

明石工業高等専門学校 都市システム工学科 学生員 ○平田 蒼
明石工業高等専門学校 都市システム工学科 正生員 上野 卓也

1. はじめに

近年、令和6年能登地震津波や南海トラフ地震など津波災害に対する社会的な注目が高まっている。2011年東日本大震災以降、日本では津波に関する研究が盛んに行われてきた。また、津波対策として、津波避難タワーや防潮壁の建設、ハザードマップの作成や防災教育などハード・ソフト両面の対策が進められてきた。

将来の予想される津波災害の対策を検討するためには、過去に発生した津波を正確に把握することが非常に重要である。しかしながら、発生した津波を正確に把握することは困難であり、津波の痕跡や波高計により計測された数値、カメラの映像などが手掛かりになる。

津波の初期分布を推定する津波逆解析は試行錯誤的に行われる場合が多く、解析の効率性や精度に課題がある。そこで、本研究では、機械学習の手法であるCNN (Convolutional Neural Network) を用いて、津波逆解析を試みることで、解析の効率性や精度の向上が期待できる。海岸工学の分野において機械学習を活用した研究例は数多くあるものの、津波逆解析へ適用された研究例は少ない。本研究では、CNNによる津波逆解析の定性的な再現性を明らかにすることで機械学習の津波逆解析への可能性について検討した。

2. 津波数値モデルおよび解析条件

本研究では、初期の津波分布が伝播する過程を数値モデルにより計算した。数値モデルの詳細は、上野ら¹⁾を参照されたい。

解析条件は、表-1に示すように、初期津波の波高 H 、水深 h 、津波の初期形状 S の3つのパラメーターを組み合わせた90ケースの津波シミュレーションを実施した。計算領域は100格子×100格子、空間格子サイズは Δx , $y=1.0\text{m}$ 、地形は $z_b=0\text{m}$ のフラット、 Δt は時間ステップ毎にCFL条件より決定した。初期津波は計算領域の中央部に設定し、伝播する過程を解析した。また、 $n=30$

ステップ時の結果を出力して、CNNの入力データとした。ただし、水深や波高によって伝播速度に違いが生じ Δt が異なるため、30ステップ時点の時間は条件ごとに異なる値となる。

3. 畳み込みニューラルネットワーク

本研究では、津波逆解析を行う手法として、畳み込みニューラルネットワーク (CNN) を採用した。CNNは機械学習の中でも画像分類や物体検出などの画像解析によく用いられる手法であり、データの空間的な位置関係をネットワークに取り込むことができる点に特徴がある。本研究で対象としている津波の空間分布を解析するためには、CNNは有効な手法の1つである。本研究で構築したCNNのモデルは、入力層、畳み込み層 (1層目)、畳み込み層 (2層目)、出力層とした。畳み込み層ではデータのエッジや形状を検出することができる。CNNを画像分類に用いる場合には、プーリング層を入れてデータを圧縮する処理を行う場合が多いが、本研究では入力データと同じサイズのデータを出力するため、プーリング層は導入していない。CNNの実装においては、オープンソースライブラリTensorFlowを使用した。

本研究では、入力データに到達津波、出力データに初期津波分布を与えることで、津波逆解析を試みた。機械学習では基本的には物理モデルに基づいて計算されおらず、単に入力 (到達津波) と出力 (初期津波) を入れ替えるだけで逆解析を行うことができる。

データは80%をトレーニング (学習) データ、10%をバリデーション (検証) データ、10%をテスト (評価) データとした。データを分割する割合については、明確な基準はないが一般的にはトレーニングデータを70~80%にすることが推奨されている。また、1層目のフィルターサイズは32、2層目のフィルターサイズは64、カーネルサイズは5×5、バッチサイズは32、初期の学習率は0.1とした。

4. 結果および考察

津波数値シミュレーションを行った結果を図-1 に示す。初期分布から津波が伝播している様子が確認できる。本研究では到達津波を 30 ステップ時としたため、津波の到達位置はいずれのケースも同様の結果であった。

CNN による津波逆解析を行うにあたってモデルの学習時の損失関数は二乗平均誤差 (MSE) を用いた。つまり、MSE が最小となるようにモデルのパラメーター (重み, バイアス) を決定する。本研究では、適応的な学習率調整手法 (Adaptive Learning Rate) を用いて、学習率を検証データとの誤差に応じて調整することで過学習を防ぎながらも効率的に学習している。また、検証データとの誤差が 10^{-6} となるまでモデルの学習を行い、今回のケースではエポック数は 35 回であった。

構築した CNN モデルを用いて、テストデータの再現を行った。結果の代表的な例を図-2 に示す。いずれのテストデータ (9 ケース) についても、初期津波の定性的な形状や波高は再現されていることが確認された。本研究で構築した CNN モデルは、物理的・力学的な制約条件は組み込まれておらず、単に数値データに基づいた学習により予測を行っており、シンプルな CNN モデルであっても津波逆解析により初期津波の特徴を捉えることが可能であることが明らかになった。特に図-2(a)のように、高い精度で再現された事例も確認できた。一方で、図-2(b)のように、初期津波は再現しているものの、到達津波の結果が混在したような事例も確認された。ニューラルネットワーク系のモデルでは内部での処理がブラックボックス化する。そこで近年は、ブラックボックス

化、つまり極めて複雑化したモデルを単純化する SHAP や LIME などの解釈可能な AI や XAI (説明可能な AI) の手法が発展している。

入力出力データに着目すると、到達津波を $n=30$ と定義したことで波高や水深により波速が変化する点が CNN の逆解析では考慮されていない可能性がある。

5. おわりに

本研究では津波数値解析による結果を用いて CNN による津波逆解析を試みた。主な成果と課題を以下に示す。

1. 初期津波の定性的な分布は再現することが可能であるが、結果にノイズが含まれる場合がある。
2. 解釈可能な AI によりモデル内部の処理を明らかにし、力学的な制約条件を導入するなど、解析精度を向上できる可能性が十分にある。
3. 入出力データに検討の余地が残されており、特に地形条件は本研究では考慮されていない。

参考文献

- 1) 上野卓也, 由比政年, 天方匡純, 煤田真也, 斎藤武久: 四分木格子を適用した有限体積法に基づく数値モデルの構築と透過性防波柵周辺の津波浸水流解析への適用, 土木学会論文集 B2(海岸工学), Vol.72, No.2, pp.I_25-I_30, 2016.

表-1 解析条件

初期波高 H (m)	1, 2, 3
水深 h (m)	10, 20, 30, 50, 100
初期形状 S (m)	$10 \times 10, 6 \times 20, 20 \times 6,$ $20 \times 20, 10 \times 20, 20 \times 10$

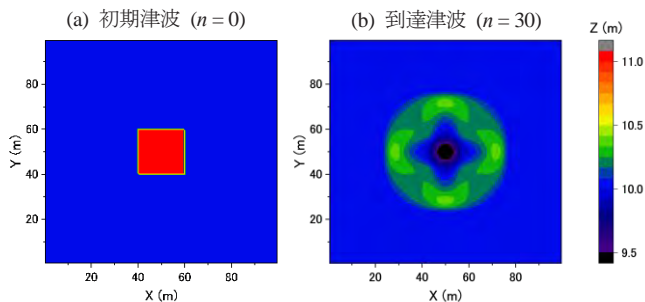


図-1 津波解析の解析例

($H = 1$ m, $h = 10$ m, $S = 20$ m \times 20 m)




図-2 CNN による津波逆解析の例