

超音波非破壊検査における拡散モデルを用いた欠陥位置推定

安藤 佑咲* 中島 未椰* 斎藤 隆泰* 加藤 毅†
Yusaku Ando Miya Nakajima Takahiro Saitoh Tsuyoshi Kato

1. はじめに

近年、ダムや橋などの社会基盤を整備する人工材料の老朽化が深刻な社会問題となっており、維持管理の重要性が高まっている。検査の方法として、対象物を壊すことなく検査ができる非破壊検査の需要が高まっており、検査効率性や安全性の観点からレーザー超音波を用いたレーザー超音波可視化試験 (LUVT) が注目されている。LUVT は超音波の伝搬の様子を可視化することで、欠陥の有無を検査できる。検査員不足などの問題から LUVT で得られた画像を深層学習を用いて検査を自動化する試みが検討され始めた。

例えば、検査から得られる画像を用いて欠陥の有無を画像分類や物体検出、セグメンテーションタスクとして自動化されている。しかし、それらの方法は教師あり学習であり、LUVT においては正例データとなる欠陥あり画像が入手困難である。さらに、学習には画像とラベルが対になった教師データが必要であり、ラベル付けには時間と労力がかかるという問題もある。

一方で、深層学習手法には学習に正例データを用いない教師なし学習がある。教師なし学習は、医療分野などの異常検知で盛んに研究が行われている。超音波非破壊検査においては Jong Moon Ha らによる VAE を用いた欠陥検知 [1] が挙げられるが、欠陥位置推定まで行っている研究は発展途上である。

そこで、本論文では拡散モデルを用いた教師なし学習である AnoDDPM[2] を用いて、自動で検査を行う手法を提案する。時系列情報を用いて検査を行い、欠陥の有無の判定だけでなく欠陥位置推定までを行った。本論文では、その方法論を示し、いくつかの教師あり学習手法と比較して提案手法の有効性を検証した。

2. 提案手法

2.1. 拡散モデル

本節では、提案法で用いる拡散モデルを簡単に紹介する。拡散モデルは、Forward Process および Reverse Process からなる。Forward Process は、入力画像にノイズ画像を付加する過程である。Reverse Process は、ノイズ画像から入力画像を再構成する過程である。提案法は、正常画像のみで学習した拡散モデルで再構成すると欠陥部分が修復された画像が得られるという性質を利用している。

Forward Process は入力画像 $\mathbf{x}_0 \in \mathbb{R}^{h \times w}$ に正規ノイズを繰り返し加える過程である。ただし、 w および h は

それぞれ画像の幅と高さを表す。各ステップにおける画像を $\mathbf{x}_0, \dots, \mathbf{x}_T$ とすると、 \mathbf{x}_{t-1} から生成される \mathbf{x}_t の分布は次のように表される：

$$q(\mathbf{x}_t | \mathbf{x}_{t-1}) := \mathcal{N}(\mathbf{x}_t; \sqrt{1 - \beta_t} \mathbf{x}_{t-1}, \beta_t \mathbf{I}). \quad (1)$$

ただし、 β_t はノイズの大きさを表す定数である。すると、正規分布の性質から、

$$\mathbf{x}_t = \sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, \quad \epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I}) \quad (2)$$

が成立する。ただし、 $\bar{\alpha}_t := \prod_{s=1}^t (1 - \beta_s)$ とおいた。

Reverse Process では、次の分布を使って $\mathbf{x}_T, \mathbf{x}_{T-1}, \dots, \mathbf{x}_0$ の順に、ノイズ画像 \mathbf{x}_T から徐々に入力画像を復元しようとする：

$$p_{\theta}(\mathbf{x}_{t-1} | \mathbf{x}_t) = \mathcal{N}\left(\mathbf{x}_{t-1}; \boldsymbol{\mu}_{\theta}(\mathbf{x}_t, t), \frac{1 - \bar{\alpha}_{t-1}}{1 - \bar{\alpha}_t} \beta_t \mathbf{I}\right). \quad (3)$$

ベクトル値関数 $\boldsymbol{\mu}_{\theta}$ は、U-Net と呼ばれるニューラルネットワークで構成され、その重みパラメータ θ は分布 q と分布 p のカルバック距離が小さくなるように学習される。

\mathbf{x}_0 を入力画像としたとき、この Forward Process を経て、Reverse Process によって再構成すると、欠陥が修復された画像になる。

2.2. 欠陥位置推定法




図 1: 欠陥に当たる前後の超音波の様子

LUVT は検査対象に超音波を照射して得られる信号を使って、超音波が物体内を伝播する画像系列を構成する技術である。検査対象の内部に欠陥があるとき、超音波の伝播に異常が発生する (図 1)。欠陥の位置は伝播の異常から同定できる。

本研究では、LUVT 画像系列から欠陥位置を推定するために、次のようにアルゴリズムを構成した (図 2)。 K フレームの画像系列 $\mathbf{x}_0^{(1)}, \dots, \mathbf{x}_0^{(K)} \in \mathbb{R}^{h \times w}$ が所与とする。各画像 $\mathbf{x}_0^{(k)} \in \mathbb{R}^{h \times w}$ に拡散モデルを適用して復元した画像を $\hat{\mathbf{x}}_0^{(k)} \in \mathbb{R}^{h \times w}$ とする。差分画像

