

次元圧縮と深層学習を用いたリアルタイム浸水域予測における メッシュ解像度の影響評価

Evaluation of the Impact of Mesh Resolution on Real-Time Flood Inundation Prediction Using Dimensionality Reduction and Deep Learning

- 山口 歓太, 中央大学大学院, 東京都文京区春日 1-13-27, E-mail : a21.6ff7@g.chuo-u.ac.jp
 中山 龍也, 中央大学大学院, 東京都文京区春日 1-13-27, E-mail : a20.3emg@g.chuo-u.ac.jp
 一言 正之, 日本工営株式会社, 東京都千代田区麹町 5-4, E-mail : hitokoto-ms@n-koei.jp
 櫻山 和男, 中央大学, 東京都文京区春日 1-13-27, E-mail : kaz@civil.chuo-u.ac.jp
 Kanta Yamaguchi, Chuo University, 1-13-27 Kasuga, Bunkyo-ku, Tokyo 112-8551, Japan
 Ryuya Nakayama, Chuo University, 1-13-27 Kasuga, Bunkyo-ku, Tokyo 112-8551, Japan
 Masayuki Hitokoto, Nippon Koei Co., Ltd., 5-4 Kojimachi, Chiyoda-ku, Tokyo 102-8539, Japan
 Kazuo Kashiya, Chuo University, 1-13-27 Kasuga, Bunkyo-ku, Tokyo 112-8551, Japan

This paper proposes a surrogate model that integrates dimensionality reduction based on Singular Value Decomposition (SVD) with deep learning using a Deep Neural Network (DNN) to mitigate the high computational cost of conventional numerical flood simulations. While the authors have previously demonstrated the effectiveness of this approach, the present study further examines the impact of mesh resolution on prediction accuracy and computational efficiency. The proposed method was applied to the lower basin of the Arakawa River in Tokyo. Flood simulations were conducted using the finite difference method with three mesh resolutions—25 m, 15 m, and 5 m—which served as reference data. The prediction performance was evaluated in terms of water depth distribution, inundation boundary location, and computational efficiency. The results revealed that the proposed method consistently maintained high accuracy across all mesh resolutions while substantially reducing computation time. These findings confirm that the proposed approach is highly effective for real-time flood prediction.

1. はじめに

近年、豪雨や異常気象の頻発により河川氾濫による浸水被害が深刻化しており、地球温暖化の進行に伴い洪水リスクのさらなる増大が懸念されている。被害軽減には、降雨や水位の変化を迅速に把握し、高精度な浸水予測に基づく防災対応が不可欠である。このため、氾濫解析に基づく浸水予測システムの研究開発が進められてきたが、膨大な計算コストを要するためリアルタイム運用には課題が残る。

近年、この課題に対し深層学習を活用した手法が注目されており、Stacked Autoencoder と LSTM を組み合わせた浸水域予測手法⁽¹⁾や、畳み込みニューラルネットワーク (CNN) を用いて都市域の複雑な地形情報と降雨時系列データを入力とし、浸水予測を高速に行う手法⁽²⁾などが提案されている。これらは従来手法と比べ計算時間を大幅に短縮しつつ精度を維持することを目的としている。

著者らはこれまでに、次元圧縮と深層学習を組み合わせたリアルタイム浸水域予測手法⁽³⁾を提案し、特異値分解 (Singular Value Decomposition; SVD)⁽⁴⁾、非負値行列因子分解 (Non-negative Matrix Factorization; NMF)、およびオートエンコーダ (Autoencoder; AE)などを適用し、荒川流域を対象に高精度かつ効率的な予測が可能であることを示してきた。しかし、メッシュ解像度が予測精度や計算効率に与える影響は十分に検討されていない。

本研究では、SVD と深層学習を組み合わせた手法を構築し、25m・15m・5m メッシュを対象にメッシュ解像度における予測精度および計算効率の影響を比較・検証する。越流パターンごとの 12 時間後の氾濫解析結果を用い、時系列の越流水深データを説明変数、SVD で得られる係数行列を目的変数として学習を行い、精度と計算効率の両面から本手法の有効性を評価する。

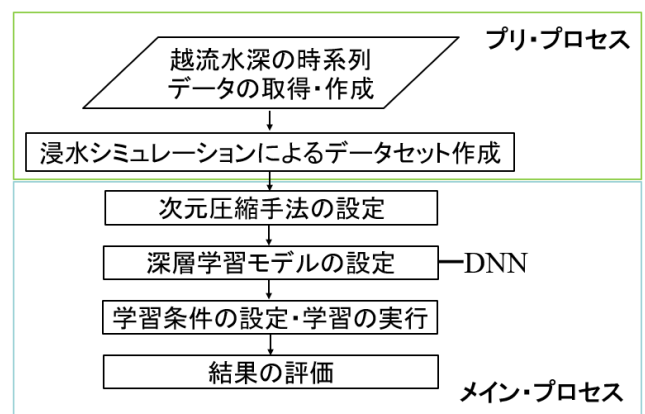


Fig. 1: Flow chart

2. 解析手法

本研究で提案する浸水域予測手法の概要を Fig. 1 に示す。本手法は、氾濫解析の結果を学習データとし、次元圧縮技術と深層学習を組み合わせて構築した。まず、複数の越流シナリオに基づく氾濫解析を実施し、各シナリオに対応する 12 時間後の浸水域を算出する。

