト期間（2017年9月～2018年10月）における各 LSTM モデルの 48 時間先予測値を実測値とともに Fig. 4 に示す。いずれの LSTM モデルにおいても、概ね観測値と同様の波形を再現できている様子が確認できる。ただし、詳細にみると RS を用いたモデルでは DS や MIMO と比べて放流量を過大評価する期間や、立ち上がりの先行が散見された。また、12月～1月にかけて DS および MIMO で長期間にわたる過大推定が確認できるが、これはこの期間に行われたダム堤体のメンテナンスにより特異的な


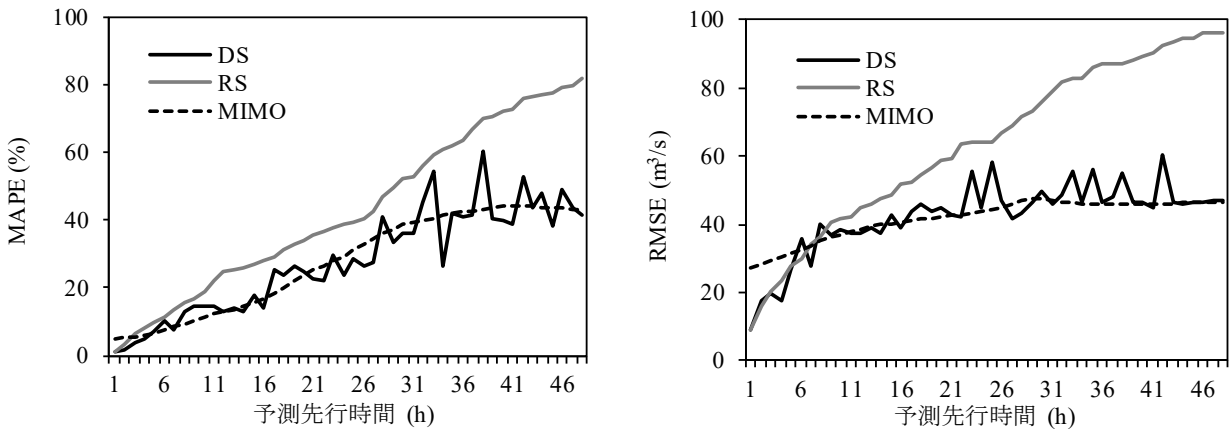



Fig. 4 テスト期間における各手法の 48 時間先推定結果

放流操作が行われていたことに起因すると考えられる。

また、各予測手法による1~48時間先までの予測先行時間別での推定精度を Fig. 5 に示す。Fig. 5(a) はテスト期間全体に対する推定精度、Fig. 5(b) は利水管理上特に重要となる低流量時のみを対象とした推定精度を RMSE (平均2乗誤差の平方根)、MAPE (平均絶対パーセント誤差) で評価したものを表す。なお、ここでの低流量時とは、本河川での利水管理上の基準点である下淵頭首工地点 (Fig. 1) における実測河川流量が低水量の $11.5 \text{ m}^3/\text{s}$ 以下となる時間を指す。各予測先行時間における推定精度を比較すると、6 時間先程度までであればいずれの手法にも大きな差はなく予測誤差も小さいといえる。しかし、先行時間がそれより長くなると、どの手法でも誤差は大きくなり、特に RS で誤差の増大が顕著であった。これは再帰的な予測が誤差を累加させる方向に作用した結果であると考えられる。また、DS では他の手法と比べて予測先行時間ごとに精度のばらつきが大きい。これは DS が個別モデルの集合体であることにより、ハイパーパラメータの設定による学習のばらつきの影響を受けたものと推察され、より詳細なハイパーパラメータ探索を行えば予測精度がさらに改善する可能性が残されている。



(a) テスト期間全体に対する推定精度



(b) 低流量時における推定精度

Fig. 5 予測先行時間ごとのモデル別推定精度

ここで、各手法の 24 時間先および 48 時間先における推定精度を Table 4 に示す。この表における MIMO_24h, MIMO_48h は MIMO における出力時系列長をそれぞれ 24 時間、48 時間として計算を行ったことを表す。また、表中の塗りつぶし部分は各評価項目における最良値を指す。48 時間先予測では、DS の予測精度が MIMO を僅かに上回る結果となった。ただし、24 時間先予測ではいずれの流量レベルにおいても MIMO_24h の推定精度が最も高く、特に低流量時には RMSE で $0.3 \text{ m}^3/\text{s}$ 、MAPE で

2.0 %と予測への高い適用性を示した。一方，出力時系列長を 48 時間とした MIMO_48h による 24 時間先予測では，いずれの項目においても MIMO_24h を下回る結果となり，目的とする予測先行時間によっては手法間の優位性が異なる可能性も示唆された。

Table 4 各手法の 24 時間先および 48 時間先における推定精度

モデル	24時間先				48時間先			
	全流量		低流量時		全流量		低流量時	
	RMSE (m ³ /s)	MAPE (%)	RMSE (m ³ /s)	MAPE (%)	RMSE (m ³ /s)	MAPE (%)	RMSE (m ³ /s)	MAPE (%)
DS	44.8	23.6	0.6	14.9	47.1	41.7	1.7	55.5
RS	64.1	39.0	1.5	39.0	96.4	81.8	2.7	86.1
MIMO_24h	43.6	15.3	0.3	2.0	-	-	-	-
MIMO_48h	43.8	29.3	1.6	25.3	46.5	43.0	1.8	60.5

