

2次元波動問題を対象とした 深層学習ベース逆散乱解析手法の開発

○群馬大学大学院理工学府 学生会員 笹岡真次
群馬大学大学院理工学府 正会員 斎藤隆泰
東京工業大学 正会員 廣瀬壮一

1. はじめに

複数の受信点で得られた波動を用いて、その散乱源を推定する逆散乱解析法に関する研究は以前から行われてきた。それら研究の代表例として、ボルン近似やキルヒホフ近似を用いた線形化逆散乱解析や、得られた散乱波形を時間反転させることによって欠陥を検出する時間反転法¹⁾等が挙げられる。しかしこれらの方法は、比較的計算時間がかかることで知られる。一方、近年、機械学習²⁾が注目を集めている。特にニューラルネットワーク (NN) を拡張した深層学習 (CNN) は、AI 作成のための基礎技術として工学の様々な分野で広く利用されている。そこで本研究では、この CNN を用いた新しい逆散乱解析手法を提案する。ただし、逆散乱解析で用いる波動は、数値シミュレーションを用いて再現し、それらを CNN の学習データに用いることとする。以下では、数値シミュレーション手法として用いる時間領域境界要素法と、本研究で用いる CNN について簡単に説明した後、数値解析例を示すことで、本手法の有効性について検討を行う。

2. 解くべき問題

図1のような様々な波動の送信点から同時刻に波動を励起したことで生じる、擬似的な入射平面波による2次元波動散乱問題を考える。入射平面波は、半径 a で、中心座標 (x_{1c}, x_{2c}) に配置された空洞により散乱される。このとき、空洞による散乱波は、送信点と同じ箇所で受信される。解くべき問題は、これら受信波形から、空洞の中心座標 (x_{1c}, x_{2c}) と大きさ (半径 a) を予測する逆問題である。ただし、超音波の伝搬領域は無限領域であると仮定し、空洞は唯一つ存在すると仮定する。この空洞を推定する方法として、冒頭で述べたように、逆散乱解析法等、様々な方法¹⁾が知られているが、本研究では CNN を用いて推定する方法を検討する。なお、CNN を用いる場合、空洞を推定するために、CNN に与える学習データを多数用意しておく必要がある。そのような十分なデータを揃えることができれば、空洞を検出するための有用な手法を構築できる可能性がある。そこで、以下では次節で述べる時間領域境界要素法で求めた散乱波形データ群を用いて、空洞の位置を推定する。ただし、解析の対象は2次元面外波動場とする。




図1 深層学習ベース逆散乱解析モデル。

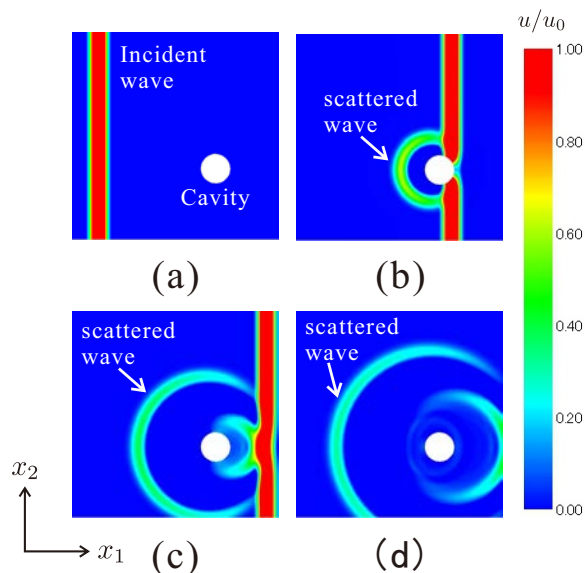


図2 CQBEM を用いて得られた半径 a の空洞周辺における全変位場の時刻歴 (a) $c_t t/a = 5.0$, (b) $c_t t/a = 15.0$, (c) $c_t t/a = 18.0$, (d) $c_t t/a = 22.5$.

3. 演算子積分時間領域境界要素法を用いた2次元波動解析

(1) 演算子積分時間領域境界要素法 (CQBEM)

本研究では、著者らがこれまでに研究を行ってきた CQBEM を用いて受信点における散乱波形を求める。一般的に、従来の時間領域境界要素法 (BEM) は、時間増分が小さい場合に数値解が不安定になることが知られている。CQBEM は、そのような欠点を改善した BEM である。CQBEM の詳細については、紙面の都合上、割愛する。詳細は文献³⁾等を参照されたい。

Key Words: 深層学習, 時間領域境界要素法, 逆散乱解析, 超音波探傷試験.
〒376-8515 群馬県桐生市天神町 1-5-1




図3 CQBEM を用いて得られた受信点における散乱波形の一例
(a) 散乱波形の走時曲線 (b) 走時曲線のカラーマップ。

(2) CQBEM を用いた空洞による平面波の散乱解析例

ここでCQBEMを用いた空洞による平面波の散乱解析例を示しておく。図2は、図1に示すように空洞の左側から擬似的な平面波を送信した場合、空洞周辺の全変位場の可視化結果の一例を示している。図2(a)のように左側から平面波が送信され、図2(b)-(d)のように入射平面波が空洞に到達し、空洞による散乱波が発生している様子を見て取れる。このように空洞と入射波の相互作用により発生した散乱波は、空洞の左側に配置された、いくつかの観測点で受信されることとなる。

