

LSTM (Long Short-Term Memory) を活用した ダム流入量予測に関する研究

(執筆者) 天 方 匡 純*
梁 田 信 河**
藤 井 純 一 郎***

概 要 出水時のダム管理事務所では、数時間先のダム貯水池への流入量を予想し、ダム下流河川に急激な水位上昇を引き起こさないよう、ゲート放流の開始時刻や放流量を判断する。これらの作業を支援するダム流入量予測モデルが導入されている事務所もあるが予測精度の関係上、最終的なゲート操作は、様々な情報を加味したダム管理者の経験的判断に依るところが大きい。そこで、出水時のダム操作支援を目的に、深層学習方式の一種である LSTM (Long Short-Term Memory) を活用し、ダム上流域の水文量からダム流入量を予測する手法を検討した。

キーワード：ダム流入量予測, 深層学習, RNN, LSTM, 相関モデル

1. はじめに

本論文にて検討対象とする道志ダム上流域は、図-1、図-2 に示す通り、神奈川県相模川水系道志川に位置し、流域面積 112.5km² であり、上流域に降った雨量が流入量として道志ダムに到達する時間は、雨量や水位等の観測データより概ね 60~90 分と推測される。

道志ダムの目的は発電のみであり、操作規程に従い、常時満水位を超えないよう貯水位を維持する操作が求められており、水利権上の最大取水量である発電使用水量 11.4m³/s を上回る流入が継続すると予測される場合、ゲート放流を行う必要がある。そして、そのために、道志ダムへの移動時間や放流連絡に要する時間、休祝祭日における職員の参集時間等の放流までのリードタイムの確保が必要である。

一方、過去 30 年間のダム流入量を整理すると図-3 のとおり、近年の気候の変化等により年間最大流入量及び 1 時間当たり年間最大ダム流入量増加量が増加傾向を示しており、安全なダム管理を進めていくための精度の高いダム流入量予測システムの構築が不可欠である。

2. ダム流入量予測モデルの枠組み

ダム流入量予測モデルは、雨量を入力条件とし、流量を算定する流出解析モデルが主体となる。流出解析モデルは、既往洪水に対してパラメータを検証した上で予測モデル確定となる。しかし、実現象や実空間に比較して、シミュレーションで取り扱う観測データや空間情報



図-1 本研究の対象ダム位置図 (道志ダム)

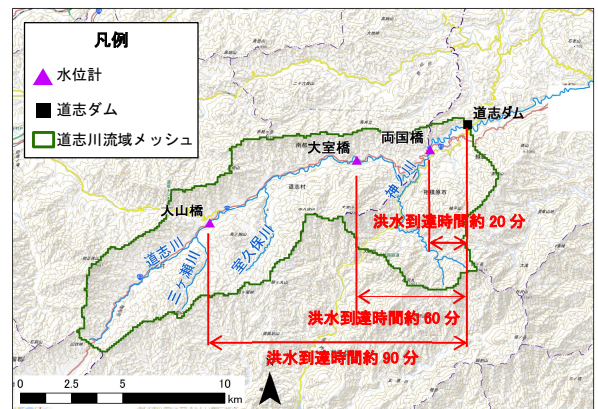


図-2 本研究の対象流域概要 (相模川水系道志川)




図-3 近年の出水傾向 (左：流入量, 右：流入量増加量)



天方匡純 梁田信河 藤井純一郎

* 八千代エンジニアリング株式会社 技術開発研究所 所長 amakata@yachiyo-eng.co.jp

** 八千代エンジニアリング株式会社 東北支店 取締役 支店長 会員 yanada@yachiyo-eng.co.jp

*** 八千代エンジニアリング株式会社 技術開発研究所 AI 解析研究室 上席研究員 jn-fujii@yachiyo-eng.co.jp

等には不確定性が多く、リアルタイムでのダム流入量、流量再現も難しい現実がある。

この不確定性に対応するためにダム流入量予測等を対象とした研究として、古くは単位図、貯留関数、タンクモデル等にカルマンフィルターを適用した事例^{1),2)}、近年では分布型流出モデルにカルマンフィルターを適用した事例³⁾等がある。しかし、カルマンフィルターは過去の観測値からモデル変数を最適化するため、雨量とダム流入量等の関係が急激に変化する際に予測精度が悪くなる等の問題があった。そこで、近年では粒子フィルターと呼ばれる現時刻観測値に状態方程式の変数を適合させ、現時刻から1ステップ先の予測精度を向上させる手法^{4),5),6),7)}が、まずは全国の一級河川等で取り入れられようとしている。この手法により現時刻、そして、1ステップ先の予測精度は飛躍的に向上することが期待される。一方で、水文学的プロセスを追跡せず、データ間の繋がりから予測を目指す手法がある。これらは、雨量や上流側水位等の上流域水文量から下流域水文量を推定する方法(図-4 参照)であり、単相関、重相関、ニューラルネットワークといった手法がダム流入量予測^{8),9),10)}、洪水予測^{11),12)}で適用されている。

