

レーザー超音波可視化検査における スタイル変換を用いたデータ拡張手法の検討

中島 未椰*

Miya Nakajima

塚越 勇真*

Yuma Tsukagoshi

斎藤 隆泰*

Takahiro Saitoh

加藤 毅†

Tsuyoshi Kato

1. はじめに

近年、構造物の老朽化などの社会的背景から、非破壊検査の需要が高まっている。特に超音波非破壊検査は、検査効率や安全性から、幅広く用いられてきた。本論文では、その中でも、レーザー超音波可視化試験(LUVT)に注目する。LUVTでは、超音波の伝搬を画像化し、欠陥の有無を判定できる。しかし、検査員が欠陥の有無を精査するため、機械学習の技術を導入し、検査の省力化を図る試みが検討され始めた[1]。

本研究の目標は、深層学習モデルを使ってLUVTで得られる画像を自動検査する技術の開発である。しかし、一般の画像認識と比べ、非破壊検査の訓練用画像の収集には、多くのコストがかかる。

そこで本論文では、LUVT画像検査における、シミュレータを活用した効果的なデータ拡張を提案する。シミュレータは、コストをかけずに、内部欠陥の画像を生成できる。しかし、シミュレーション画像と実画像との間に差異があり、直接、訓練データに追加すると悪影響が生じる。そこで、スタイル変換を施し、シミュレーション画像を実画像に近づけることを考案した。本論文では、その方法論を示し、効果を実証する実験結果を報告する。

2. LUVTとデータセット

2.1. LUVTとは

LUVTを用いた非破壊検査では、試験体にレーザーを照射し、レーザー照射点(送信点)において超音波を発生させる(図2(b))。そして、予め設置した超音波探触子から、超音波を送信しているような画像を得ることができる。この操作をアルミ試験体に対して適用し、得られた画像を図1に示す。欠陥がない画像に関して、入射超音波は、そのまま伝搬する。一方、欠陥が存在する画像では、欠陥から発生した散乱波が発生する。この散乱波から欠陥を発見できる。

2.2. 大規模データセット取得の難しさ

LUVT画像は測定ノイズにより、欠陥からの散乱波を視認できない場合がある。このような画像を高精度で判別するには、大量の訓練画像が必要になる。LUVT画像の正例を得るには次の工程を要する。

1. 試験体を用意する。
2. ドリルなどで試験体の内部に欠陥を作る(図2(a))。
3. 前節に述べた画像化の方法で、LUVT画像を得る。

以上を繰り返して正例を得る。負例を得るには、ステップ1とステップ3のみ実施する。ただし、想定する試

(a) 欠陥なし画像 (b) 欠陥あり画像





図1: LUVT実画像の例。

(a) 人工欠陥の生成



(b) レーザーの照射




図2: LUVT画像収集のための作業工程。

験体は高価な場合も多く、それに加え測定と画像化を繰り返すため、時間と労力を要する。これが障壁となり、LUVTデータセットの大規模化は妨げられている。

3. 提案手法

3.1. シミュレータによる画像生成

超音波伝搬画像をシミュレーションで求めるには、試験体に対する境界条件と初期条件の下、超音波が満足する弾性波動方程式を解く必要がある。弾性波動方程式を解く方法として、差分法や有限要素法が知られている[2]。これらは、比較的少ない計算時間で、数値解を求められる。本研究では、大量の人工画像を用意するため、短時間で荒い数値解を求めることができる時間領域差分法を用いてシミュレーション画像を得た。

3.2. スタイル変換

LUVT画像獲得の過程では、様々な要因でノイズが混入する。一方、シミュレータは超音波の散乱から画像構成に至るまでの過程に混入する多様なノイズまでは再現できない。シミュレーション画像と実画像との差異がドメインシフトを生むため、シミュレーション画像を直接利用しても汎化性能が向上するとは限らない。

そこで、本研究では、シミュレータで生成した画像を実画像に近づけるための手段として、スタイル変換を応用する。スタイル変換器は、形や物体の配置などの特徴を持ったコンテンツ画像と、色やテクスチャーの情報を有するスタイル画像を入力として、スタイルの変換方法を学習する。本論文では、LUVTの自動判別の訓練データ拡張に、教師なし学習に基づくスタイル変換器の導入した。後述の実験では、CycleGAN[3]

*群馬大学大学院理工学府

†群馬大学情報学部

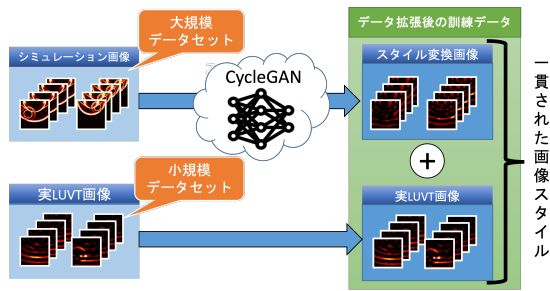


図 3: 提案法の概略.