次に、解析メッシュごとの浸水深に対して SVD を適用し、空間情報を代表する係数行列と特徴量を抽出する。この処理により、データの高次元性を抑えつつ、氾濫特性を保持することができる。その後、越流水深の時系列データを説明変数、SVD で得た係数行列を目的変数としてディープニューラルネットワーク (Deep Neural Network; DNN) を学習させた。最終的に、本手法を用いて 12 時間後の浸水域を高速に予測する。

実行環境は、東京科学大学が運用するスーパーコンピュータ TSUBAME 4.0 上で実施した。ハードウェアは、CPU に AMDEPYC 9654, メモリ 384 GB, GPU に NVIDIA H100 (2 基) を搭載した構成である。OS には Linux を使い、ソフトウェアには Python 3.10.13, TensorFlow 2.10.0, および NumPy を使用した。

2.1 氾濫解析

氾濫解析には、Dynamic Wave 法を適用したモデルを用いた。x 方向および y 方向の運動量保存式と質量保存式は次式で表される。

$$\frac{\partial M}{\partial t} + \frac{\partial(uM)}{\partial x} + \frac{\partial(vN)}{\partial y} + gh \frac{\partial H}{\partial x} = -gh \frac{n^2 u \sqrt{u^2 + v^2}}{R^3} \quad (1)$$

$$\frac{\partial N}{\partial t} + \frac{\partial(uN)}{\partial x} + \frac{\partial(vN)}{\partial y} + gh \frac{\partial H}{\partial y} = -gh \frac{n^2 v \sqrt{u^2 + v^2}}{R^3} \quad (2)$$

$$\frac{\partial h}{\partial t} + \frac{\partial M}{\partial x} + \frac{\partial N}{\partial y} = 0 \quad (3)$$

ここで、 u および v はそれぞれ $x \cdot y$ 方向の流速、 h は水深、 H は基準面からの水位、 R は径深、 $M = uh$ および $N = vh$ は単位幅流量、 g は重力加速度、 n はマンニングの粗度係数である。離散化手法には空間方向に有限差分法(中心差分)、時間方向に陽解法(オイラー法)を用いた。タイムステップは 25m メッシュで 0.20s, 15m メッシュで 0.12s, 5m メッシュで 0.04s とした。粗度係数は、基盤地図情報の土地利用分類⁽⁵⁾に基づき設定した。

2.2 解析条件

対象領域を Fig. 2 に示す。対象領域は東京都荒川区および台東区を中心とする荒川右岸域とした。標高データおよび土地利用データには国土地理院の国土数値情報⁽⁶⁾を使用した。解析領域の解像度は 25m メッシュで 404 × 548 点, 15m メッシュで 672 × 912 点, 5m メッシュ 2016 × 2736 点である。越流水深データは 1 時間ごとに 12 時間分用意し、1000 ケースの越流パターンを生成した。越流水深 h は次式で定義される。

$$h = \left\{ \sin \left(a - 0.5 + \pi \times \frac{t}{720} \right) + 0.3b \right\} \times 2c \quad (4)$$

ここで a, b, c は 1 以下の正の乱数、 t は時刻(分)である。 $h \leq 0$ の場合は $h = 0$ とした。代表的な越流水深パターンを Fig. 3 に、それに対応する 12 時間後の氾濫解析結果を Fig. 4 に示す。平均越流水深最大ケース (CaseA) においての計算時間は 25m メッシュ, 15m メッシュ, 5m メッシュでそれぞれ 266s, 2,811s, 67,380s であった。

3. 次元圧縮手法及び予測手法

次元圧縮は、多次元データを低次元に変換し、情報を保持しつつ計算負荷を軽減する手法である。本研究では、浸水深データに SVD を適用して次元圧縮を行い、得られた係数行列を深層学習の目的変数とした。

