

Wave field データの転移学習による 自動非破壊評価システムの開発

○群馬大学大学院理工学府
群馬大学大学院理工学府
東京工業大学環境・社会理工学院

学生会員 荻輪里歩
正会員 斎藤隆泰
正会員 廣瀬壮一

1. はじめに

近年, 構造物の維持管理等を目的に非破壊評価の重要性が高まっている. 特に超音波非破壊評価法は安全性や利便性で優れていることから, 現場で広く利用されている. その中でもレーザー超音波可視化試験¹⁾は将来の完全自動化に向けた非接触かつ高速な検査が可能であり, 試験体表面の超音波伝搬を可視化することができる. 一方で, 近年の AI 技術の発展は目覚ましく, 様々な業界で応用が進んでいる. しかしながら, AI に必須な膨大なデータを集めるためには, 様々な条件下での検査結果を収集する必要がある, 現実的ではない. そこで本研究では, 数値シミュレーションに着目する. 数値シミュレーションを用いることによって, 実験画像と同等の超音波伝搬画像を生成できる. その利点を活かし, 我々のグループでは, 数値シミュレーションで得られた超音波伝搬画像を深層学習させ, 画像中の欠陥の有無を判定する研究を行って来た²⁾. 本研究では, その成果を拡張し, 数値シミュレーションによる超音波伝搬画像と実際の実験画像の両者を学習させた転移学習による自動非破壊評価システムの開発を試みる. 以下では, まず, レーザー超音波可視化試験, 数値解析について説明する. 次に, 転移学習について簡単に説明し, 実際の欠陥に対する適用例を示すことで, 本手法の有効性や, 今後の課題等について述べる.

2. レーザー超音波可視化試験

レーザー超音波可視化試験により, 図 1(a) のアルミニウム試験体中の欠陥を自動的に検出する方法を考える. 試験体の寸法は x 方向の幅が 100mm, z 方向の厚さが 30mm, y 方向の奥行きが 50mm であり, 直径 $\Phi=3\text{mm}$ の貫通空洞が x - z 面に垂直で, 中心 $(x, z)=(50\text{mm}, 15\text{mm})$ の位置に存在するとする (x - z 面左下を $(x, z)=(0\text{mm}, 0\text{mm})$ とする). このアルミニウム試験体の x - z 面に, レーザー超音波可視化試験を実施し, x - z 面の超音波伝搬を可視化する. なお, 超音波の受信には, 中心周波数 1MHz の縦波探触子を用い, $(x, z)=(50\text{mm}, 30\text{mm})$ に設置した. 図 1(b) に図 1(a) のアルミニウム試験体に対するレーザー超音波可視化試験結果の一例を示す. 図 1(b) より, 探触子から放射された入射波の伝搬や, 試験体中央付近の欠陥からの散乱波を確認できる.




図 1 アルミニウムに対するレーザー超音波可視化試験 (a) 試験体 (b) 試験結果.




図 2 レーザー超音波可視化試験に対応する数値シミュレーション (a) 数値解析モデル (b) 数値シミュレーションによる散乱波動場の可視化結果.

3. 数値解析による超音波伝搬シミュレーション

学習に不可欠である膨大な入力画像を集めるために, 有限要素法による数値シミュレーションを行った. 数値シミュレーション画像から得られた特徴量抽出能力をレーザー超音波可視化結果に適用することも見据えて, 解析モデルは図 2(a) で示すように, 図 1(a) と同等のものとした. 図 2(b) に超音波伝搬シミュレーション結果の一例を示す. なお図 2(b) では, 面外方向変位をプロットしてある. 図 2(b) より, 欠陥からの散乱波が明瞭に生じていることが確認できる.

4. 転移学習

転移学習³⁾とは, ある領域内での仮説を効率的に導き出していくために, 別の領域で学習された知識を得て, それを適応させる学習のことである.

(1) 転移学習のメカニズム

転移学習における領域をドメインと呼び, 転移する知識を送る側を元ドメイン (source domain), 受け取る側を目標ドメイン (target domain) と呼ぶ. 一概に転移学習と言っても様々なケースが存在する. 本研究では, ある画像の集合の中で, 特定の画像であるかどうかを識別する問題において, 他の画像集合を活用する帰納転移学習問題を扱う. その中でも, 特徴ベース・分離型のアプローチに着目した. これは

Key Words: 非破壊検査, レーザー超音波可視化試験, 転移学習

〒 376-8515 群馬県桐生市天神町 1-5-1 TEL/FAX:0277-30-1610

元ドメインの特徴空間の中で、目標ドメインでも有用な部分空間を求め、その知識を目標ドメインの問題に適合するように変換する方法である。元ドメインの画像集合において同じカテゴリの画像は近く、異なるものは遠くなるような目的関数を定義し、ニューラルネットワークで最適化することで特徴空間の変換を求める。その後、目標データのラベルに加えて、変換した距離空間から推定した勾配を同時に学習させることで識別を行う。学習されたモデルは、元ドメインから抽出した特徴量ベースの目標ドメインに適応した性質をもつ。本研究では元ドメインは数値シミュレーション、目標ドメインはレーザー超音波可視化試験とした。

