

## 河川氾濫リスク評価に対する LSTM と物理モデルの比較 Comparative study of LSTM and Physical Models for River Flood Risk

張 嘉欣<sup>†</sup>  
ZHANG JIAXIN

岡崎 威生<sup>‡</sup>  
Takeo OKazaki

### 1. はじめに

日本の国土は約 7 割を山地が占めており、河川は急勾配かつ流域面積が狭小である。このような地理的特性により、洪水は日本に暮らす人々にとって最も身近な自然災害の一つとなっており、毎年のように甚大な被害が報告されている。こうした被害を軽減するためには、降雨情報から河川の水位変動を予測し、事前に対策を講じることが不可欠である。しかし、降雨から河川への流出過程は、地形、土地被覆、土壌分類、湿潤状態など多数の要因に依存し、極めて複雑である。そのため、正確な予測を行うことは依然として困難である。こうした背景を踏まえ、洪水予測の分野では、これまでにさまざまな手法が提案されてきた。

洪水予測の分野では、従来から物理モデルが広く用いられてきた。これらのモデルは流体の運動を記述するナビエ・ストークス方程式などの物理法則に基づいており、理論に則った予測が可能であるという利点がある。そのため、流出解析の現場では長年にわたり信頼されてきた。ただし、物理モデルによる予測にはいくつかの課題もある。特に、モデルパラメータの事前同定が難しいこと、そして実時間の観測データを予測に動的に反映しにくい点が問題となっている。

一方で近年は、物理法則に依存せず、データの入出力関係に注目して予測を行うデータ駆動型アプローチが登場している。機械学習ベースの手法では、水文学的知識がなくてもモデル構築が可能であり、十分なデータがあれば高精度な予測を実現できる。しかしながら、こうした機械学習モデルは大量の学習データに依存するため、観測データの少ない地域では性能が低下する傾向がある。

### 2. 課題

洪水予測においては、予測精度の向上が長年の研究課題とされてきた。特に近年では、物理モデルの高度化や機械学習技術の導入により、水位変動の時系列予測が可能となりつつあり、一定の成果が挙げられている。しかし、実際の災害対応においては、単なる予測精度の高さだけでは不十分であり、予測の内容とタイミングが意思決定にとって有効かどうか極めて重要となる。従来の洪水予測モデルでは、平均絶対誤差 (MAE) や平均二乗誤差 (MSE) などの対称的な誤差指標が評価関数として広く用いられてきた。これらは予測値と実測値の差の大きさに着目するものであるが、その誤差が「過大」であるか「過小」であるかといった誤差の方向性には配慮されていない。しかし洪水のピーク時では、予測が過小であった場合には、避難や排水操作などの判断が遅れ、甚大な人的・物的被害を引き起こす可能性が高い。一方で、予測がやや過大であった場合には、避難の空振りといった社会的コストは発生するものの、被

害そのものを拡大させるリスクは相対的に小さい。このことから、過小予測は過大予測よりも重大なリスクを孕んでいると考えられる。また、たとえ水位のピークを正確に予測できたとしても、それが実際の洪水発生の直後であれば、警報の発令や住民の避難に要する時間を十分に確保することができない。これは、予測の遅れとして実用上の大きな障害となる。

これらの課題は、従来の誤差最小化を目的とするモデルでは十分に対処されていない。したがって、今後の洪水予測モデルには、「安全側に予測する」とこと、「できる限り早い段階で予測する」とことを両立する新たな設計指針が必要とされている。

本研究では、こうした背景を踏まえ、過小予測と予測遅延の両方を考慮に入れた予測手法の構築を研究課題として位置付け、リスク感度を高めた損失関数の設計と、それを用いたモデル最適化の実現を目指す。さらに本研究では、これらの課題に加え、洪水予測における物理モデルと深層学習モデル (特に LSTM) の比較研究を通じて、それぞれの手法が有する利点・限界・実用上の適合性を明らかにすることをもう一つの研究課題とする。