本論文では、上流域水文量から下流域水文量を推定する手法として、機械学習の一手法であるDNN(Deep Neural Network)を活用する。DNNは、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、産業界への具体的な適用も始まっているところである。各分野で適応されるDNNのモデル構造は異なっており、例えば、自然言語処理のように前後の言葉(データ)の繋がりを認識する必要がある分野では、RNN(Recurrent Neural Network)と呼ばれるデータ間の再帰関係を表現できるニューラルネットワークが基本となる。ただし、RNNでは保持できる前後関係が短く、長い文章を読み解くことができないため、長い前後関係を保持することができるLSTM(Long Short-Term Memory)^{13),14),15)}が開発された。本論文では、水文事象の時系列データの特徴量を適切に捉えるためにLSTMを選択し、その適用過程、適用結果等を示す。なお、適用結果では、従来から我が国の実務の場で利用され^{9),10),11),12)}、LSTMと特性・構造等が類似する3層のニューラルネットワーク(以下、3NNと記す)との予測精度の差を確認することでLSTMの適用可能性を評価する。

3. LSTMの概要

「LSTM(Long Short-Term Memory)」は、DNNと呼ばれる人工知能の一種であり、「教師」とするデータを基にモデルパラメータを決定する教師あり学習手法の一種である。

DNNは、これまでも洪水予測やダム流入量予測に利用されてきたニューラルネットワークの枠組みと類似している。ニューラルネットワークは、図-5のアルゴリズムを基本単位とし、これを図-6のように組み合わせることで表現力を高める。DNNは、更に中間層(隠れ層とも呼ぶ)の数を大幅に増やすことができ、非線形性に代表されるより複雑なデータ間の関係を読み解くことが可能になった。中でも、LSTMは、前後関係が重要となる時系列データの特徴量抽出に威力を発揮す





図-4 上流域水文量から下流域水文量を推定する原理

る¹⁶⁾とされている。本論文では対象とする時系列のハイドログラフの特徴量抽出にLSTMを適用する。

これまで、我々が洪水予測やダム流入量予測に利用していた3NNは図-6に示す通り、中間層を1層(1層当たりニューロン7個)とし、活性化関数にシグモイド関数を用いてきた。シグモイド関数は図-7の形をしており、 $[-\infty, \infty]$ の入力を $[0, 1]$ に出力し、微分可能な形で正規化する役割を果たす。中間層を多層化することで非線形性が高まり、データから複雑な特徴量を抽出できることは従来の研究^{17),18)}で分かっていた。一方で、多層化により生じる勾配消失問題¹⁹⁾により中間層の多層化が困難であった。現在のAIブームは、多層化・深層化したネットワークでもモデルパラメータを最適化できる技術(深層学習)が登場したことにも起因している。

3NNに代表される従来のニューラルネットワークは、図-6に示す通り、原則として入力データの前後関係を保持する機構を持たない。しかし、例えば、入力層に入力箇所が3個あり、「時刻 t で始まるデータ」、「時刻 $t+1$ で始まるデータ」、「時刻 $t+2$ で始まるデータ」のように1ステップずつ時刻をずらして入力する工夫をすると、前後関係を保持して目的データとの関係を構築出来る。しかし、数日先のように予測スパンを長くしたり、XRAIN²⁰⁾のようなメッシュ雨量を利用す



注) 図中の各○はニューロン

$$u_j = (\omega_{j1}x_1 + \omega_{j2}x_2 + \omega_{j3}x_3 + \omega_{j4}x_4 + b_j)$$

$$y_j = f(u_j)$$

図-5 ニューラルネットワークの基本構造





図-6 3層ニューラルネットワーク



$$f(x) = \frac{1}{1 + e^{-x}} \dots \dots (1)$$

図-7 シグモイド関数

ると、冗長な類似データセットが大量に出来るため好ましくない。

一方、RNN、LSTMは図-8、図-9のように入力データの前後関係を保持する機能が整備されており、3NNのように入力データに冗長性を持たせることなく、データ前後関係の特徴量を捉え、出力データとの関係を構築することが可能となる。具体的には、RNNは図-8のように時刻 $t-1$ の中間層のデータを時刻 t の中間層のデータに紐づけることができ、これにより入力データの前後関係を保持している。LSTMは、図-9のように基本的な考え方はRNNと同様であるが、中間層をニューロンではなくLSTMブロック(図-10参照)と呼ばれるメモリセルと3つのゲートを持つブロックに置き換え、データの前後関係の長期依存

(long-term dependencies)を高めている。学習時に長期記憶を必要とするAdding Problemにおいて、RNNは長さ100の配列でさえも上手く記憶保持できないが、LSTMは500-1000の配列が記憶保持できる²¹⁾とされる。LSTMブロックは、通常のDNNの勾配消失問題をネットワーク構造的なアプローチにより解決している。すなわち、メモリセルのアイデアを中心とした3つのゲートによるデータの制御である。3つのゲートは、忘却ゲート(forget gate)、入力ゲート(input gate)、出力ゲート(output gate)と呼ばれ、それぞれシグモイド関数によりデータを通す/通さないを判定する。これらの一連のデータ制御方法は以下の(2)式~(7)式で表現される(図-10と対応)。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad \dots\dots\dots (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad \dots\dots\dots (3)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad \dots\dots\dots (4)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad \dots\dots\dots (5)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad \dots\dots\dots (6)$$

$$h_t = o_t * \tanh(C_t) \quad \dots\dots\dots (7)$$

ここに、 W_p, W_i, W_c, W_o : 重み行列, b_p, b_i, b_c, b_o : バイアス項, h_t, h_{t-1} : 時刻 $t, t-1$ の中間層値, x_t : 時刻 t の入力値, C_t, C_{t-1} : 時刻 $t, t-1$ のメモリセル値, \tilde{C}_t : 時刻 t のメモリセル暫定値, f_t : 忘却ゲート出力