* 群馬大学大学院理工学府

† 群馬大学情報学部

$\mathbf{y}^{(k)} := |\mathbf{x}_0^{(k)} - \hat{\mathbf{x}}_0^{(k)}| \in \mathbb{R}^{h \times w}$ を求める. すると, K フレームの差分画像 $\mathbf{y}^{(1)}, \dots, \mathbf{y}^{(K)}$ を得たことになる. K フレームの画像から欠陥が強調されるように統合した1枚の2値画像 $\mathbf{z} \in \{0, 1\}^{h \times w}$ を得る. 2値画像 $\mathbf{z} \in \{0, 1\}^{h \times w}$ における輝度値1の画素は欠陥があることを表し, 0は欠陥がないことを表す. 2値画像 \mathbf{z} の連結成分に対して, 一定以上の面積のものを欠陥と予測する. 最大の連結成分の面積が一定値未満の時は, 欠陥なしと判定する. 後述の実験において, 最大面積の連結成分の重心を欠陥位置の推定値として, 性能評価を行った.

本研究では, 2値画像 \mathbf{z} は, 次のような2段階の二値化によって得ることとした: 第1段階で K 個の差分画像 $\mathbf{y}^{(1)}, \dots, \mathbf{y}^{(K)}$ をそれぞれ複数の閾値で二値化した画像を計算した. それらの平均画像 $\mathbf{z}_{\text{pre}} \in \mathbb{R}^{h \times w}$ を求め, さらにもう一度二値化を行うことによって \mathbf{z} を得た. 第1段階の二値化に用いる閾値には 0.15, 0.16, ..., 0.35 の 21 種類を用いた. すると, $21K$ 個の2値画像が得られることになる. 第2段階の二値化, すなわち, $21K$ 個の2値画像の平均画像 \mathbf{z}_{pre} を二値化する際の閾値は, \mathbf{z}_{pre} に含まれる $w \cdot h$ 個の輝度値の最大値の $1/3$ を用いた.

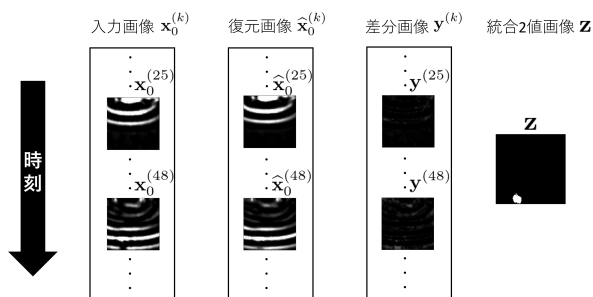


図2: 提案法の流れ

3. 実験

3.1. 実験条件

拡散モデルにおける検査の有効性を確かめるために, 教師あり学習の物体検出手法である RetinaNet, Yolov3 を用いて性能を比較した. また, LUVT における検査素材はアルミを用い, 学習の際は画像サイズを 128×128 にリサイズし, グレースケール変換を行った. データセットは実際の検査のように数個の欠陥ありのデータがある状況を考え, 表1のように構成した. なお, 教師なし学習と教師あり学習の学習に使用した画像枚数はそれぞれ実験を行った.

表1: データセットの構成. 訓練用データおよび評価用データセットに含まれる動画数. カッコ内は欠陥有りの動画を表す.

| | 動画数 |
|------------|---------|
| 訓練用: 物体検出 | 78(5) |
| 訓練用: 拡散モデル | 78(0) |
| 評価用 | 100(50) |

また, 教師あり学習においてはエポックごとに検証データにおける損失を記録し, その中で最良な重みを学習結果とした. 拡散モデルにおいては, エポック数は1000で行った. そして, 実験により得られた重みを用いて評価用データにおける Precision, Recall を算出した.

3.2. 実験結果

実験により得られた Precision, Recall を図3に示す. なお, 横軸の閾値は欠陥位置の ground truth と予測の誤差である.




図3: 実験結果

図3より, 物体検出の2つの手法と比較して AnoDDPM を用いた提案手法は Precision, Recall の値が上回っており, 欠陥検出性能が最も良い結果となった. また, Recall において, 物体検出の最も値の大きかった Retinanet は閾値 20 で 0.804 だったのに対し, 提案手法では閾値 10 で 0.820 を達成しており, 欠陥位置推定の観点でも性能が高い結果となった. 以上のことから, 提案手法は有効な手法であると言える.

4. 結論

本論文では, LUVT において教師なし学習を用いて欠陥位置推定を行う手法を提案した. LUVT では特に正例データである欠陥あり画像の収集が困難である. このことから, 正例と負例の両方が学習に必要な教師あり学習では検査性能が低くなってしまふ. そこで, 訓練用データに正例データを使わない教師なし学習で欠陥検出だけでなく, 位置推定も可能としたモデルを考案した. 数値実験の結果, 教師あり学習の手法と比べて提案手法は欠陥検出, 位置推定性能の両方で上回った.

謝辞: 本研究は, 公益財団法人セコム科学技術振興財団一般研究助成, ならびに科学研究費補助金基盤研究 (C)(21K0423100) の支援の下, 実施された. また, 学際大規模情報基盤共同利用・共同研究拠点である京都大学, 北海道大学により計算資源が提供された (Project ID: jh220033).

参考文献

- [1] J. Moon Ha et al. Autoencoder-based detection of near-surface defects in ultrasonic testing. In *Ultrasonics*, Vol.119, pp.106637, 2022.
- [2] J. Wyatt et al. AnoDDPM: Anomaly Detection with Denoising Diffusion Probabilistic Models using Simplex Noise. In *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, pp.649-655, 2022.