### 3. 従来の予測方法

物理モデルを用いた洪水予測では、予測精度の評価指標として従来から平均二乗誤差 (MSE) や平均絶対誤差 (MAE) が一般的に用いられてきた。しかしながら、これらの評価指標は「過小予測」と「過大予測」を同等に扱っており、災害リスクの非対称性に対応していないという課題がある。

これらの問題に対して、宮本ら (2016) は、洪水予報に適した非対称的な誤差評価指標を導入した。彼らは、「過小予測が引き起こすリスクは過大予測よりも大きい」という実災害上の観点から、以下のような損失関数を導入している：

$$\text{Loss} = \begin{cases} \alpha \cdot |y - \hat{y}|, & \text{if } \hat{y} < y \\ (1 - \alpha) \cdot |y - \hat{y}|, & \text{if } \hat{y} \geq y \end{cases}$$

$y$  : 観測水位

$\hat{y}$  : 予測水位

$\alpha \in (0.5, 1]$  : 過小予測に対する重み係数であり、過小予測をより重くペナルティ化するために 0.8~0.95 程度に設定される。

この損失関数を適用することで、モデルのパラメータ調整や評価において「安全側の予測」が促進され、実運用上より信頼性の高い予測が可能になるとされている。

一方、従来の物理モデルでは、流体力学や流出モデルに基づいた明示的な物理的解釈が可能であるという利点を持つが、その反面、計算負荷が大きく、パラメータの初期化や事前校正に多大な労力を要するという課題があった。こうした課題を背景に、一言ら (2016) は深層学習技術を活用した水位予測手法を提案した。彼らの提案するモデルは、

<sup>†</sup> 琉球大学大学院理工学研究科 Graduate School of Science and Engineering, University of the Ryukyus

<sup>‡</sup> 琉球大学工学部 Faculty of Engineering, University of the Ryukyus

4 層構造の順伝播型ニューラルネットワーク (Feedforward Neural Network) であり、水位と降雨量の過去の時系列データをもとに、将来の河川水位を予測する仕組みである。具体的には、入力データとして過去 60 分間の時間降雨量と水位観測データを用い、出力としては予測対象河川における 30 分後から 1 時間後までの水位を生成する。モデルの学習には平均二乗誤差 (MSE) が誤差関数として採用され、以下の目的関数を最小化するように設計されている

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

$y_i$  : 実際の水位 (観測値)

$\hat{y}_i$  : モデルの予測値

学習には誤差逆伝播法 (Backpropagation) および Adam 最適化アルゴリズムが用いられており、実時間予測に対応した柔軟かつ高精度なモデル構築が目指されている。

#### 4. 提案

本研究では、上記の課題に対して以下の二つの視点からアプローチを試みる。

第一に、宮本ら (2016) が提案したリスク加重型損失関数を、物理モデルおよび機械学習モデルの評価指標として導入することである。これにより、過小予測を抑制した「安全側の予測」を実現し、従来よりも災害対応に適した予測システムの構築を目指す。第二に、過去の洪水事例データおよび降雨データを用いて、長期時系列予測に適した LSTM を代表とする深層学習モデルと、パラメータ最適化を施した物理モデルの予測性能を比較する。特に、以下の観点から両モデルの有効性および実用性を検討する：

- 予測精度 (MAE/MSE および非対称損失による評価)
- データ依存性・汎用性
- 災害リスク回避の適合性 (過小予測の割合)

また、本研究により、以下のような成果が期待される：

- 非対称損失を導入した予測モデルによって、災害リスクに配慮した実用的な水位予測が可能となる。
- LSTM と物理モデルの比較分析を通じて、両アプローチの長所・短所を明確化し、状況に応じたモデル選定の指針を提供できる。
- 提案手法は、将来的にリアルタイム防災システムや避難情報発信支援ツールとしての応用が期待される。

#### 5. 比較実験

本研究では、洪水予測のための二つの手法——物理モデルと機械学習モデル (LSTM) の性能を比較し、非対称損失関数の導入による予測精度および安全性の向上を検討する。実験は以下のステップに沿って実施した。