値, i_t : 入力ゲート出力値, o_t : 出力ゲート出力値, σ : シグモイド(1)式参照)関数(層), \tanh : \tanh 関数(層)

忘却ゲートは、(2)式と(5)式に示す通り、時刻 $t-1$ のメモリセル値 C_{t-1} の捨てる/捨てないの判定を時刻 $t-1$ の中間層値 h_{t-1} と時刻 t の入力値 x_t から実施する役割を担う。例えば、出水期間から非出水期間に移行した場合、出水期間のデータ特性は忘れても良い。忘れた上で非出水期間のデータ特性をメモリセルに保存するための新たな情報追記を判定する。入力ゲートは、(3)式と(5)式に示す通り、入力層からのデータを新たに加えてメモリセルを更新する/しないを判定する。更新する場合、(4)式に示す通り、時刻 $t-1$ の中間層値 h_{t-1} と時刻 t の入力値 x_t を \tanh 関数(層)に通し、時刻 $t-1$ のメモリセル値 C_{t-1} に新たに加え、時刻 t のメモリセル値 C_t とする。そして、出力ゲートは、(6)式と(7)式に示す通り、更新されたメモリセル値を \tanh 関数(層)に通し、時刻 t の中間層値 h_t として出力する/しないを判定し、LSTMブロックより出力される。

以上の各ゲート(忘却ゲート、入力ゲート、出力ゲート)の判定は、シグモイド関数(層)((2),(3),(6)式)により行われ、その変数である重み行列とバイアス項の値は、出力データと教師データの誤差を最小化するための複数回の教師学習により決定される。

4. モデルの学習

本章では、道志ダム上流域において、LSTMを適用してダム流入量予測モデルを作成するための利用データ及び手順について示す。

(1) 学習・予測過程の概要

図-11に示す通り、学習出水(52出水)に対してダム流入量を予測するLSTMモデルを作成したのち、未学習出水(3出水)に対して予測結果・精度を確認する。ただし、予測雨量は現時点では不確実性が高いプロダクトであるため、本論文では予測雨量も含めて雨量を用いず、降雨後の水文過程となる河道を流れる水位・流量の上流地点と下流地点のデータ相関性に着目して、予測精度向上の可能性を探る。




