Recurrent Neural Network を用いた CFRP 中の 欠陥の自動検出方法の検討

○群馬大学理工学部 学生会員 福島輝宙
群馬大学大学院理工学府 正会員 斎藤隆泰

1. はじめに

近年, 社会基盤構造物や材料に対する維持管理を目的に, 非破壊検査の重要性が高まっている. 特に, 超音波非破壊検査法は, 最も広く利用されている非破壊検査法の一つである. 一方, 先進材料である炭素繊維強化プラスチック (CFRP: Carbon Fiber Reinforced Plastics) を, 土木分野で応用する事例が増加している. しかしながら, CFRP は強い音響異方性を示す. そのため, 検査員がその音響異方性を理解していなければ, 欠陥の誤検出を招く可能性がある. このような理由から, 著者らはレーザ超音波可視化試験 (LUVT: Laser Ultrasonic Visualization Testing) を用いた非破壊検査の研究を行って来た¹⁾. LUVT を用いると, 試験体表面の超音波伝搬を検査員が直接視認することができ, 熟練の技術でなくとも検査が容易となるメリットがある. 本研究では, この検査員による視認を AI が実行できるか否かを検討する. ただし, ここではその第一段階として, まず数値解析で得られたノイズの少ない LUVT 結果に対して深層学習を施し, AI を作成する. 以下では, まず, LUVT について簡単に説明する. 次に, 準備した LUVT 画像や, そのために用いた数値解析手法について簡単に触れ, 欠陥検出結果を示す. 最後に, 本手法の有効性や今後の展望等について述べる.

2. 対象とする CFRP 試験体

本節では対象とした CFRP 試験体について簡単に説明する. 本研究で用いた試験体の概要を図 1 に示す. 高さ 2cm, 横幅 5cm, 奥行 5cm のトレカ T800 の CFRP 試験体を用意する. この試験体は x 方向に炭素繊維が配向された CFRP であり, 側面である B 面に LUVT 試験を実施した場合を想定する. その場合, LUVT ではセンサーから発信された超音波の B 面における伝搬を画像化 (映像化) することができる. LUVT におけるセンサーは中心周波数が 1MHz のものを想定した. なお, 欠陥は, 簡単のため貫通空洞と仮定し, 試験体内部に欠陥が無い場合と 1 つある場合を想定する. ここでは, まず次節で示す数値解析手法を用いてセンサーが図 1 中央前面に設置された場合の超音波伝搬解析を実施する. ただし CFRP の弾性定数等の物性は, 計測実験²⁾ により決定し, $C_{11} = 144.95$, $C_{33} = 14.19$, $C_{13} = 3.87$, $C_{55} = 6.09$ GPa であり, 密度 ρ は $\rho = 1600$ kg/m³ とした.

図 1 検討対象とする CFRP 試験体.

図 2 欠陥が無い場合の B 面における超音波伝搬シミュレーション結果の一例.

3. FDTD 法による CFRP 中の超音波シミュレーション

実際には 3 次元解析を実施することが望ましいが, 空洞は貫通空洞であり, 奥行方向の影響は小さいと考え, ここでは B 面を対象とした 2 次元 FDTD 法による超音波シミュレーションを実施する. FDTD 法を用いたメリットは, 解析が容易であり, 後に示す AI 作成のためのデータを大量に用意するのに便利なためである. なお, FDTD 法の定式化の詳細は多くの文献で参照できることから, 紙面の都合上割愛する. 図 2 に欠陥がない場合の B 面に対する超音波伝搬シミュレーション結果の一例を示す. ただし図 2 中の結果は全変位場の絶対値を示している. 通常, アルミニウム等の等方性材料では, 超音波は等方に伝搬する. しかしながら, 本研究で対象とした一方向 CFRP の場合, 擬似縦波 (qP 波) は, 繊維方向である x 方向に速く伝搬し, その波面は等方にならず, 音響異方性を示していることがわかる. 一方, 比較のため欠陥が有る場合の結果の一例を図 3 に示す. ただし, 図 3 中の各図は, 欠陥の位置がそれぞれ異なる場合の適当な時刻における全変位場を示していることに注意されたい. 図 3 より, 図 2 と異なり, それぞれ欠陥からの散乱波を目で見て確認することができる. よって, このような散乱波を AI が認識できれば欠陥有無を自動的に判定できることとなる. 以下では, 図 2,3 のような画像を学習データとした, AI の作成を検討する.