3.1 特異値分解

次元圧縮手法の 1 つである特異値分解 (SVD) は、行列を複数の特異ベクトルとそれに対応する特異値に分解する手法である。SVD は以下の式で表され、 $n \times m$ の行列 A は次のように分解される。

$$A = U \Sigma V^T \quad (5)$$

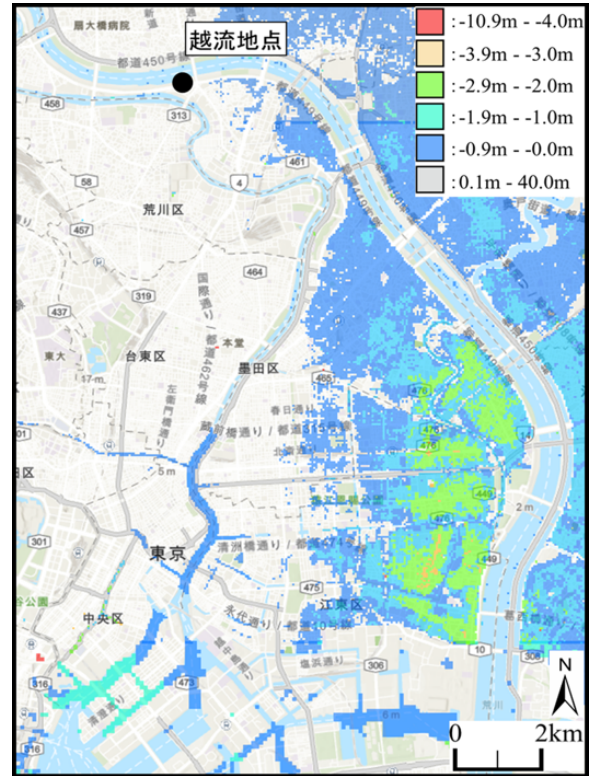


Fig. 2: Target area and elevation distribution




Fig. 3: Example of overflow depth data




Fig. 4: Flood simulation results of Case A

ここで、 U は左特異ベクトル行列、 Σ は特異値を対角成分に持つ対角行列、 V^T は右特異ベクトル行列の転置行列である。各行列は以下のように表される。

Tab. 1: Execution conditions for SVD

対象データ	12時間後の浸水域
入力次元数	25mメッシュ 221,392次元 (404×548)
	15mメッシュ 612,864次元 (672×912)
	5mメッシュ 5,515,776次元 (2,016×2,736)
圧縮次元数	1~20次元の各次元
評価指標	RMSE

Tab. 2: Training conditions for DNN

訓練データ	800case
テストデータ	200case
説明変数	越流水深
目的変数	係数行列
学習回数	最大500回 (損失が10回連続で低減しない場合は早期終了)
中間層の数	4層 (128-64-32-16)
バッチサイズ	32
損失関数	平均二乗誤差
検証方法	交差検証




Fig. 4: Overview of the DNN architecture




Fig. 5: Relationship between the number of compressed dimensions and RMSE

$$U = \begin{pmatrix} u_{1,1} & \cdots & u_{1,m} \\ \vdots & \ddots & \vdots \\ u_{m,1} & \cdots & u_{m,m} \end{pmatrix} = (\vec{u}_1 \quad \vec{u}_2 \quad \cdots \quad \vec{u}_m) \quad (6)$$

$$\Sigma = \begin{pmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_r \end{pmatrix} \quad (7)$$

$$V^T = \begin{pmatrix} v_{1,1} & \cdots & v_{1,n} \\ \vdots & \ddots & \vdots \\ v_{n,1} & \cdots & v_{n,n} \end{pmatrix} = (\vec{v}_1 \quad \vec{v}_2 \quad \cdots \quad \vec{v}_n)^T \quad (8)$$

ここで、 σ_i は特異値を表し、対応する特異ベクトル \vec{u}_i および \vec{v}_i が行列 A の特徴を構成する。特異値が大きいほど情報の重要度が高いため、上位 k 個の特異値と特異ベクトルを用いることで、情報を保持しつつ低次元化が可能である。本研究では、SVD で得られた係数行列 U を DNN の目的変数とした。

3.2 深層学習 (DNN)

本研究では、予測手法としてディープニューラルネットワーク (DNN) を採用し、その概要を Fig. 4 に示す。DNN は、多層のネットワーク構造を通じてデータに内在する複雑な関係性や特徴量を表現できる手法あり、大規模かつ非線形な洪水データの処理に適している。入力層には、1~12 時間後の 1 時間ごとの越流水深を与えた。出力層では、SVD により抽出した係数行列を予測対象とし




Fig. 6: Prediction results for Case A (10 Dimensions)

た。学習後は、得られた係数行列と対角行列で復元計算を行い、浸水域を再構成する。

4. 実行条件と学習条件

SVD および DNN の実行・学習条件を Tab. 1, Tab. 2 に示す。評価指標には RMSE を用い、次式で定義される。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - f_i)^2} \quad (9)$$

ここで n はデータ数、 a_i は予測値、 f_i はシミュレーションによる真値である。なお、RMSE は 5m メッシュの氾濫解析を真値として、3 つのメッシュの格子点が一致する 75m おきの点を評価点とした。