図-8 RNNの基本構造




図-9 LSTMの基本構造

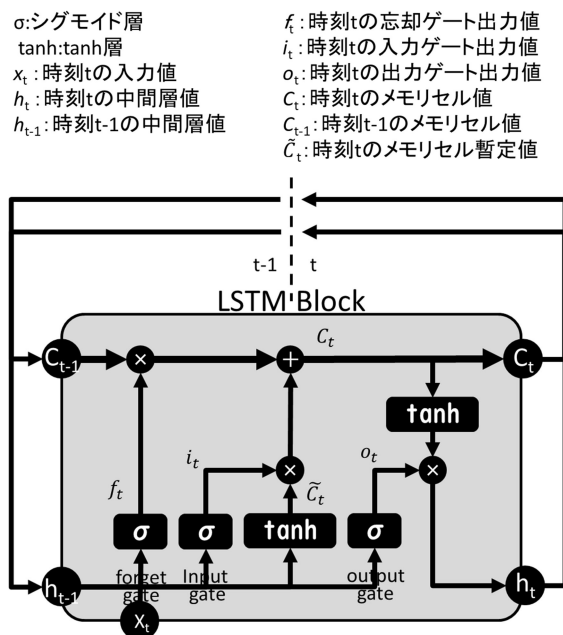


図-10 LSTMブロックの構造

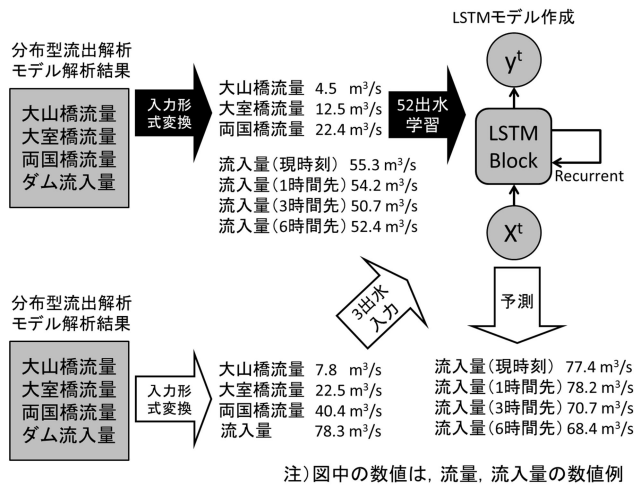


図-11 LSTMの学習・予測過程の概要




図-12 分布型流出解析モデルの諸条件の整理

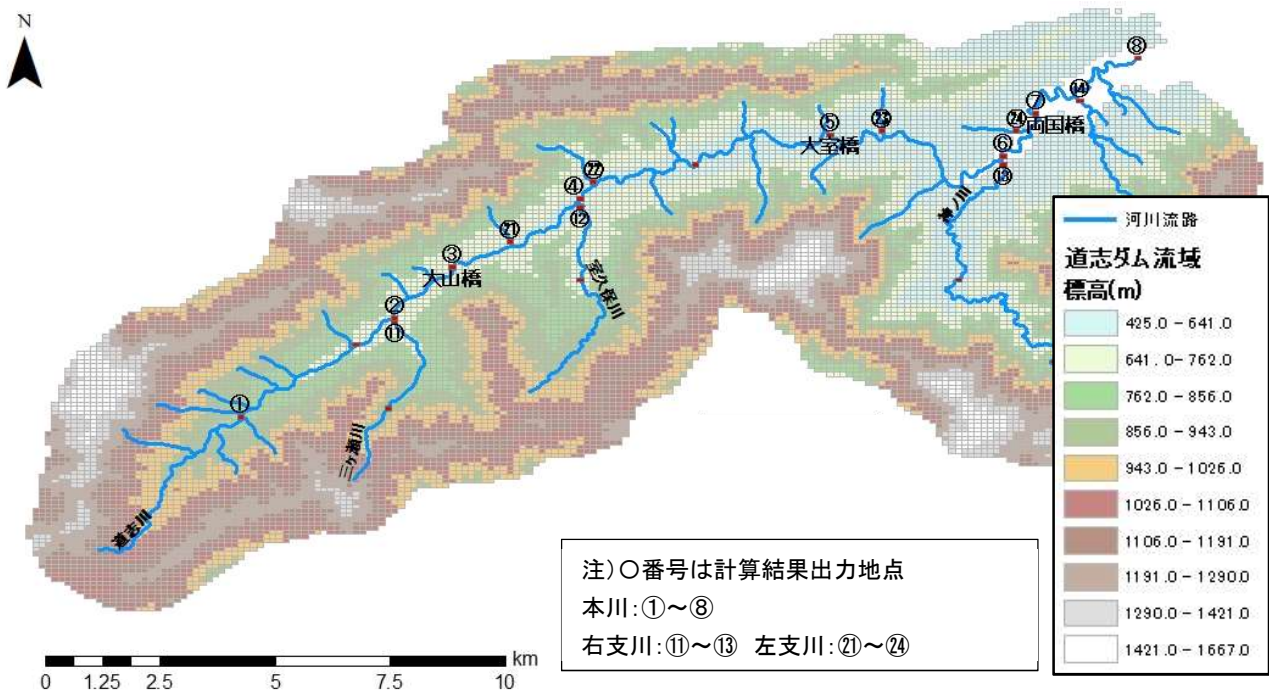


図-13 分布型流出解析モデルメッシュ図

表-2 入力・出力フォーマットの概要

洪水イベントNo	時刻	入力データ				出力データ			
		大山橋 計算流量	大室橋 計算流量	両国橋 計算流量	ダム 計算流入量	ダム 計算流入量			
		(m ³ /s)	(m ³ /s)	(m ³ /s)	(m ³ /s)	0時間 (m ³ /s)	1時間先 (m ³ /s)	...	6時間先 (m ³ /s)
1	9:00	0.5	1.2	20.3	2.0	2.0	2.0	...	2.8
1	9:30	0.5	1.4	20.8	2.1	2.1	2.2	...	3.5
1	10:00	0.6	1.6	21.5	2.0	2.0	2.5	...	4.5
...	10:30	0.6	1.8	22.7	2.2	2.2	3.0	...	5.2
2	21:00
2	21:30
...	22:00

(2) 入力データ

対象出水を定め、その入力データを整理した(表-2参照)。具体的には、平成17年から平成27年までのゲート放流を伴う出水から、①ダム流入量が90m³/s以上となった出水(道志ダム操作規程ではダム流入量90m³/s以上を洪水という)、②最高水位が常時満水位-1.5m以上の出水、③20mm/3hr又は総雨量100mm以上の出水、の条件にて55出

水を抜き出し、そこから平成27年に発生した3出水以外の52出水を学習対象とした。なお、運用時の最新時刻(以下、現時刻という)のデータを最大限活用する目的で、ダム流入量を入力データとしても活用する。そして、入力データ自体は、観測誤差や欠測等を回避するため、道志ダム流域の分布型流出解析モデルの計算結果を仮想的に用いた。実測データを活用する際の問題点への取り組みは別途検討を進める予定である。

