

機械学習を用いたレーザー超音波可視化試験 における非接触非破壊検査システムの開発

○群馬大学大学院理工学府 学生会員 伊藤司
群馬大学理工学部 学生会員 中村茉耶
群馬大学大学院理工学府 正会員 齋藤隆泰

1. はじめに

近年、自動車等の機械材料・構造や社会基盤構造物に対する品質保証や維持管理を目的に、非破壊検査の重要性が高まっている。しかし、そのような中、非破壊検査の分野では将来の検査技術者の人材不足の危機に直面している。一方、ビッグデータ等、IT技術の発展は目覚ましく、様々な業界で応用が進んでおり、中でも機械学習は、人間が行う作業を機械に任せる点で大きな注目を集めている。そこで、本研究では、レーザー超音波可視化試験において機械に評価を行わせる検査システムの開発を行う。以下では、まずレーザー超音波可視化試験について説明する。次に、得られた可視化試験結果へ施す画像解析手法や、機械学習手法の1つである畳み込みニューラルネットワークおよび構築システムの概要について説明する。最後に、構築した非破壊検査システムを用いた欠陥検出結果を示し、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

まず、レーザー超音波可視化試験について説明する。レーザー超音波可視化試験は、図1(a)のようなLUVE(Laser Ultrasonic Visualization Equipment)と呼ばれる計測装置を用いて実施した。レーザー超音波可視化試験では、パルスレーザーを、試験対象とする材料の表面に照射し、熱膨張を発生させることで、超音波を伝搬させる。そして、予め設置していた探触子で超音波を受信し、受信探触子から試験体へ超音波が伝搬する様子を逆に可視化する。レーザー超音波可視化試験の様子は図1(b)に示すとおりである。本研究で扱うレーザー超音波可視化試験では、波動伝搬挙動の可視化結果を連番画像として出力することができる。

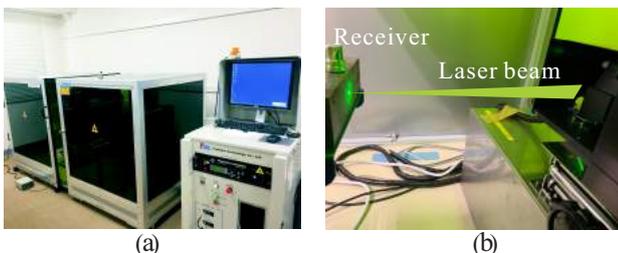


図1 レーザー超音波可視化試験 (a) 計測装置 LUVE(Laser Ultrasonic Visualization Equipment) (b) 実際のレーザー超音波可視化試験の様子。

3. 画像解析

可視化試験より得られた連番画像の番号が若いものから順に画像処理を施す。まず、背景から散乱波を分離するために2値化処理を行う。本研究では、画像の2値化における閾値処理は、閾値処理された白黒画素の級内分散を最小にするOtsu法¹⁾を用いることとする。しかし、得られた2値化画像は散乱波が黒色、背景が白色で表現されている。よって、散乱波を白色として画像処理を行うために白黒の画素値を反転させる。また、ノイズを除去するためにモルフォロジー収縮演算を施す。モルフォロジー収縮演算とは、ある対象画素とその近傍画素を比較し、近傍画素の中で最小の画素値を対象画素に割り当てる変換である。今回用いる構造化要素は5×5の正方形要素であり、要素の中心は正方形の中心とした。さらに、本研究では、モルフォロジー収縮演算で除去できない大きさのノイズを除去するためにエリアオープニングを行う。そして、上記の方法によって画像処理された連続する2枚の画像を合成し、画像間の位置ずれから画素毎に局所変位場を算出する。各連結要素での局所変位場の和を取り、その変位方向を波動の伝搬方向とする。

4. 畳み込みニューラルネットワーク

本研究では、機械学習として、画像認識に特化して開発されてきた畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)²⁾を用いる。CNNは、入力層(Input layer)、畳み込み層(Convolutional layer)、プーリング層(Pooling layer)、全結合層(Fully connected layer)、出力層(Output layer)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い層を形成し、データの特徴を抽出・選択する。そして、上記の層に加えて、バッチ正規化層やReLU(Rectified Liner Unit)層、ソフトマックス層でネットワーク構造を形成する。バッチ正規化層において学習を安定させ収束を早め、さらにReLU層を定義することによって学習をスムーズに進行させる。ネットワーク構造の最後に、ソフトマックス活性化関数を用いて、全結合層の出力を正規化する。

5. システムの構築

本手法では、まず、レーザー超音波可視化試験より得られた連番画像に対して画像解析を行い、各時刻の波動の伝搬方向ベクトルを求める。そして、波動の伝搬方向が反転

した画像に対して、学習済み CNN を用いて欠陥か否かを判定する。ただし、本研究では、垂直下向きに入射波を入射するため、伝搬方向ベクトルが上向きになった時を散乱波の発生とする。判定基準は、垂直上向きから左右各 15 度以内の方向に向いた時とする。

CNN の畳み込み層ではゼロパディングを追加することによって入力画像のサイズを保持したまま次の層に引き渡し、畳み込み層を経る毎にフィルター数を倍に増加させ、局所パターンの緻密化を図る。最大プーリング層では、すべての層でプーリング領域を 2×2 、入力画像上を走査するステップサイズであるストライドを垂直方向走査と水平方向走査ともに 2 画素に設定する。ネットワーク構造の学習には、勾配降下法の最適化アルゴリズムである Adam (Adaptive moment estimation)³⁾ を用いる。

