

多地点越流を考慮した次元圧縮手法によるリアルタイム浸水域予測モデルの構築

中央大学大学院 学生会員 ○ 中山 龍也 中央大学大学院 学生会員 羽物 裕人
 日本工営 正会員 一言 正之 中央大学 正会員 檜山 和男

1. はじめに

これまで著者ら¹⁾は次元圧縮手法を深層学習に適用したリアルタイム浸水域予測モデルの構築を行った。しかし、従来の研究は特定地点での越流条件に基づく適用が中心であり、多様な越流シナリオに対応する汎用性に課題が残されている。

本研究は、複数地点からの越流を考慮した浸水域予測モデルを構築し、異なる条件下でも高い適用性を有するモデルの実現を目指す。異なる3つの圧縮次元手法を適用し、予測精度の比較から最適な浸水域予測モデルを検討した。

2. 解析手法

(1) モデル構築と解析の手順

フローチャートは図-1に示す。浸水域推定モデルは、物理法則に基づく洪水氾濫シミュレーションモデルの結果を学習することによって構築を行った。図-1中の(a)学習時では以下の手順でモデルの構築を行う。

1. 越流箇所や浸水規模など様々な浸水状況シナリオに応じた物理法則に基づく洪水氾濫シミュレーションを実施。
2. 洪水氾濫シミュレーションの計算メッシュごとの浸水深を抽出し、浸水の疑似観測データを作成。
3. 次元圧縮手法を用いて、浸水の疑似観測データから特徴量と係数行列を抽出。
4. 深層学習を用いて、越流水深の時系列データから係数行列を推定する予測器を構築。

以上の手順によって構築された浸水域予測モデルを使用し、浸水観測情報に基づき浸水範囲を推定を行う。

(2) 浸水解析モデル

氾濫浸水解析には、氾濫水の挙動を精密に表現可能なDynamic Wave法を適用した。以下の x, y 方向の運動量保存式と質量保存式により構成される。その式を(1), (2), (3)に示す。

$$\frac{\partial M}{\partial t} + \frac{\partial(uM)}{\partial x} + gh \frac{\partial H}{\partial x} = -gh \frac{n^2 v \sqrt{u^2 + v^2}}{R^{\frac{4}{3}}} \quad (1)$$

$$\frac{\partial N}{\partial t} + \frac{\partial(uN)}{\partial y} + gh \frac{\partial H}{\partial y} = -gh \frac{n^2 v \sqrt{u^2 + v^2}}{R^{\frac{4}{3}}} \quad (2)$$

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

ここで、 $M = uh$ は x 方向の単位幅流量、 $N = vh$ は y 方向の単位幅流量、 u は x 方向の流速、 v は y 方向の流速、 h は水深、 H は基準面からの水位、 R は径深、 g は重力加速度、 n はマンニングの粗度係数である。

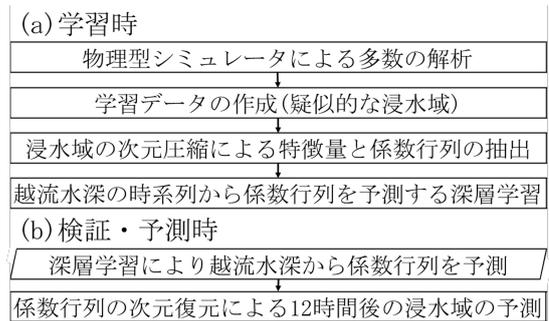


図-1 浸水域予測モデルの構築・検証手順

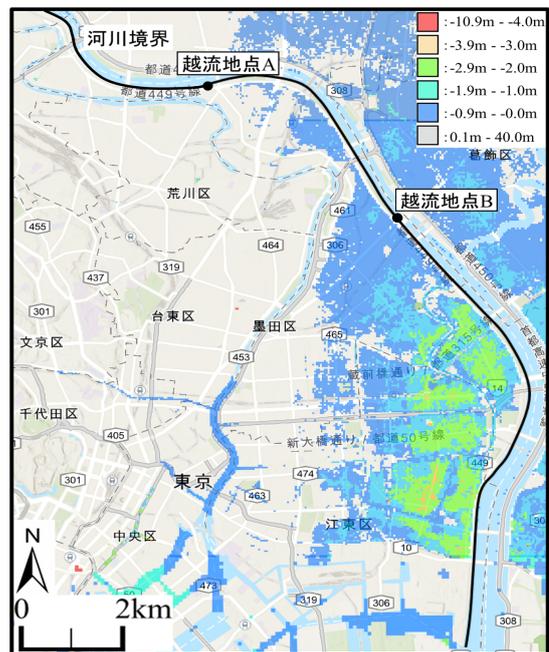


図-2 対象地域とその標高

(3) 学習データ

本研究では、複数の越流地点における1時間ごとの越流水深を入力データとし、洪水氾濫計算プログラムで得られる浸水深を学習データとした。1時間ごとの越流水深を説明変数、目的変数を係数行列に設定する。越流水深の時系列データは、正弦波にノイズを付与して生成した式(4)を以下に示す。

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

式(4)の計算で $h < 0$ となった場合は0に置き換えた。なお、 a, b, c は0~1の間の乱数とし、 t は時間(分)を表す。荒川下流のデルタ地帯を対象地域とし、標高分布を図-2に示す。標高データ・土地利用データには国土地理院の国土数値情報²⁾を使用し、25mメッシュで最近隣挿法を用いた。解析条件は地点A、地点Bからそれぞれ、同時越流の3条件とし、各1000ケースを実施した。