分布型流出解析モデルは土研モデル²²⁾を用いた。土研モデルは、3種類のタンクで構成される流出解析モデル(図-12参照)であり、表面モデル、地下水モデル、河道モデルの各要素モデルから成る。それぞれの変数は、土地利用データ(出典:土地利用細分メッシュ図,国土地理院)、土壌データ(出典:土壌分類図,国土数値情報)、地質データ(出典:表層地質区分図,国土数値情報)を基に設定し、落水方向は5mDEM(出典:国土地理院)を100mメッシュに加工(図-13参照)して設定した。そして、平成17年から平成26年度までのゲート放流を伴う10個の代表出水についてパラメータを検証⁷⁾しモデルを確定した。その後、55出水(学習出水52+未学習出水3)に対応するレ

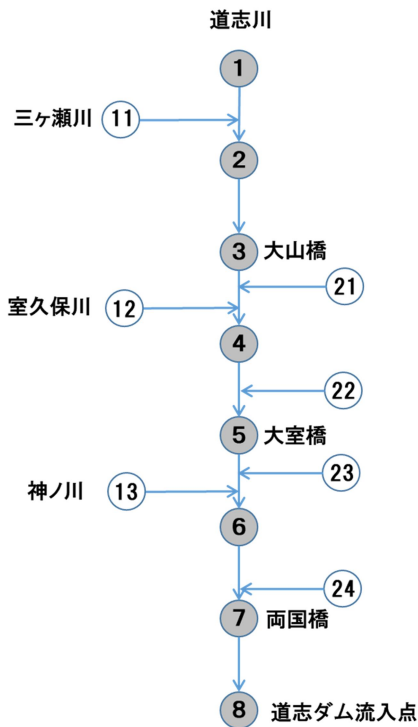


図-14 観測所位置対応図 (番号は図-14 の○付き番号と対応)

ーダー・アメダス解析雨量 (1km²メッシュ) を分布型流出解析モデルに入力し、その計算結果となる図-13 に示す○番号の各地点の30分毎の流量を入力データとした。通常、河川の観測対象は水位であるが、流出解析モデルの計算結果である流量を水位に変換せず、そのまま入力データとして用いた。また、観測に伴う誤差も考慮していない。

(3) 出力データ

学習対象とする出力データも分布型流出解析モデルの計算結果の一つであるダム流入量を用いる。また、洪水到達時間が最大でも1.5時間程度と想定され、実用上は2時間先までのダム流入量予測利用が限界と考えられるが、模擬的に6時間先までのダム流入量計算結果も学習対象に加えた (表-2 参照)。

(4) モデルの構築方法

入力と出力 (教師データ) のデータを組み合わせ、LSTM を介して、その関係性を学習することによりダム流入量予測モデルを構築した。具体的には、雨量データを一切用いず、大山橋 (③)、大室橋 (⑤)、両国橋 (⑦) (番号は図-13、図-14 に示すモデル上の地点番号を示す) の3観測所の位置に該当する分布型流出解析モデルのメッシュ位置の計算結果を活用して、ダム流入量 (⑧) (番号は図-13、図-14 に示すモデル上のダム位置を示す) を予測するモデルを構築した。

未学習出水に対する検証の際は、現時刻までの入力値 (大山橋、大室橋、両国橋の計算流量及びダム計算流入量) から6時間先までのダム流入量を予測する。なお、比較のために構築した3NN及びLSTMのモデル構造は表-3、図-15 と表-4、図-16 のとおりである。なお、表-3と表-4に記載されている全結合層とは図-6のように前後層のニューロンが全て結合している層を言う。計算データと教師データの誤差関数を最小化する手法は確率的勾配降下法 (通称、SGD (Stochastic Gradient Descent)) を用いている。

なお、LSTM 構造決定に当たっては、LSTM ブロックの数を増やしたモデル (1層の中に56個のLSTMブロック) や、2層のモデル (1層目の中に7個のLSTMブロック×2層目の中に7個のLSTMブロック) で予測精度を検証し、1層に7個のLSTMブロックを格納したモデルの予測

精度

表-3 3NN モデル構成表

Layer	レイヤータイプ	出力データ数	パラメータ数
dense_1	全結合層	7	427
dense_2	全結合層	1	8
パラメータ総数			435




図-15 3NN モデル構造

表-4 LSTM モデル構成表

層名	レイヤータイプ	出力データ数	パラメータ数
lstm_1	LSTM層	7	364
dense_1	全結合層	1	8
パラメータ総数			372

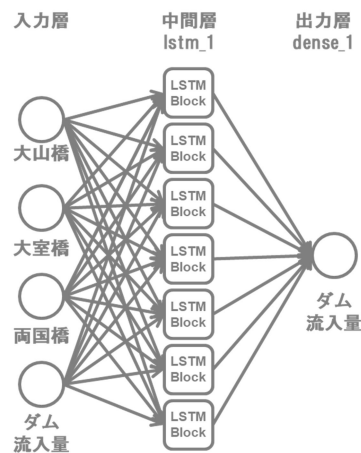


図-16 LSTM モデル構造

が高いことを確認している。これは小さなデータセットにパラメータを増やしたモデルを適用しても大きな効果が得られないことを示唆しており、取り扱うデータ量を勘案しながら適切なネットワーク構造を選定していく必要がある。