を使って、LUVT 画像の判別における、データ拡張の効果を検証した。

3.3. スタイル変換によるデータ拡張

提案法の概略を図 3 に示す。まず、実画像群の獲得と同時に、シミュレータを使ってシミュレーション画像群を得る。次に、実画像の集合およびシミュレーション画像群を使って、CycleGAN を学習し、それぞれのシミュレーション画像をスタイル変換する。実画像とスタイル変換したシミュレーション画像を合わせて訓練用画像とし、欠陥検出のための深層学習モデルを学習する。比較実験では、提案手法の有効性を確かめるべく、LUVT データセットを用いて検証を行う。

4. 実験

4.1. 実験条件

スタイル変換によるデータ拡張の有用性を確かめるため、LUVT 画像のみの場合、シミュレーション LUVT 画像でデータ拡張した場合、スタイル変換画像でデータ拡張を行った場合（提案手法）についての比較を行った。以上の手法において、EfficientNet, ResNeXt, ViT のモデルでその性能を検証した。データセットは、波が欠陥に届くまでを欠陥なし、それ以降は欠陥ありとアノテーションした。また、実画像の欠陥なし画像を 22,634 枚、欠陥あり画像を 4,567 枚用いた。シミュレーション及び、スタイル変換後の画像はそれぞれ、欠陥なし画像を 17,111 枚、欠陥あり画像を 6,594 枚用いた。なお、スタイル変換画像は、CycleGAN の学習における、20,000 反復時に生成された画像を使用した（表 1）。性能評価では、計 203 種類の画像集合を訓練用データを 61 個、検証用データを 20 個、評価用データを 122 個に分割したデータセットを用いて、LUVT 画像の欠陥の有無を学習した。エポックごとに検証データにおける損失を記録した上で、そのうち損失を最小にする重みを学習結果とした。最後に、学習で得られた重みを用いて評価用データにおける F 値を算出した。

4.2. 実験結果

実験結果を、表 2 に示す。モデルが ViT の場合に着目すると、シミュレーションによるデータ拡張で欠陥検出性能が向上している。一方、EfficientNet と ResNeXt の場合では、シミュレーション画像でデータ拡張を行うことで、かえって欠陥検出性能を低下させている。これは、直接的にシミュレーション画像を用いて、データ拡張を行うことは一部のモデルに対して、有用でな

表 1: CycleGAN によるスタイル変換の結果.

| ラベル | シミュレーション | スタイル変換後 |
|------|----------|---------|
| 欠陥なし | | |
| 欠陥あり | | |

表 2: F 値での欠陥検出性能の比較.

| データ拡張手法 | EfficientNet | ResNeXt | ViT |
|----------|--------------|--------------|--------------|
| なし | 0.846 | 0.857 | 0.872 |
| シミュレーション | 0.848 | 0.848 | 0.882 |
| 提案手法 | 0.878 | 0.888 | 0.901 |

いことを示唆している。これに対し、全てのモデルにおいて、提案手法では欠陥検出性能が向上しており、有用な手法であると結論づけられる。

5. 結論

本論文では、LUVT におけるシミュレーション画像にスタイル変換を施し、データ拡張を行う手法を提案した。LUVT では、画像の収集に多くの費用と時間を要するため、大規模な訓練用データが利用できない。これにより、大量の訓練データに依る深層学習モデルの汎化性能は、データの不足が原因となり、減退させられる。そこで、多様かつ大規模なシミュレーション画像を訓練用データとして活用することを考えた。スタイル変換を導入し、シミュレーション画像のスタイルを、LUVT 画像のスタイルに近づけることで、データ拡張を行った。数値実験から、シミュレーション画像にスタイル変換を施し、データ拡張を行うことで、有意に欠陥分類性能を向上させることを確認した。

謝辞：本研究の一部は、公益財団法人セコム科学技術振興財団一般研究助成により実施された。また、JSPS 科研費 19K04661 の助成を受けた。

参考文献

- [1] 中島 未椰, 斎藤 隆泰, and 加藤 毅. レーザー超音波可視化試験における欠陥検出のための深層 CNN 構造の検討. AI・データサイエンス論文集, 3(J2):916–924, 2022.
- [2] 斎藤 隆泰. 境界要素法 (BEM) を用いた超音波シミュレーション. 非破壊検査, 60(4):210–215, 04 2011.
- [3] Jun-Yan Zhu, Taesung Park, Phillip Isola, and Alexei A Efros. Unpaired image-to-image translation using cycle-consistent adversarial networks. In *ICCV2017*.