

有限要素解析および赤外線測定による応力分布に基づく 転移学習を用いたCFRP単純形状内の 欠陥3次元情報の予測

Prediction of 3D Information of Defects in a Simple Shaped CFRP Specimens
Using Transition Learning Based on Stress Distribution
from Finite Element Analysis and Infrared Measurements

児嶋佑太¹⁾ 平山健太²⁾ 遠藤克浩³⁾ 原田祥久⁴⁾ 村松真由⁵⁾

Yuta Kojima, Kenta Hirayama, Katsuhiko Endo, Yoshihisa Harada and Mayu Muramatsu

¹⁾慶應義塾大学大学院理工学研究科 (〒 223-8522 神奈川県横浜市港北区日吉 3-14-1, E-mail: kojimayuta@keio.jp)

²⁾慶應義塾大学大学院理工学研究科 (〒 223-8522 神奈川県横浜市港北区日吉 3-14-1, E-mail: kenta.hirayama@keio.jp)

³⁾国立研究開発法人産業技術総合研究所 (〒 305-8568 茨城県つくば市梅園 1-1-1, E-mail: katsuhiko.endo@aist.go.jp)

⁴⁾国立研究開発法人産業技術総合研究所 (〒 305-8564 茨城県つくば市並木 1-2-1, E-mail: harada.y@aist.go.jp)

⁵⁾博 (工) 慶應義塾大学理工学部機械工学科 准教授 (〒 223-8522 神奈川県横浜市港北区日吉 3-14-1, E-mail: muramatsu@mech.keio.ac.jp)

This study proposes a framework of Non-destructive Testing (NDT) for predicting the three-dimensional structure of internal defects in Carbon Fiber Reinforced Plastic (CFRP) structures from the distributions of sum of principal stress on surface (DSPSS) through transition learning. DSPSS are obtained from both the Finite Element Method (FEM) and infrared stress measurement. The infrared stress measurement uses Kelvin's theory to convert the surface temperature fluctuation under cyclic loading into DSPSS. The machine learning model used in this framework is a three-dimensional convolutional neural network (CNN). The transition learning method employed in this framework is as follows; First, a 3D-CNN that predicts the 3D-structure of defects is trained from the DSPSS by FEM with noise. Noise is added to the FEM DSPSS, for which a large amount of training data is available. This noise imitates thermal noise generated by infrared stress measurements and noise generated by differences in the physical properties of the resin and carbon fiber bundle. Next, the 3D-CNN is trained by transition learning using DSPSS obtained from infrared stress measurements. The amount of available data is limited. The accuracy is evaluated using DSPSS from the infrared stress measurements that are not used for training.

Key Words : Machine Learning, Non-destructive Testing, Finite Element Method, Carbon Fiber Reinforced Plastic, Convolutional Neural Network, Infrared Stress Measurement

1. 諸言

炭素繊維強化プラスチック (Carbon Fiber Reinforced Plastic, CFRP) は、樹脂を母材とし、炭素繊維を強化材とした複合材料である。高い比弾性率を持つため、宇宙・航空分野で多く使用されている。例えば、ボーイング 787 型機の機体構造の 50% 以上に CFRP が使用されている [1]。また、この材料は一方向に高い強度と剛性を持つ一方向強化材であるプリプレグを、積層して使用されるのが一般的である [2]。しかし、積層板の損傷は、剥離、繊維破断、母材割れなど著しく複雑であり、高効率かつ高精度な損傷解析が必要である。一般に損傷解析は、超音波測定 [3]、放射線透過法 [4] などの非破壊検査 (Non-destructive Testing, NDT) で行われている。これには多大な労力と時間、安全管理、経済的負担および計測技術者の経験が必要である。上記の既存の損傷解析手法の他に、赤外線サーモグラフィを用いた手法 [5] がある。赤外線サーモグラフィは、赤外線センサを用いて対象物の表面から放射される赤外線エネ