5. モデルの学習結果

52個の既往出水データを学習したのち、平成27年の3個の出水 (7月3日、7月16日、9月9日) データについて予測精度を検証した。

予測値と計算値 (観測値相当とする分布型流出解析モデルの計算結果) の乖離度についてRMSEを用いて整理し、その結果を図-17~図-19に示した。RMSEは(8)式より算定した。Nは総計算ステップ数、 $Q_c(i)$ はi時の計算値、 $Q_p(i)$ はi時の予測値である。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_c(i) - Q_p(i))^2} \dots\dots\dots (8)$$

また、図-20～図-22 に時系列で計算値と予測値を示した。いずれも点線が 3NN と LSTM による計算値、実線が予測値である。

(1) 平成 27 年 7 月 3 日出水について (図-17, 図-20 参照)

本論文では降雨データを入力データとして含めないため、現時刻よりも先の予測は、上流側観測点とダム地点との洪水到達時間差によって担保されており、3NN も LSTM も洪水到達時間を超える先の予測となる 2 時間先以降で予測精度の劣化程度 (RMSE 変化) が大きくなる。それ以降、3NN と LSTM の予測精度の違いは 5 時間先までほとんどなく、現時刻のみ LSTM が 3NN の予測精度を上回る。これは、LSTM の前後データの連関性を保持する機能の影響である。例えば、ダム地点のピーク流量の予測精度を高めるためには、ある上流側観測地点の「ピーク時刻前後の連続データ群」とダム地点の「ピーク時刻以前の連続データ群」との連関性が重要であり、その連関性が高い場合、データの前後関係を読み取る能力の高い LSTM は良好な予測精度を確保できる。逆に、その連関性が低い場合、LSTM の特性を發揮できず、データの流れを読み取らない 3NN の予測精度を LSTM の予測精度が上回らないことがある。ただし、その比較優劣はデータ特性に左右され、現時刻においてさえ 3NN が LSTM よりも優れた予測精度を算定することも十分に考えられる。

こういった 3NN と LSTM の予測精度の優劣は、流域特性に起因すると考えられる。降った雨が直ぐに流出する洪水到達時間が短い流域では、データの前後の連関時間は短い。一方、洪水到達時間が長い流域では、降った雨が貯留等を交えながら時間をかけて流出するためデータの前後の連関時間が長い。後者であれば LSTM が 3NN の予測精度を上回る優位性は高いが、前者であれば LSTM の優位性は低い。この結果、洪水到達時間が短い道志ダム上流域では、データの前後の連関性を読み取らない 3NN の予測精度が僅かに上回る結果となっている。

(2) 平成 27 年 7 月 16 日出水について (図-18, 図-21 参照)

3NN と LSTM の予測精度の違いは平成 27 年 7 月 3 日出水と同様であり、洪水到達時間を超える 2 時間先以降の予測精度はいずれも低下程度 (RMSE 変化) が大きくなる。また、現時刻の予測精度は LSTM の方が良いのも同様である。全体的には 3NN も LSTM も予測精度に大きな差異はないが、3NN よりも LSTM はダム流入量を小さく予測する傾向があり、予測時間先が大きくなるほど顕著な傾向となる。

(3) 平成 27 年 9 月 9 日出水について (図-19, 図-22 参照)

前半部に小さいピークがあり、後半部に大きいピークがある出水である。3NN と LSTM 共に、前半部の小さいピークは 2 時間先も良い予測精度を維持している一方、後半部の大きいピークは大きく予測形状を崩している。3NN と LSTM 共に 2 時間先未満の予測精度は良好であるが、2 時間先以降の予測精度は悪く、洪水到達時間を利用した予測精度の限界が感じられる。

7. おわりに

上流側水水量と下流側水水量を関係づける新手法として深層学習方式の LSTM (Long Short-Term Memory) を採用し、従来手法である 3 層ニューラルネットワークと比較し、ダム流入量の予測精度を確認した。基本的には、上流地点から下流地点に至る洪水到達時間を利用してダム流入量の予測精度を高めようとする手法の提案 (図-4 参照) であり、洪水到達時間以上のリードタイムが必要な場合は、別途、雨量、特に予測雨量が必要となる。

本論文では、筆者等が実務で活用してきた 3NN とのモデル対比を切




図-17 平成 27 年 7 月 3 日のパターン毎の精度検証




図-18 平成 27 年 7 月 16 日出水のパターン毎の精度検証

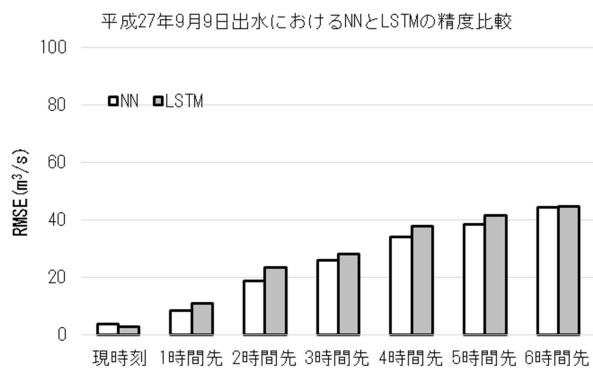


図-19 平成 27 年 9 月 9 日出水のパターン毎の精度検証

り口とし、LSTM の適用過程・適用結果等を示し、実用上は 3NN と LSTM で大きく性能が変わらない結果となった。ただし、あくまで道志ダム流域を対象とした、過去 10 年間程度の高水データに対しての結果である。3NN や LSTM に関わらず、学習により構築したモデル精度はデータセットに支配される部分が多く、今しばらくは様々なデータセットを対象に LSTM の可能性を探った事例の積み重ねが必要である。例えば、より大きな流域やより観測データが存在する流域等のより複雑なデータ条件での適用、また、高水だけでなく低水も含めた適用等の可能性を検討することが重要である。