KeyWords : 深層学習, 次元圧縮, 洪水氾濫, 防災, 予測

連絡先 : 〒112-8551 東京都文京区春日 1-13-27 TEL : 03-3817-1815 E-mail : a20.3emg@g.chuo-u.ac.jp

表-1 次元圧縮の実行条件

対象データ	3000case の氾濫域計算結果
入力次元数	221392 次元 (404 × 548)
次元圧縮手法	特異値分解 非負値行列因子展開 AutoEncoder
圧縮次元数	1 から 20 次元 (1 次元ごと)

表-2 AutoEncoder モデルの学習条件

訓練/テストデータ	2400/600case
学習回数	50 回
中間層の数	2 層 (256-128)
バッチサイズ	32
検証方法	交差分割

(4) 次元圧縮

次元圧縮は、高次元のデータの重要な特徴を保持したまま低次元で表現する方法である。データの本質的な特徴を保ちつつ、次元数を減らすことで深層学習が推論に要する計算効率が向上する。今回は、特異値分解³⁾、非負値行列因子展開⁴⁾、AutoEncoder(以後 AE)⁵⁾を用いて氾濫域データを圧縮し、得られた係数行列を深層学習に適用した。

(5) 深層学習手法

本研究では、Deep Neural Network; DNN を採用した。深層学習は、機械学習モデルで、大量のデータから特徴を自動的に学習するアルゴリズムである。本研究では、1 時間ごとの越流水深の数値を説明変数、各ケースごとの係数行列を目的変数とした深層学習モデルを構築する。

(6) 開発環境と学習条件

本例題で行った次元圧縮の実行条件、AE モデルおよび DNN モデルの各学習条件は表-1, 2, 3 に示す。表-3 に示す学習回数は損失が 10 回続けて一定の場合は早期に終了する。浸水域の予測に関する評価指標には 2 乗平均平方根誤差 (Root Mean Square Error ; RMSE) を式 (5) に示す。本研究では、東京科学大学のスーパーコンピュータ TSUBAME4.0 を利用して実施した。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - f_i)^2} \quad (5)$$

なお、 n はデータ数、 a_i は復元された際の浸水深、 f_i はシミュレーションによる浸水深である。

3. 学習結果

図-3 は RMSE と圧縮次元数の関係を示す。図-3 より、圧縮次元数の増加から RMSE は減少し、表現力が向上する傾向を確認した。いずれの手法においても圧縮次元数が 1 から 10 に増加するにつれて RMSE は急激な低下を示し、それ以降は緩やかな減少傾向を示した。今回の結果から AE と DNN を組み合わせたモデルが最も高精度であった。その一方、次元数の増加に伴い性能が悪化する場合もあり、適

表-3 DNN モデルの学習条件

訓練/テストデータ	2400/600case
説明変数	越流水深
目的変数	係数行列
学習回数	最大 500 回
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	交差分割

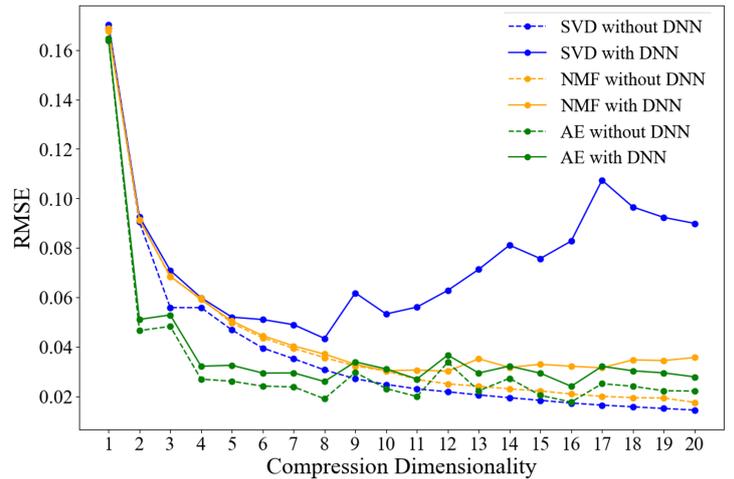


図-3 RMSE と圧縮次元数の関係

切な次元数の選定には検討の余地がある。

4. おわりに

本研究では、多地点の越流を考慮した浸水域予測モデルを構築し、その汎用性の向上を目的として解析を行った。異なる 3 種類の次元圧縮手法を適用し、予測精度の比較を実施した結果、以下の知見を得た。

- 本手法は、任意の地点から発生する越流に対して、高精度な浸水域予測が可能である。
- オートエンコーダを適用した浸水域予測モデルが最も高精度であった。

今後は、最適な圧縮次元数の選定に取り組むことで、更なる予測精度の向上と計算コストの低減を目指す。

参考文献

- 1) 中山龍也, 羽物裕人, 一言正之, 榎山和男: 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 5 巻 3 号, p. 563-571, 2024.
- 2) 国土地理院, 国土基盤情報 <https://www.gsi.go.jp/kiban/> (参照 2023-10-10)
- 3) Eckart C. and Young G., The approximation of one matrix by another of lower rank, *Psychometrika*, 1(3), 211-218, 1936.
- 4) Lee D. D. and H. S. Seung, Learning the parts of objects by non-negative matrix factorization, *Nature*, 401(6755), 788-791, 1999.
- 5) Rumelhart D. E., G. E. Hinton and R. J. Williams, Learning representations by back-propagating errors. *Nature*, 323(1), 533-536, 1986.