まず、時系列水文データの収集および前処理を行い、次に物理モデルの構築とパラメータの最適化を実施した。さらに、LSTM モデルを構築し学習を行った後、両モデルによる洪水時の水位予測結果を比較し、その精度と実用性を評価した。

対象流域としては、宮崎県を流れる大淀川水系の樋渡水位観測所を選定した。当観測所は、流域面積が約 816km<sup>2</sup> におよび、山地や丘陵地に囲まれた地形的特徴を有する。流域内には図 1 のように、複数の水位および雨量観測所が設置されており、高密度な観測データの取得が可能である。

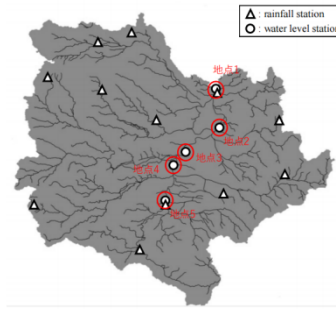


図 1 : 樋渡水位観測所の流域界と流域内の雨量および水位観測所

本研究では、水門水質データベースから取得した水位および地点雨量データを利用し、機械学習モデルではそれぞれの予測対象地点に対して個別にモデルを構築した。物理モデルの構築には、標高データ (DEM) と C バンドレーダ雨量データを使用した。RRI モデルの機能を用いてメッシュ分割と標高データの反映を行い、流域全体の詳細な水理挙動を再現した。

実験に用いたデータは、学習データ・検証データ・テストデータに分割され、特に 2016 年 9 月に発生した洪水事例をテストケースとして評価に用いた。観測データは 1 時間ごとの時系列形式で記録されており、欠損値に対しては線形補間または移動平均法による補完を施した。また、モデルの学習安定性を高めるため、すべての変数に対して Min-Max スケーリングによる正規化処理を行った。

時系列データを用いた洪水予測においては、欠損値 (missing values) の存在がモデル精度に大きく影響する。特に機械学習モデルにおいては、欠損値をそのまま残すと学習が困難となるため、適切な補完処理が不可欠である。本研究では、欠損の継続時間に応じて補完手法を選択した。欠損が 2 時間以下の場合には、線形補間 (Linear Interpolation) を適用し、間を直線で結ぶことで滑らかな補完が可能となる。

$$\hat{x}(t) = x(t_1) + \frac{t - t_1}{t_2 - t_1} (x(t_2) - x(t_1)), \quad (t_1 < t < t_2)$$

$x(t_1), x(t_2)$  : それぞれ欠損区間の直前・直後の既知の観測値

欠損が 3~11 時間連続の場合には、移動平均補完 (Moving Average Imputation) を適用する。

$$\hat{x}(t) = \frac{1}{2k+1} \sum_{i=-k}^k x(t+i), \quad \text{ただし } k=6$$

これは、前後 12 時間のウィンドウ (計 13 点) で平均を取り、データのなだらかな変化を維持しながら補完する手法である。特に降雨データや水位データのような変動幅の大きい系列に対して有効である。

さらに、河川水位や降雨データ等の観測系列には、センサー異常、通信エラー、環境ノイズなどに起因する外れ値が混入している可能性がある。これらの外れ値はモデル学習時の勾配不安定化や予測誤差の拡大を引き起こすため、統計的指標に基づく除去処理を施す。本研究では、Z スコア法 (Z-score method) を用いて異常値を識別し、閾値を超えるデータを除外対象とした。与えられた系列データ  $x_1, x_2, \dots, x_n$  に対して、Z スコア  $z_i$  は以下のように定義され

る :

$$z_i = \frac{x_i - \mu}{\sigma}$$

$\mu$  : 系列全体の平均値  
 $\sigma$  : 系列の標準偏差  
 $x_i$  : 各時刻の観測値

Z スコアの絶対値が 5 を超えるデータを外れ値と判定し、学習対象から除外した。また、水位データにおいては、異常に高いピークや、ゼロ近傍での急激な落下が確認された場合に外れ値として除去する。