図-20 平成27年7月3日出水に対する各モデルの予測状況

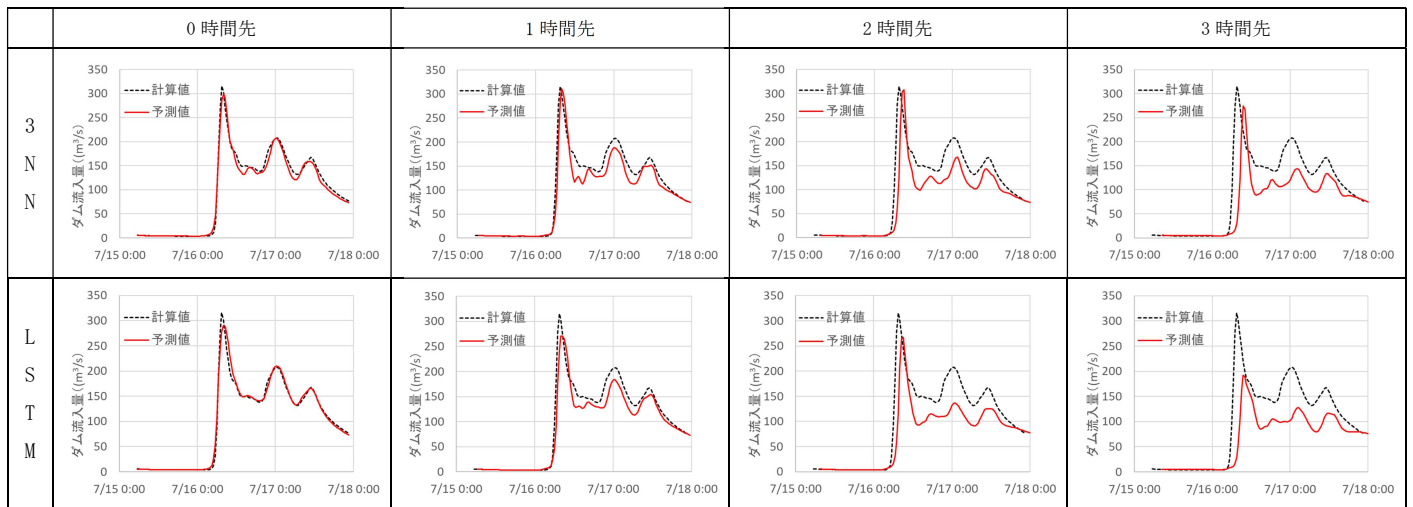


図-21 平成27年7月16日出水に対する各モデルの予測状況

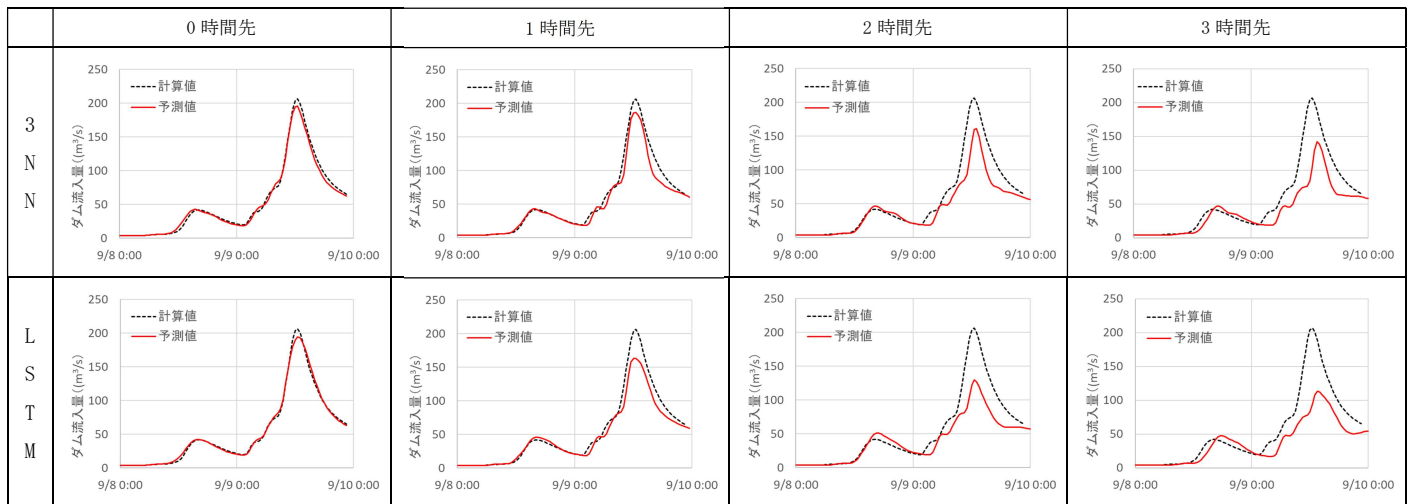


図-22 平成27年9月9日出水に対する各モデルの予測状況

参 考 文 献

- 1) 日野幹雄：水文流出系予測へのカルマン・フィルター理論の適用，土木学会論文報告集，No. 221，pp. 39-47，1974。
- 2) 角屋睦，田中丸治哉：長短期流出両用モデルによる実時間洪水予測，農業土木学会論文集，No. 177，pp. 31-41，1995。
- 3) 藤田暁，大東秀光，上坂薫，椎葉充春，立川康人，市川温：分布型流出モデルに基づくダム流入量実時間予測モデルについて，水工学論文集，第45巻，pp. 115-120，2001。
- 4) 立川康人，須藤純一，椎葉充晴，萬和明，キムスンミン：粒子フィルター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，第55巻，pp. 511-516，2011。
- 5) 工藤亮治，近森秀高，永井明博：粒子フィルタを用いた実時間洪水予測システムの構築と河道任意地点における予測精度の検証，水文・水資源学会誌，pp. 137-148，第24巻，第3号，2011。
- 6) 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), Vol. 48, No. 4, pp. I_511-516, 2012.
- 7) 天方匡純, 梁田信河, 渡邊優: 粒子フィルターを活用したダム流入量予測に関する研究, 電力土木, No. 389, pp. 16-22, 2017.
 - 8) 天方匡純, 梁田信河, 田代克浩: SOINN (自己増殖型ニューラルネットワーク) を活用したダム流入量予測に関する研究, 電力土木, No. 389, pp. 9-15, 2017.
 - 9) 井本文雄, 中村正俊: 雨量情報に基づく数時間先行のダム流入量のオンライン予測法, 電学論B, 113, 3, pp. 213-220, 1993.
 - 10) 瀬野英二, 村上研二, 泉田正則, 松本普: 広域雨量データを用いたニューラルネットワークによるダム流入量予測, 電学論B, 124, 4, pp. 561-568, 2004.
 - 11) 竹村仁志, 眞間修一, 吉田武司, 石上尚: 中流域に洪水調節ダムを有する河川における洪水予測システムの精度検証, 河川技術論文集, 第19巻, pp. 247-252, 2013.
 - 12) 関基, 木村晃, 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, 第19巻, pp. 295-300, 2013.
 - 13) Hochreiter, S. and Schmidhuber, J.: Long short-term memory, Technical Report FKI-207-95, Fakultät für Informatik, Technische Universität München, 1995.
 - 14) Hochreiter, S. and Schmidhuber, J.: Long Short-Term Memory, Neural Computation, 9(8), pp. 1735-1780, 1997.
 - 15) Graves, A. and Schmidhuber, J.: Framewise phoneme classification with bidirectional lstm networks, In Proceedings of the 2005 International Joint Conference on Neural Networks, Montreal, Canada, 2005.