ルギーを測定する方法である。測定した赤外線エネルギーは、温度分布に変換される。既存の損傷解析手法と比較して、安全管理が不要、解析コスト・時間コストが低い、接触媒体が不要、試験技術者の技量が結果に影響しない、などの利点がある。近年では、赤外線分析で得られた温度変動から表面主応力を算出し、損傷解析に用いることが多い。構造物の赤外線応力解析が橋梁の欠陥検出に有用であることを確認した研究がある [6]。一方、欠陥位置推定に機械学習を用いた研究も行われている。Byon らは、CFRP 積層板を長手方向に 10 個のサンプルに分割し、固有振動数と損傷の位置・量を学習データとして数値解析と実験を行い、先端の 2 要素を除く 8 要素に損傷を与え、欠陥位置を予測するニューラルネットワークモデルを開発した [7]。この方法を用いて、1 次から 3 次の固有振動数を入力データとして、2 次元の位置と損傷量を決定する機械学習モデルを開発した。しかしながら、欠陥位置が 8ヶ所と限定的で解像度が低いという課題がある。Hasebe らは、実験におい

て損傷を有する CFRP 積層版の表面性状から衝突による損傷を、決定ベースのマルチタスク学習を用いて予測し、既存手法との精度比較を行った [8]。また、本研究グループは有限要素法 (Finite Element Method, FEM) のみのデータを用いて表面主応力和分布から欠陥情報の 3 次元構造を予測する概念実証を行なった [9]。しかしながら、使用したデータは FEM による表面主応力和分布のみであり、実験で得られる表面主応力和分布を用いた欠陥情報の 3 次元構造の予測は行われていない。本研究では、健全短冊形 CFRP 試験片と、異物としてプリプレグ層間にテフロン製シートを挿入した短冊形 CFRP 試験片に対し、3 次元畳み込みニューラルネットワーク (Convolutional Neural Network, CNN)、FEM および赤外線応力測定から得られる表面主応力和分布を用いて異物の 3 次元構造を予測する。精度評価には、モデルの訓練に使用していない赤外線応力測定により得られた表面主応力和分布を用いる。なお本研究の試験片は、CFRP 製構造物を作成する際に最も発生しやすい欠陥として知られているフィルムのはがし忘れによる異物混入を想定している。

2. 転移学習 [11]

近年、画像認識分野において、CNN は多くのタスクでの高い精度から高い注目が集まっている。ImageNet [12] のような大規模なデータセットを用いた CNN の学習により獲得される特徴は非常に汎用性が高く、同一のドメインのみならずその他のドメインにおいても応用する研究がなされている [13]。転移学習を行うことのメリットとして、質が高く大量のデータセットを用意することができるドメインで学習された特徴を、少量のデータセットしか用意できないドメインに応用することができるという点が挙げられる。

3. 提案する欠陥逆推定手法

提案する欠陥逆推定手法の流れ (図 1) と利点について説明する。本手法は、FEM から得られる表面主応力和分布により訓練された 3 次元 CNN を、赤外線応力測定から得られる表面主応力和分布により転移学習を行う。具体的な流れを以下に示す。まず初めに、FEM により表面主応力和分布を計算する。次に、赤外線応力測定で発生するノイズを模擬したノイズを加える。得られたノイズあり FEM 表面主応力和分布を用いて異物の空間情報を予測する 3 次元 CNN を訓練する。最後に、引張りによる疲労を加えた試験片の表面における温度変動から Kelvin の理論に基づき計算された表面主応力和分布を用いて、3 次元 CNN の転移学習を行う。これにより、表面主応力和分布から異物の空間情報を予測する 3 次元 CNN を構築する。

4. 方法

(1) 赤外線応力測定

a) 作成した試験片設計図

赤外線応力測定で使用した CFRP 製短冊形試験片の設計図例を図 2 に示す。試験片は 1 方向強化材料であるプリプレグ (厚さ 0.3 mm) を 10 層貼り合わせた構造をしている。積層する一方向強化複合材の繊維方向は

$0^\circ, 45^\circ, 90^\circ, -45^\circ, 0^\circ, 0^\circ, -45^\circ, 90^\circ, 45^\circ, 0^\circ$ とする。積層板の寸法は $200.0 \text{ mm} \times 25.0 \text{ mm} \times 3.0 \text{ mm}$ とし、異物は図中破線部分に挿入し、異物長さ a 、幅 b 、 x 方向挿入位置 c 、 y 方向挿入位置 d 、挿入層を変更することにより試験片を用意する。図中 A、B の領域は振動試験機の治具に挟み込むための GFRP 製タブを貼り付けた領域である。工場における異物混入では異物が含まれていない構造物の数が多いことを想定し、異物の含まれない試験片を 17 枚、異物の含まれる試験片を 12 枚用意する。