4. 散乱波形データの深層学習

さて、CQBEMで集めた散乱波形データに対してCNNを行い、空洞の位置や大きさを推定する。ここで、CQBEMで得られた散乱波形の一例を図3(a)に示す。ただし、図3(a)の横軸は時間、縦軸は素子の中心座標の x_2 座標を示している。欠陥近くの素子である程、散乱波を早期に受信するため、図3(a)のような波形データを得ることができる。今、図3(a)のような波形データをAI作成のための学習に使っても構わないが、図3(a)では縦軸や横軸のキャプション等も含まれており余分な情報を学習してしまう。そこで、本研究では図3(a)のような画像を図3(b)のような学習に不要な情報を取り除いたカラーマップ画像に変換し、それらをCNN作成のための学習画像として用いる。ただし、ここでは教師あり学習とし、学習画像と共に空洞の中心位置 (x_{1c}, x_{2c}) と半径 a も学習させる。その後、このように用意した学習画像群に対して、CNNを用いて適切に深層学習を実施し、CNNモデルを作成する。作成したCNNモデルに、図3(b)のような未学習の散乱波形データを与えることにより、与えた散乱波形データを作り出す元となる空洞の中心位置 (x_{1c}, x_{2c}) と半径 a を推定する。

5. 深層学習による欠陥位置推定結果

以下、数値解析例を示す。CNNにおける学習データとして図3(b)のようなカラーマップ画像を45927枚用意した。CNNの学習には、欠陥の中心位置 (x_{1c}, x_{2c}) を $-8.0a \leq x_{1c}, x_{2c} \leq 8.0a$ の範囲に設定した。入力画像は224ピ

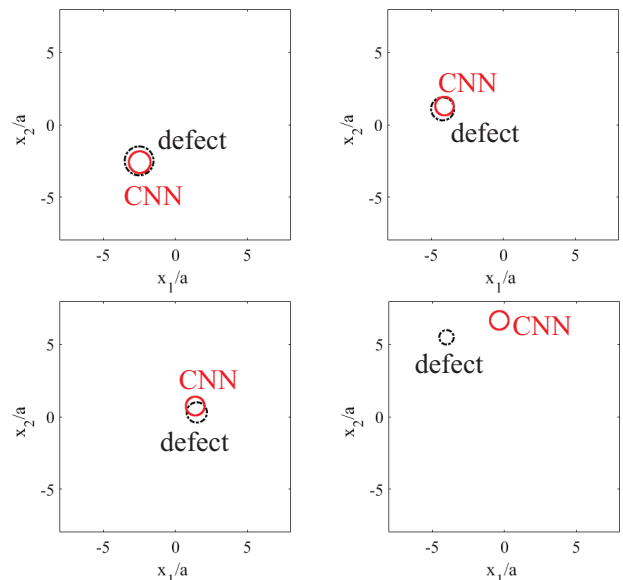


図4 CNNを用いた逆散乱解析手法による空洞の位置と大きさの推定結果の一例(黒点線は実際の空洞の位置)。

クセル*224ピクセルの画像、正則化のための係数である荷重減衰 ω_d は $\omega_d = 1.0 \times 10^{-4}$ 、学習率 ω_l は $\omega_l = 1.0 \times 10^{-4}$ を用いた。学習にはAdamを使用し、総エポック数128のミニバッチ学習を行った。ただしミニバッチサイズは32とした。CNNの学習にはホールアウト法を用い、全学習データをランダムに分割し訓練データと検証データを8:2になるよう学習した。そのため、訓練、検証に用いた画像枚数は、それぞれ36742枚、9185枚である。また、出力層には恒等関数を用いた。図4に本手法を用いて算出された未知の空洞位置と大きさの推定結果の例を示す。各図中の黒点線は実際の空洞(Correct solution)、赤線はCNNで推定した空洞(CNN solution)を示している。図4より、右下の結果の除いた場合では、概ね欠陥の位置や大きさを再構成できていることがわかる。一方、右下のケースは最も空洞が小さい場合、すなわち半径が $0.5a$ の場合である。深層学習は外挿が苦手なため、最も精度が落ちていると考えられるが、これについてはさらに詳細な検討が必要である。

6. おわりに

本研究では、2次元波動問題を対象とし、CNNベースの逆散乱解析手法を開発した。空洞の大きさや位置を概ね推定することができた。今後は、2次元面内波動問題や3次元問題への拡張を予定している。また、実際の計測実験波形を使った場合の検討も行う予定である。

参考文献

- 1) T. Saitoh: Application of various forward and inverse scattering techniques to non-destructive testing, 京都大学数理解析研究所講究録 2174, RIMS 共同研究 (公開型), pp.93-107, (2021).
- 2) Francois Chollet.(株式会社クイープ 訳):PythonとKerasによるディープラーニング, 株式会社マイナビ出版, (2018).
- 3) 斎藤隆泰: 波動解析と時間領域境界要素法, 計算工学, vol.24, No.3, pp.13-16, (2019).