 - 16) Klaus Greff, Rupesh K. Srivastava, Jan Koutník, Bas R. Steunebrink, Jürgen Schmidhuber: LSTM: A Search Space Odyssey, IEEE Transactions on Neural Networks and Learning Systems, pp. 2222-2232, 2017.
 - 17) G. Cybenko: Approximation by superpositions of a sigmoidal function, Mathematics of control, signals and systems, 2(4), pp. 303-314, 1989.
 - 18) Kurt Hornik, Maxwell Stinchcombe, Halbert White: Multilayer Feedforward Networks are Universal Approximators, Neural Networks, 2(5), pp. 359-366, 1989.
 - 19) Hochreiter, S.: Untersuchungen zu dynamischen neuronalen Netzen, Diploma thesis, Technische Univ. Munich, 1991.
 - 20) 国立研究開発法人防災科学技術研究所: Xバンドマルチパラメータレーダ, <http://mp-radar.bosai.go.jp>, (2017. 3. 7)
 - 21) Shuai Li, Wanqing Li, Chris Cook, Ce Zhu, and Yanbo Gao: Independently Recurrent Neural Network (IndRNN): Building A Longer and Deeper RNN, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 5457-5466, 2018.
 - 22) 吉野文雄, 吉谷純一, 堀内輝亮: 分布型流出モデルの開発と実流域への適用, 土木技術資料, 32-10, pp. 54-59, 1990.

ABSTRACT

In order to predict the inflow discharge precisely, we selected to use LSTM (Long Short-Term Memory) which is one kind of RNN (Recurrent Neural Network) which is included in Deep Neural Network. In this research, we recognized that both LSTM and three layers neural network using the upstream discharge information could estimate the inflow discharge after two hours adequately

without the rain information. But as the accuracy of the machine learning model is much affected by the dataset, we have to make this method adapt the other basin datasets. And we have to confirm the possibility of the application in the low and high water situation.