深層学習を用いた固体中の欠陥検出手法の検討

1. はじめに

複数の超音波素子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. それら研究の代表例として、ボルン近似やキルヒホッ フ近似を用いた線形化逆散乱解析、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⁾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 を用いた新しい欠陥検出手法を提案する.ただし, 超音波探傷試験(UT)で取得する散乱波は、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のようなリニアアレイ探触子の各素子で同時刻に超 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 a で,中心 座標 (x_{1c}, x_{2c}) に配置された空洞欠陥により散乱される.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}) 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 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. 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,解析の対象は面外波動場とする.

〇群馬大学理工学部	学生会員	笹岡真次
群馬大学大学院理工学府	学生会員	竹田晴彦
群馬大学大学院理工学府	正会員	斎藤隆泰

linear array element



図1 リニアアレイ探触子を用いた UT における逆解析モデル.



図 2 CQBEM を用いて得られた空洞周辺の全変位場の時刻歴結 果の可視化一例 (a)c_tt/a = 5.0, (b)c_tt/a = 15.0, (c)c_tt/a = 18.0, (d)c_tt/a = 22.5.

3. 時間領域境界要素法を用いた散乱波形のシミ ュレーション

(1) 演算子積分時間領域境界要素法 (CQBEM)

本研究では、時間領域境界要素法 (TD-BEM) を用いて欠 陥からの散乱波形を求める.ただし、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、演算子積分時間領域境界要素法 (CQBEM)³⁾を用いる. 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.





(2) CQBEM を用いた空洞による平面波の散乱解析例

ここで COBEM 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に示すようにリニアアレイ 探触子を設置した左側から平面波を送信した場合の空洞周 辺の全変位場を可視化した結果を示している. 図 2(a)の ように左側から平面波が送信されていることがわかる.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 に配置されたリニアアレイ探触子の各素子で受信されるこ 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 x2 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 (x1c,x2c) 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. 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})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 6561 枚用意した.



図4 CNN を用いた逆散乱解析手法による空洞の位置推定結果の 一例 (黒点線は実際の空洞の位置).

CNN の学習には、欠陥の中心位置 (x_{1c},x_{2c}) を -8.0a ≦ *x*_{1c}*x*_{2c} ≤ -8.0*a* 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 $\omega_l = 1.0 \times 10^{-4}$ 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16とし 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た.図4 に本手法を用いて算出された未知の空洞位置の推定結果の 例を示す. 各図中の黒点線は実際の空洞 (Collect solution), 赤線は CNN で推定した空洞 (CNN solution) を示している. また、実際の空洞の位置と CNN で推定した空洞の位置に ついても各図中に示してある.図4より正しく空洞を推定 できていることがわかる.

おわりに

本研究では、2次元面外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. 空洞の大きさは一定と仮 定したものの, 欠陥の位置を概ね推定できた. 今後は欠陥 の大きさの推定や、2次元面内波動問題へと拡張する予定 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).
- 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).
 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).