深層学習モデル、特に LSTM (Long Short-Term Memory) のようなリカレントニューラルネットワークにおいては、入力変数のスケールの差異が学習収束性と勾配安定性に大きな影響を与える。そのため、モデル学習に先立ち、すべての連続変数に対してスケーリング処理を行う必要がある。

本研究では、Min-Max スケーリング (最小最大正規化) を適用し、すべてのデータ系列を [0, 1] の範囲に変換した :

$$x_{\text{norm}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}}$$

$x_{\text{min}}$  : 系列中の最小値  
 $x_{\text{max}}$  : 系列中の最大値

この変換により、すべてのデータが 0~1 の範囲に収まり、LSTM セル内部の活性化関数 (特にシグモイド関数) との整合性が保たれる。

物理モデルとしては、構造が比較的単純で実装性の高い貯留関数法 (Storage Function Method) を採用した。このモデルは、流域全体の降雨-流出関係を平均化されたパラメータで記述する集中型モデルであり、次のように定式化される :

$$Q(t) = \frac{S(t)}{K}, \quad \frac{dS(t)}{dt} = P(t) - Q(t)$$

$S(t)$  : 貯留量 [mm]  
 $P(t)$  : 降雨量 [mm/h]  
 $Q(t)$  : 流出量 [mm/h]  
 $K$  : 時定数パラメータ

本研究では、これを最適化するために、宮本ら (2016) が提案した非対称損失関数を目的関数として用いる。パラメータ最適化は、Scipy ライブラリの optimize.minimize 関数を用いて、非線形目的関数に対する数値的最小化を実行する。

一方、本研究においては、物理モデルとの比較のため、長短期記憶ネットワーク (Long Short-Term Memory, LSTM) を用いた水位予測モデルを構築した。LSTM はリカレントニューラルネットワーク (RNN) の一種であり、時系列データにおける長期依存性の学習に優れていることから、降雨-流出過程のモデリングに適している。本研究で用いたモデルは、以下のような順伝播型の LSTM アーキテクチャで構成されている。

- 入力層 : 60 時間分の過去データ (降雨量+水位)
- LSTM 層 : 2 層 (各 128 ユニット)、dropout 率 0.2
- 全結合層 (Dense) : 1 ユニット (1 時間後の水位予測)
- 活性化関数 : 全層で tanh、出力層で linear

LSTM モデルの学習には、各観測点における過去 60 時間の水位・降雨データを入力とし、1~3 時間後の水位を出力とするように系列分割を行った。入力系列は以下のように定義される :

$$X_t = [\{P_{t-59}, P_{t-58}, \dots, P_t\}, \{H_{t-59}, H_{t-58}, \dots, H_t\}]$$

$P_t$  : 時刻 t における降雨量 (mm/h)

$H_t$  : 時刻 t における水位 (m)

## 6. 比較結果

本研究では、2016 年 9 月 1 日から 9 月 30 日までの観測データを学習用として用い、特に 19-21 日に発生した洪水に対して、水位予測性能の検証を行った。予測対象は、現在時点から 9 時間先までの水位変動であり、予測には直前 12 時間分の水位および降雨データを入力とした。

評価では、物理モデル (DNN を導入した RRI 構造) と LSTM モデルの両方に対して同一条件下で予測を行い、各予測結果と観測水位との比較を通じて、モデルごとの特性と課題を明らかにした。図 2~図 4 に示されるように、LSTM モデルは時系列的なパターンを学習しており、水位の急激な上昇を比較的早期に検出する能力を有していた。特に降雨量が集中した期間においては、LSTM モデルが実測値のピークに対して先行的に反応する傾向が見られ、予測のタイミングと強度の両面で良好な結果が得られた。一方で、物理モデルは、全体的な水位の傾向に対して堅実に追従する挙動を示していたが、ピークのタイミングや急変動の振幅においてやや鈍化した反応を示す場面も確認された。この背景には、物理モデルにおける拡散的な応答特性およびパラメータ同定の制約が関係していると考えられる。




