

多点計測データに対する深層学習を用いた 2 次元動弾性逆散乱解析 2-D Elastodynamic Inverse Scattering Analysis Using Deep Learning for Multipoint Measurement Data

斎藤 隆泰 (群馬大・理工) 笹岡 真次 (群馬大・理工)
木本 和志 (岡山大・環境生命科学領域) 廣瀬 壮一 (東工大・環境・社会理工学院)
Takahiro SAITOH, Gunma University
Shinji SASAKA, Gunma University
Kazushi KIMOTO, Okayama University
Sohichi HIROSE, Tokyo Institute of Technology
FAX: 0277-30-1610, E-mail: t-saitoh@gunma-u.ac.jp

This paper presents a 2-D elastodynamic inverse scattering analysis using deep learning for multipoint measurement data. The convolution quadrature time-domain boundary element method (CQBEM) is utilized to obtain scattered waves at multi-receiver points. A supervised learning is implemented to estimate the position and size of a cavity. Numerical results show that our proposed method can estimate the position and size of a cavity in a 2-D elastic solid.

1. はじめに

複数の受信点で得られた欠陥からの散乱波形を用いて欠陥の形状を再構成する逆散乱解析は、以前から行われてきた。それら逆散乱解析に関する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¹⁾、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ている。一方、近年、機械学習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)²⁾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 を用いた新しい欠陥検出手法を提案する。ただし、本研究で用いる多点計測して得られる散乱波は、著者らが開発を続けてきた演算子積分時間領域境界要素法(CQBEM)³⁾を用いて再現し、それら擬似散乱波形データを CNN の学習データに用いることとする。以下では、解くべき問題や、本研究で用いる CNN について説明した後、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

ここでは超音波探傷法(UT)を想定し、Fig.1 のようなリニアアレイ探触子で同時刻に超音波を励起したことで生じる、擬似的な入射平面波の欠陥による散乱問題を考える。入射平面波は、半径 r 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、リニアアレイ探触子上の各素子で受信される。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}) および空洞の半径 r 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。UT における基礎理論の分野では、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、様々な方法が知られているが、本研究では CNN を用いて空洞の位置や大きさ等を推定する方法を検討する。CNN を用いる場合、欠陥である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、欠陥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リニアアレイ探触子の各素子で取得し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、




Fig. 1 Analysis model for CQBEM and inverse scattering technique using deep learning.

解析の対象は 2 次元動弾性波動場とする。そのため、固体中には縦波(P-波)と横波(S-波)の両者が現れることに注意されたい。

3. 2 次元動弾性演算子積分時間領域境界要素法(CQBEM)

本研究では、CQBEM を用いて欠陥からの散乱波形を求める。一般的に、従来の時間領域境界要素法は、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。そこで、本研究では、そのような数値安定性の問題を改善した新しい時間領域境界要素法である CQBEM を用いた。なお、CQBEM の詳細については、紙面の都合上、割愛する。詳細は文献等³⁾を参照されたい。

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 を実装する。ここで、CQBEM で得られたリニアアレイ探触子の各素子での受信波形の一例を Fig.2 に示す。ただし、Fig.2 の横軸は時間、縦軸は素子の中心座標の鉛直成分 x_{2c} を示している。ただし、欠陥の半径 r は $r = 1.5a$ 、空洞の位置は $(x_{1c}, x_{2c}) = (4.5a, -5a)$ としている。Fig.2 より $20.0 \leq c_L t/a \leq 30.0$ 付近で、欠陥からの散乱 P 波を観測していることがわかる。一方、 $35.0 \leq c_L t/a \leq 45.0$ 付近で、散乱 S 波を確認できる。欠陥近くの素子である程、散乱波を早期に受信するため、Fig.2 のような波形データを得ることができる。今、Fig.2 のような波形データを AI 作成のための学習




Fig. 2 Time variations of the received waves at multipoint ($r = 1.5a, x_{1c} = 4.5a, x_{2c} = -5a$).



Fig. 3 Color map of Fig. 2 ($r = 1.5a, x_{1c} = 4.5a, x_{2c} = -5a$).

に使っても構わないが、Fig.2 のまま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。また、波形以外の白塗りの箇所も学習に不要な情報である。そこで、本研究では、Fig.2 のような散乱波形データを Fig.3 のようなカラーマップへ変換し、CNN の学習に用いることとする。ただし、ここでの学習は、教師あり学習とし、Fig.3 のような学習画像と共に、空洞の中心位置(x_{1c}, x_{2c})と半径 r も学習させることとする。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。最終的に、作成した CNN モデルに Fig.3 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 r を推定することを試みる。

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 Fig.3 のようなカラーマップ画像を 4624 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、欠陥の大きさは $0.5a \leq r \leq 2.0a$ の範囲に設定した。入力画像は 224 ピクセル×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 $\omega_l = 1.0 \times 10^{-4}$ とし、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




Fig. 4 Estimation of unknown cavity position and scale using CNN based inverse scattering technique.

った。ただしミニバッチサイズは 16 としている。また、CNN の学習にはホールドアウト法を用い、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の比を 8:2 になるよう学習した。また、出力層には線形関数を用い、空洞の位置(x_{1c}, x_{2c})と半径 r の推定値を出力させる。

Fig.4 に本手法を用いて算出された未知の空洞の推定結果の一例を示す。なお、各図中の黒点線は実際の空洞(正解)を、赤線は CNN ベースの逆散乱解析で推定した空洞(推定)を示している。Fig.4 より 4 つの未学習の散乱波形に対する空洞の位置や大きさは、概ね正しく推定できていることがわかる。本問題の場合、入射平面波は、空洞の左側に直接当たる。そのため、空洞の水平位置 x_{1c} は比較的正解に近い。一方、空洞の鉛直位置 x_{2c} や、空洞の半径 r は、やや正解と異なる値を示していることがわかる。これについては今後、さらなる検討が必要である。しかしながら、深層学習を用いて、空洞のおよその位置や大きさを精度良く推定できる可能性があることを示すことができたと考えられる。

7. まとめと今後の課題

本研究では、2次元動弾性問題を対象とし、CNN ベースの逆散乱解析手法を開発した。空洞の位置や大きさを様々に変化した場合の多点計測による散乱波形データを大量に学習し、CNN モデルを作成した。作成した CNN モデルを用いて未学習の散乱波形データから、欠陥の位置や大きさをある程度推定することができた。今後は3次元問題へと拡張する予定である。

参考文献

- 1) 竹田晴彦, 斎藤隆泰, 廣瀬壮一: 粘弾性体中の領域型および境界型欠陥に対する 2 次元線形化逆散乱解析, 土木学会論文集 A2(応用力学), 77(2), pp. I_47-I_57, 2021.
- 2) 岡谷貴之: 深層学習 (機械学習プロフェッショナルシリーズ), 講談社サイエンティフィク, 2015.
- 3) 斎藤隆泰, 石田貴之, 福井卓雄, 廣瀬壮一: 演算子積分法および高速多重極法を用いた新しい二次元時間領域動弾性境界要素法について, 応用力学論文集, 11, pp.193-200, 2008.