Fig. 7: Shape of the Inundation area in Case A




Fig. 8: Relationship between the number of compressed dimensions and prediction time




Fig. 9: Computational speedup achieved by applying dimensionality reduction

5. ケーススタディ結果

DNN で予測した係数行列を用いて復元した浸水域を予測精度、浸水域の形状、予測時間、計算速度倍率の 4 項目から比較する。

5.1 予測精度

Fig. 5 に圧縮次元数と RMSE の関係を、Fig. 6 に可視化結果 (10 次元) を示す。Fig. 5 に示す RMSE は、1000 ケースの予測結果に基づく平均値である。本手法では、メッシュ解像度が高いほど予測精度が向上し、すべてのメッシュでおおよそ 10 次元程度で高精度となることが確認された。また、10 次元の可視化結果からも、メッシュ解像度が高いほど高精度な予測が可能であることが確認された。

5.2 浸水域の形状

Fig. 7 に氾濫解析結果と予測結果 (10 次元) の浸水域の形状を示す。予測結果はいずれのメッシュにおいても氾濫解析結果より広い浸水域を示した。しかしながら、主要な氾濫方向および浸水範囲の形状は解析結果とよく一致しており、DNN による予測が地形の詳細な特徴を的確に学習していることが示された。

5.3 予測時間

Fig. 8 に予測時間を示す。DNN 推論および SVD 復元を含む予測時間は、1 から 20 次元において、5m メッシュで平均約 5.1s、15m メッシュで平均約 1.1s、25m メッシュで平均約 0.7s であった。最も解像度の高い 5m メッシュにおいても、約 5.1s での予測が可能であったため、次元圧縮の導入により、リアルタイム浸水域予測が可能となることが確認された。また、1~20 次元の範囲では予測時間に顕著な増加傾向はみられなかった。これは、検証対象が全体の次元数に比べて極めて小さい次元範囲に限られているためだと考えられる。

5.4 計算速度倍率

Fig. 9 に平均越流水深最大ケースでの計算速度倍率を示す。ここで用いた予測時間は 10 次元の予測時間である。10 次元の予測時間は、通常の氾濫解析に対し、5m メッシュで約 13,000 倍、15m メッシュで約 2,900 倍、25m メッシュで約 400 倍の高速化が得られた。また、5m メッシュおよび 15m メッシュは 25m メッシュに比べ、それぞれ約 6.9 倍、約 31.1 倍の効率向上を示した。この結果より、メッシュ解像度が高いほど計算効率の向上が顕著となり、より大規模な解析条件においても本手法が有効に機能することが確認された。

6. 結論

本研究では、深層学習と次元圧縮を組み合わせたリアルタイム浸水域予測手法を構築し、メッシュ解像度が予測精度および計算効率に与える影響を比較検討した。得られた結論を以下に示す。

- 高解像度メッシュを用いることで、高精度な浸水域の再現が可能であることを確認した。また、10 次元程度で最も高精度であることを確認した。
- 全てのメッシュ解像度において数秒以内で浸水域を予測でき、特に 5m メッシュにおいても 5 秒程度で高精度な予測が可能であることを示した。
- 通常の氾濫解析と比較して大幅な計算時間の短縮が達成され、特に高解像度メッシュほど計算効率の向上が顕著であることが明らかとなった。

今後は、本手法の汎用性を検証するため、実際に浸水被害事例がある河川での検証を行う予定である。

参考文献

- (1) Kao, I.-F., Lin, G.-F., Lin, T.-R.: Fusing stacked autoencoder and long short-term memory for regional multistep-ahead flood inundation forecasts, *Journal of Hydrology*, Vol.603, 126894, 2021.
- (2) Guo, Y., Zhai, J., Butler, D., Zhang, Y., Yu, D.: Data-driven flood emulation: Speeding up urban flood predictions by deep convolutional neural networks, *Journal of Flood Risk Management*, Vol.14, No.4, e12718, 2021.
- (3) 中山 龍也, 羽物 裕人, 一言 正之, 樫山 和男: 深層学習を用いたリアルタイム浸水域予測における次元圧縮の適用, *AI・データサイエンス論文集*, Vol.5, No.3, pp.563-571, 2024.
- (4) Schmidt, E.: Zur Theorie der linearen und nichtlinearen Integralgleichungen. I Teil. Entwicklung willkürlichen Funktionen nach System vorgeschriebener, *Mathematische Annalen*, 63(1), pp.433-476, 1907.
- (5) 基盤地図情報: 国土数値情報土地利用細分メッシュ, <http://nlftp.mlit.go.jp/ksj/gml/datalist/KsjTmplt-L03-b.html> (参照日: 2024 年 11 月 17 日)。
- (6) 国土地理院: 国土数値情報, <https://www.gsi.go.jp/kiban/> (参照日: 2023 年 10 月 10 日)。