b) 赤外線応力測定の実験設定

実験に使用した振動試験器は 810 Material Test System、赤外線サーモグラフィは FLIR SC7500 である。振動試験器の設定条件は引張-引張の繰り返し荷重、引張上限値は 2.0 kN、引張下限値は 0.2 kN、荷重波形は sin 波であり、周波数は 5 Hz である。赤外線サーモグラフィの解像度は 320×256 である。また、ロックイン処理に使用したフレーム数は 4000 枚である。試験片表面には反射による測定の乱れを防ぐために、黒色塗装を施している。さらに振動試験機の治具に挟み込む部分は GFRP 製のタブを貼り付けている。貼り付けには接着剤を使用しており、タブのサイズは $50.0 \text{ mm} \times 25.0 \text{ mm}$ である。FEM で計算した応力和分布の解像度は 150×50 である。これらを合わせて、標準化した画像を機械学習に使用する表面主応力和分布とする。得られた表面主応力和分布を図 3 に示す。

(2) FEM 解析

本研究では、FEM に基づく数値解析により機械学習で使用する表面の表面主応力和分布を得る。FEM 解析では、実験で用意した積層板と同様の設計の積層板に対し解析を行った。CFRP 部分と異物部分の物性値を表 1 に示す。異物部分の物性値には赤外線応力測定で異物として挿入したテフロンの物性を参考にしている。解析条件を図 4 に示す。

(3) 機械学習で用いるデータセット

上記の条件で FEM 解析を行うことで、異物の空間情報と積層板表面の表面主応力和分布をペアにしたデータセットを得た。異物のデータ形状は $150 \times 50 \times 5$ 、表面主応力和分布の形状は 150×50 である。これにより、異物の位置とサイズを変更することにより、1 個の異物なし表面主応力和分布と 1033 個の異物あり表面主応力和分布を用意した。さらに、FEM 解析による応力分布に、赤外線応力測定により発生する熱ノイズや、樹脂と炭素繊維束の物性値の違いにより発生するノイズを擬似的に加えた。ノイズを異物あり表面主応力和分布は 5000 パターン、異物なし表面主応力和分布には 5 パターン加えることにより、異物なしのデータセットを 5000 組、異物ありのデータセットを 5165 組作成した。

また、赤外線応力測定による表面主応力和分布の訓練用データとテスト用データを図 5 に示す。データセットの振り分けでは、異物挿入層の偏りなくデータセットの割り当てを行った。

表-1. 各領域の物性値．Young 率 E ，せん断弾性係数 G の単位は MPa とした．

	E_1	E_2	E_3	Nu_{12}	Nu_{13}	Nu_{23}	G_{12}	G_{13}	G_{23}
CFRP	136600	9650	9650	0.29	0.29	0.40	5200	5200	3400
Defect	200000	200000	200000	0.39	0.39	0.39	-	-	-




図-4. FEM の解析条件．灰色部分は異物挿入部分． x 軸方向に 1.0 kN の引張を加え， yz 平面拘束を与えた．




図-5. 赤外線応力測定による表面主応力和分布の訓練用データとテスト用データ． 180° 回転のデータオーギュメンテーションを行なっている．

表-2. ノイズあり FEM 表面主応力和分布を用いた 3 次元 CNN の訓練条件．

損失関数	Binary Crossentropy
最適化手法	Adam (学習率 0.00007)
バッチサイズ	64
訓練回数	800
訓練データ	異物なし 3000 組+異物あり 3095 組
検証データ	異物なし 1000 組+異物あり 1035 組
テストデータ	異物なし 1000 組+異物あり 1035 組

訓練用データに異物なしのデータセット 10 組と異物ありのデータセット 12 組，テスト用データに異物なしのデータセット 6 組と異物ありのデータセット 6 組をそれぞれ割り当てた．1 画像で 1 ミニバッチを構成し，損失関数の評価と重みの更新を 1000 回繰り返すことで訓練を行った．

表-3. 転移学習における赤外線応力測定による表面主応力和分布を用いた 3 次元 CNN の訓練条件．

損失関数	Binary Crossentropy
最適化手法	Adam (学習率 0.00007)
バッチサイズ	1
訓練回数	1000
訓練用データ数	異物なし 10 組+異物あり 12 組
テスト用データ数	異物なし 6 組+異物あり 6 組

b) 転移学習による予測結果の評価方法

転移学習による赤外線応力測定による表面主応力和分布から異物の 3 次元情報を予測した結果について，異物平面位置予測の一致率 R と異物挿入層の予測 P の二つの定量評価指標を用いる．