図 2 : 降雨開始時の予測結果の比較




図 3 : ピーク到達時の予測結果の比較




図 4：降雨終了後の予測結果の比較

図 2~4 に示されるように、物理モデルおよび LSTM モデルの予測性能には、降雨の段階（開始時・増加時・終了後）によって明確な差異が見られた。

① 降雨開始時

降雨が始まった段階では、LSTM および DNN がいずれも緩やかな上昇傾向を予測した。LSTM は DNN に比べてわずかに高めの予測を示し、観測値のピークに先んじる形で反応していた。

② 降雨増加・ピーク到達時

降雨量が急増し、実測水位が 5m の氾濫危険水位を超える局面において、LSTM モデルは急激な上昇を正確に捉え、ピークのタイミングと振幅の両面で高い一致率を示した。一方、DNN モデルはピークを過ぎたタイミングで過小予測する傾向があり、特に 5 時間で降で明らかな離れが見られた。これにより、氾濫リスクの把握という観点から、LSTM モデルの有用性が際立った。

③ 降雨終了後

降雨が停止した後の水位推移においては、LSTM モデルが依然としてやや高めの水位を予測し続け、安全側のバイアスが確認された。DNN モデルは水位の下降を過大評価する傾向があり、現実よりも急速に減少する予測を出していた。これは過小評価による避難遅延の恐れがある。

	LSTM モデル	物理モデル
初動反応	やや鋭い (過小傾向)	早期兆候を捉える
ピーク予測精度	高精度 高一一致率	やや過大 前倒し
水位の下降傾向	実測に滑らかに 追従	長く高位を維持
避難判断支援	タイミング精度が 高い	早期かつ保守的に 促す
リスク管理適性	応答的 観測重視	安全重視 過小予測回避に強い
過小・遅延リスク 回避	◎ 過小予測を避ける 傾向	○ 非対称損失関数により 安全側に調整

表 1：物理モデルと機械学習比較の総括

7. 今後の課題

本研究では、物理モデルおよび LSTM モデルを用いて洪水時の水位予測を行い、その予測精度や挙動を比較した。一定の成果が得られた一方で、今後の課題も明らかとなった。

まず、モデルの一般化性能を向上させるためには、多様な時期・気象条件の洪水データを用いた学習と検証が必要である。次に、LSTM モデルの過学習を抑えるため、正則化手法や説明可能な AI 技術の導入が求められる。また、リア

ルタイム処理への対応として、推論処理の高速化やモデルの軽量化、エッジデバイスへの実装可能性も検討課題である。さらに、複数地点における広域的な水位予測や、氾濫危険水位との統合的なリスク評価も今後の実用化に向けて重要なテーマである。本研究の手法を基盤として、今後はより高精度かつ即応性の高い洪水予測システムの構築が期待される。

謝辞

本研究に必要な水位および降雨データを提供していただいた沖縄気象台に、深く感謝申し上げます。

参考文献

[1]宮本健太郎,長谷川貴之,森山知宏,「洪水予測に適した非対称損失関数を用いたパラメータ同定の提案,土木学会論文集 B1 (水工学),Vol.72,No.4,pp.889-894,2016.

[2]一言正之,林幸男,大野一樹「深層学習を用いたリアルタイム水位予測モデルの構築」,土木学会論文集 G (環境),Vol.72,No.7, pp.219-225,2016.

[3]佐山敬洋,鈴木秀俊,羽田野直道,「分布型流出モデル RRI によるフィリピンにおける洪水シミュレーション」,土木学会論文集 B1 (水工学),Vol.66,No.4,pp.361-366,2010.

[4]小林恭子,吉田拓哉,藤井義久「観測データに基づくパラメータ推定を考慮した分布型洪水モデルの構築」,水工学論文集,第 54 巻,pp.703-708,2010.

[5]Hochreiter,S.,&Schmidhuber,].(1997)“Long short-termmemory,” Neural Computation,9(8),1735-1780.

[6]日本気象庁「C バンドレーダ降雨データの精度と利用可能性に関する検討」,気象業務支援センター資料,2021 年.