3.2 各特徴量のモデル出力への寄与割合

前項の MIMO_48h モデルを用いて，各特徴量の重要度を算出した。ここで，特徴量とは，モデルへの各入力項目のことであり，重要度とはモデル入力に用いた各特徴量が予測結果に対してどの程度寄与したのかを示す指標である。本研究では，重要度の検討手法として Permutation Importance (A.Altmann, et.al.,2010) を用いた。Permutation Importance は各特徴量をランダムにシャッフルして入力に用いた際に得られる予測誤差の増加割合によって算出される。これはすなわち，ある種の感度解析に相当する。なお，ここでは予測先行時間による各特徴量の重要度の変化に着目するため，全特徴量の合計重要度に対して各特徴量の重要度が占有する割合を算出し，これを「寄与割合」と定義した。

予測先行時間ごとの各特徴量の寄与割合を Fig. 6 に示す。なお，ここでは 1, 12, 24, 36, 48 時間先を代表値として抽出している。1 時間先の予測においては，大迫ダム放流量の寄与割合が 74.7%と顕著に高く，他の特徴量の寄与割合が低い。一方で，予測先行時間が長くなるにつれて大迫ダム放流量の寄与割合は低くなり，それに伴い他の特徴量の寄与割合が高くなる傾向が確認できる。中でも，下流域頭首工流量は 36 時間先の予測において寄与割合が 35%を上回るなど，長時間先の予測において特に重要となる特徴量であると思われた。また，ダム下流（五條地点）での降水量や気温についても 48 時




Fig. 6 予測先行時間ごとの各特徴量の寄与割合

間先での寄与割合は 10%を上回り、長時間先の予測においてはダム諸量や上流での降水量のみならず、下流での気象情報が予測誤差の軽減に寄与していることが確認できる。一方で、大滝ダム流入量、五條地点風速、大迫ダム貯水量についてはいずれの予測先行時間においても寄与割合の下位 3 位を占め、予測先行時間の拡大に伴う寄与割合の増加傾向もみられない。ただし、Permutation Importance の性質上、特定の特徴量がシャッフルされて入力されたとしても他の特徴量はその影響を軽減した可能性も考慮しなければならない。

4. おわりに

本研究では、機械学習モデルの一種である LSTM モデルを用いて利水ダムにおける 1~48 時間先までの放流量予測を試みた。その結果、RS を用いた場合を除き、少なくとも 24 時間先程度までの予測誤差は MAPE で 30%未満と比較的小さく、LSTM モデルの利水ダム管理への適用の可能性は十分に示された。特に、24 時間先を目的とした場合には MIMO を用いたモデルで MAPE が 15.3%、利水管理上特に重要となる低流量時においては MAPE が 2.0%と、高い適用性を示した。また、Permutation Importance を用いて各特徴量のモデル出力への寄与割合を算出した結果、① 1 時間先程度の短時間先予測においては大迫ダム放流量の寄与割合が顕著に高いが、より長い先行時間の予測においては占有率が低下する、② 長時間先の予測においてはダム諸量や上流の降水量のみならず、下流での気象情報が予測誤差の軽減に寄与している、といったことが明らかとなった。

なお、本研究ではあくまで過去のダム管理記録に基づいて利水ダムにおける放流量予測を試みた。つまり、モデル学習に用いた教師データには実績の放流操作が用いられている。しかし、この実績値の中には結果的に過剰放流であった操作なども含まれると考えられ、利水管理の観点からいえば、決して実績値を再現することが最適となるとは限らない。よって今後は、下流の水需要を考慮するなど、利水管理実態に則したより望ましい放流操作を予測可能なモデルの構築が求められる。

謝辞：本研究の遂行にあたり、近畿農政局南近畿土地改良調査事務所の皆様からは、研究の指針となるご助言を頂くとともに、貴重なデータをご提供頂いた。ここに記して謝意を表す。

引用文献

- 猿渡農武也，四方田穆（1991）：ファジィ推論による水田の水需要予測の検討—水管理システム化に関する研究（Ⅱ）一，農業土木学会論文集，1991(152)，pp.29-37.
- 一言正之・櫻庭雅明・清雄一（2016）：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，pp.187-192.
- 田村和則・加納茂紀・三浦心・山脇正嗣・金子拓史（2018）：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—，土木工学会論文集 B1（水工学），74(5)，pp.1327-1332.
- 国土交通省水管理・国土保全局：水文水質データベース，<http://www1.river.go.jp/>.
- 気象庁ウェブページ：過去の気象データ・ダウンロード，<https://www.data.jma.go.jp/>.
- Hochreiter, P. and Schmidhuber, J.(1997): Long Short-term memory. *Neural Computation*, 9(8), pp.1735-1780.
- Akiba, S., Sano, S., Yanase, T., Ohta, T. and Koyama, M. (2019): Optuna: A Next-generation Hyperparameter Optimization Framework, *International Conference on Knowledge Discovery and Data Mining*.
- Altmann, A., Tolosi, L., Sander, O., Lengauer, T. (2010): Permutation Importance: a corrected feature importance measure, *Bioinformatics*, 26, pp.1340-1347.