6. 欠陥検出結果

5. 節で構築された手法を用いて鋼材中の欠陥検出を行う。図 2 のように、1MHz の縦波探触子を直径 2mm の欠陥 (貫通空洞) の真上に設置し、赤で囲まれた領域を可視化領域としてレーザー超音波可視化試験を行い、500 枚の連番画像を取得した。得られた試験結果に画像解析を施し、伝搬方向ベクトルが反転している画像に対して、CNN により欠陥か否かを判定する。学習データは、同じくレーザー超音波可視化試験より得られた様々な散乱波の画像を用いる。学習画像の欠陥か否かの判断は、著者らが視認できる範囲で行い、欠陥画像データ、健全画像データに振り分ける。得られた画像は、学習の都合上、全て 250×250 にリサイズし、また大量の学習データを作成するために健全画像データを 4550 枚、欠陥画像データを 1630 枚に水増しした。そして、データ数を揃えるために健全画像データからはランダムに 1630 枚を抽出した。全学習データ 3260 枚のうち 9 割を CNN の学習に、1 割を学習した CNN の性能評価、つまり検証に用いた。

また、本研究ではミニバッチ学習を行い、図 3(a) に、CNN の学習回数に対する学習精度と検証精度を、図 3(b) に、CNN の学習回数に対する学習損失と検証損失を示す。1 エポックの学習回数は 22 回とし、それを 5 エポック繰り返した。精度は全体の判定データ数に対する正しく判定されたデータ数で表し、損失にはエントロピー損失関数を用いている。図 3(a) より、学習を重ねる毎に学習精度は向上し、同様に検証精度も向上していることがわかる。また、図 3(b) より、学習損失は減少し、検証損失も減少していることがわかる。したがって、過適合は起こっておらず、本 CNN は汎化性能を獲得できているものと考えられる。

図 4 に欠陥検出結果を示す。伝搬方向ベクトルが反転した画像は 77 枚であり、図 4(a) は、CNN が 77 枚の画像の欠陥可能性を評価したものである。なお、可能性の評価は

事後確率を用いて百分率で表した。図 4(b) は事後確率 0.34 と評価された画像であり、図 4(c) は 0.94 と評価された画像である。図 4(b) より、散乱波が強く現れていると視認できる画像に対しても、事後確率は低く算出される場合があるとわかる。

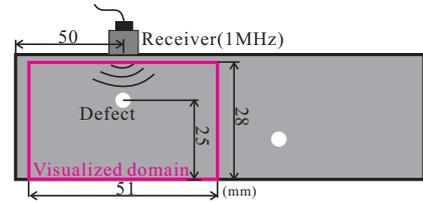


図 2 実験の可視化領域.

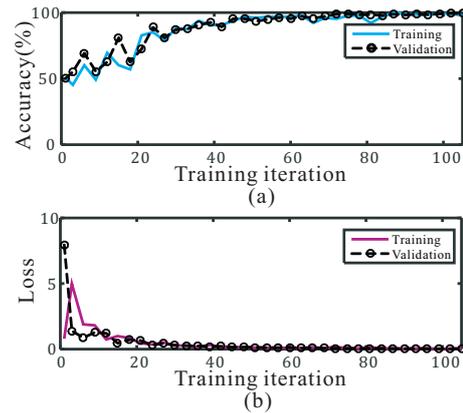


図 3 CNN の精度と損失 (a) 学習回数に対する精度 (b) 学習回数に対する損失.

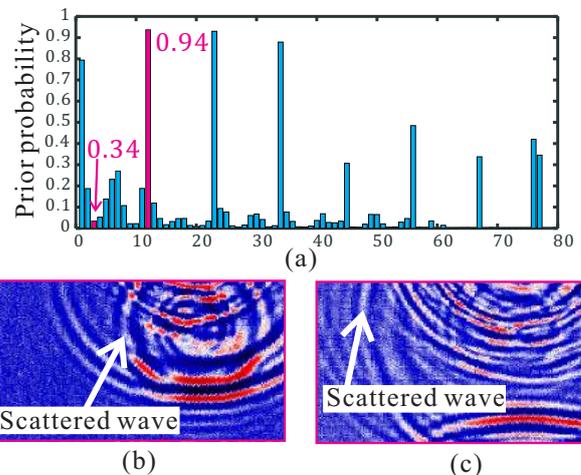


図 4 欠陥検出結果 (a) 欠陥の事後確率 (b) 事後確率 0.34 と判定された散乱波画像 (c) 事後確率 0.94 と判定された散乱波画像.

7. おわりに

レーザー超音波可視化試験より得られた結果に対して、画像解析と CNN によって欠陥の有無を判定する非接触非接触検査システムを開発した。今後は、得られた事後確率に対する定量的評価と欠陥の種類を判定する手法への拡張を行う。

参考文献

- 1) N. Otsu: A Threshold Selection Method from Gray-Level Histograms, IEEE Transactions on Systems, Man, and Cybernetics, Vol.9, No.1, pp.62-66, 1979.
- 2) 中山英樹: 深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習, 電子情報通信学会音声研究会, 2015.
- 3) D. P. Kingma, J. Ba: Adam: A method for stochastic optimization. arXiv:1412.6980, 2014.