(2) 畳み込みニューラルネットワークによる特徴量抽出

数値シミュレーションによる膨大な人工画像から特徴量を抽出するために、画像認識に特化して開発された畳み込みニューラルネットワーク (CNN) を用いる。CNN は、入力層、畳み込み層、プーリング層、全結合層、出力層等から構成され、畳み込み層とプーリング層を複数組み合わせることによって深層化させ、データの特徴を抽出・選択する方法である。上記の層に加えて、活性化関数を用いて、全結合層の出力を正規化し、クラスごとの確率を示す。CNN における学習層、つまりパラメータの更新を行う層は、畳み込み層、全結合層の2種類を指す。ここでは、全5層の学習層を持つCNNに数値シミュレーション画像を入力し、学習済みモデルを生成した。その後、学習済みモデルの入力層に近い特徴抽出部分の重みを固定し、出力層に近い分類部分のみレーザー超音波可視化画像による再学習を採り入れた。これにより、少量の実験画像でも汎化性能を獲得した転移学習モデルの生成を試みる。

5. 転移学習による欠陥判定結果

以下、特徴抽出能力を有した学習済みモデルに、レーザー超音波可視化試験で得られた超音波伝搬画像を入力し、転移学習を行う。その後、学習をさせていない未知のデータを与え欠陥有り、無しの判定結果を示す。

(1) 転移学習結果

まず、欠陥有り、無しそれぞれ948枚、合計1896枚の数値シミュレーション画像を入力し、学習済みモデルを生成した。その後、転移学習させるレーザー超音波可視化画像は、アルミニウム試験体における欠陥有り、無しそれぞれ700枚の超音波伝搬画像を用いた。欠陥有りの画像では、超音波が欠陥に散乱されてからの画像を用いる。本研究では全データの8割を学習データ、2割を検証データとする。図3(a)に、訓練検証データの損失値と学習回数の関係、図3(b)に、訓練検証データの精度と学習回数の関係を示す。精度は全体の識別データ数に対して正しく識別されたデータ数の割合で表し、損失にはクロスエントロピー関数を用いている。図3(a)より、学習損失は減少し、検証損失も減少してい




図3 学習の損失値と精度 (a) 訓練検証データの損失値と学習回数の関係 (b) 訓練検証データの精度と学習回数の関係。




図4 未知のデータに対する時間ステップ毎の欠陥存在確率。

ることがわかる。また、図3(b)より、学習を重ねる毎に学精度は向上し、同様に検証精度も向上していることがわかる。よって、学習モデルは汎化性能を獲得できたと考えられる。

(2) 未知のデータの識別

転移学習モデルを用いた未知のデータの検証結果を示す。未知のデータとして可視化領域の異なる欠陥有りのアルミニウム試験体の超音波伝搬画像350ステップを用意し、欠陥有り、無しの判定を行った。結果を図4に示す。図4は未知のデータにおける各ステップ毎の欠陥存在確率を示す。1ステップ目で入射波を送信し、176ステップ付近で人間の目でも散乱波を確認できることに注意されたい。図4より、176ステップ程度までは、欠陥が存在しないと判定されるが、その後、欠陥存在確率が急激に上昇することが分かる。以降、若干の誤判定が見て取れるものの、各ステップでの欠陥存在確率の平均値は大幅に上昇しており、転移学習モデルが欠陥の存在を示唆していることがわかる。

6. 結言

本研究では、将来の完全自動非破壊評価システムの開発に資する基礎的研究を行った。数値シミュレーションによって得られた人工画像と実験画像の転移学習により、散乱波の特徴から欠陥有り、無しの判定が行えることを示した。今後は、数値解析データに多様性を持たせて、転移学習による欠陥判定技術の高精度化を目指すこと、アルミニウム試験体以外の材料への適用を試み、実用性を検討していきたい。

参考文献

- 1) 高坪純次, 王波, 劉小軍, 鈴木修一, 王曉東: レーザー超音波可視化技術の開発と欠陥検出への応用, 非破壊検査, vol.63(3), pp.142-147, 2014.
- 2) R. Minowa and T. Saitoh: Development of automatic defect detection method using deep-learning for elastic wave fields obtained by time-domain boundary element method, APCOM2019, pp.123, 2019.
- 3) 神島敏弘: 転移学習, 人工知能学会誌, vol.25, No.4, pp.572-580, 2010.