図3 欠陥が有る場合のB面における超音波伝搬シミュレーション結果の一例。

4. RNN

AI作成のために、本研究ではRNN(Recurrent Neural Network)の利用を考える。リカレントニューラルネットワーク(RNN)とは、過去の時系列情報を使って、任意の時刻における学習が可能なニューラルネットワーク手法(NN)である。通常のNNでは、ある層の出力は、次の層の入力に利用されるのみである。しかしRNNでの出力は、次の層の入力だけでなく、時系列でのデータとして入力するため、過去の情報を基に、予測を行うことが可能である。RNNの詳細については、例えば文献³⁾等を参照されたい。

5. RNNを用いた欠陥有無の判定結果

以下、RNNを用いた学習結果を示す。学習に用いた画像は、図2のような欠陥無しの画像を525枚、欠陥有の画像を2323枚の合計2848枚とした。ただし欠陥無しの画像は、入射超音波が発生してから底面からの反射波が発生するまでの画像で散乱波を含まないものを、欠陥有りの画像は散乱が発生してから底面からの反射波が発生する程度までの画像を、それぞれ学習対象とした。いずれもB面側面からの反射波は含めても良いとした。学習には、ホールドアウト法を用い、全学習画像の8割を訓練、残り2割を検証用画像に用いる。また、AI作成後のテストに用いる画像は、未学習画像を用いるため、別途用意する。計算にはGPUを使用し、そのグラフィックカードはGeforce GTX1060であり6GBのメモリを登録している。なお、RNNの学習におけるミニバッチサイズは64、学習回数は150回、weight decayは $\omega_d = 1.0 \times 10^{-2}$ とした。出力層におけるニューロン数は2とし、活性化関数にはシグモイド関数を用いた。画像サイズは128*128に変換して用いている。RNNにおける中間層には、LSTMブロック(ユニット数=64)を3つ配置し、それぞれのDropoutは0.5とした。RNNにおける時刻歴データは、各画像の水平列を対象とした。

図4に、この学習におけるEpochと損失の関係を示す。ただし、図中の青線は訓練、赤線は検証に対する場合の結果であることに注意されたい。図4より、学習回数が進むにつれて、訓練、検証いずれの場合においても損失は減少していることがわかる。一方、図5に、この学習におけるEpochと精度の関係を示す。図4より、学習回数が進むにつれて、訓練、

図4 Epochと損失の推移。

図5 Epochと精度の推移。

検証いずれの場合においても精度は増加傾向にあることがわかる。なお、紙面の都合上、詳細は割愛するが、ここで作成したAIを用いて未学習の一連の時刻歴画像に対して、画像中の欠陥の有無を判定させて。その場合、入射波を送信した直後は、欠陥の存在確率は小さいものの、散乱波の発生と共に欠陥存在確率は上昇し、9割以上の確率で欠陥の有無を判定できたことを付け加えておく。

6. まとめと今後の課題

本研究では、CFRP中の欠陥をLUVTで自動的に検出するために、RNNを用いたAIのプロトタイプを作成した。RNNにより、未学習画像中の欠陥の有無を概ね正しく判定することができた。今後は、FDTDで得られた画像でなく、ノイズ等を含んだ実際のLUVT画像に対してRNNを実行し、欠陥の有無を判定させる予定である。また、FDTDの画像と実験の画像両者を考慮した転移学習も実施する予定である。

参考文献

- 1) 斎藤隆泰・加藤毅・廣瀬壮一: 時間領域境界要素法で求めた散乱波動場の深層学習と欠陥種別の判定の試み、非破壊検査, pp.272-279, Vol.70(7), (2021)
- 2) K. Nakahata, Y. Amano, K. Ogi, K. Mizukami and T. Saitoh: Three-dimensional ultrasonic wave simulation in laminated CFRP using elastic parameters determined from wavefield data, Composites Part B, Vol.176, 107018, (2019)
- 3) チーム・カルボ:TensorFlow2 プログラミング実装ハンドブック, 株式会社秀和システム,(2020)