異物の平面位置予測の一致率 R では，Ground Truth の異物領域内に存在する，予測結果が異物である割合を算出する．式 (1) に R の定義式を示す．赤外線応力測定による応力分布と異物挿入位置のずれを考慮して，2 mm 異物領域より範囲を広めている．

異物領域から 2 mm 範囲を広めた
$$R = \frac{\text{領域内の異物予測ピクセル数}}{\text{異物領域内のピクセル数}} \quad (1)$$

異物挿入層の予測 P では，3 次元 CNN の予測した異物挿入層を異物ありと予測したピクセル数から確率的に算出する．各層間における異物ありと予測したピクセル数の合計値を，全層における異物ありと予測したピクセル数で割ることにより，異物挿入層の各層に対する存在確率を導出する．

5. 結果と考察

本章ではまず，ノイズあり FEM 応力分布から異物の 3 次元情報を予測する 3 次元 CNN の予測結果を述べる．次に，赤外線応力測定による表面主応力和分布を用いて転移学習を施した 3 次元 CNN の予測結果をまとめる．

(1) ノイズあり FEM 応力分布 (テストデータ) から異物の 3 次元情報を予測した結果

本節では，ノイズあり FEM 応力分布から異物の 3 次元情報を予測したときの出力 (Predicted Data) と教師データ (Ground Truth) を可視化し，比較したところ，それぞれ欠陥の大きさごとに，異物が存在する平面位置と挿入されている層を正しく予測できていることがわかった．これらの結果から，赤外線応力測定で発生するノイズの擬似ノイズを加えた FEM 表面主応力和分布




図-6. 3次元 CNN のアーキテクチャ及びノイズあり FEM 表面主応力和分布を用いた訓練プロセス。




図-7. 転移学習における 3 次元 CNN のアーキテクチャ及び赤外線応力測定による表面主応力和分布を用いた訓練プロセス。




図-8. (a), (b) 異物が挿入されたテストデータの赤外線応力測定による表面主応力和分布 (上), Ground Truth(左下) と予測データ (右下) と (c) 異物が挿入されていないテストデータの赤外線応力測定による表面主応力和分布 (上), Ground Truth(左下) と予測データ (右下)。

表-4. 平面位置予測の一致率 R と異物挿入層の予測 P 。

		Test Data No.1		Test Data No.2		Test Data No.3		Test Data No.4		Test Data No.5		Test Data No.6	
		Prediction	Ground Truth	Prediction	Ground Truth	Prediction	Ground Truth	Prediction	Ground Truth	Prediction	Ground Truth	Prediction	Ground Truth
P	7-6 layer	0.56	1.00	0.83	1.00	0.61	1.00	0.31	1.00	0.82	1.00	0.59	1.00
	8-7 layer	0.21	0.00	0.02	0.00	0.56	1.00	0.21	0.00	0.01	0.00	0.32	1.00
	9-8 layer	0.00	0.00	0.04	1.00	0.00	0.00	0.00	0.00	0.79	1.00	0.08	0.00
	10-9 layer	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.02	0.00	0.00	0.00
R	7-6 layer	0.79	1.00	0.13	0.00	0.44	0.00	0.79	1.00	0.27	0.00	0.41	0.00
	8-7 layer	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	9-8 layer	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	10-9 layer	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00

に対して、異物の 3 次元情報を精度よく予測できていることがわかる。したがって、この 3 次元 CNN を用いて転移学習を行うこととする。

(2) 赤外線応力測定による表面主応力和分布を用いた転移学習

ノイズあり FEM 表面主応力和分布を用いて訓練した 3 次元 CNN に対し、赤外線応力測定による表面主応力和分布を用いて転移学習を行う。学習に使用していない

テストデータに対する出力 (Predicted Data) と教師データ (Ground Truth) を可視化し、比較する。図 8 に異物が挿入されたテストデータと、異物が挿入されていないテストデータにおける赤外線応力測定による表面主応力和分布と、3 次元 CNN の予測データ、Ground Truth の例を示す。

これらの結果から、赤外線応力測定から得た表面主応力和分布を用いた転移学習により、異物ありと異物なしの試験片を正確に判断することができていること

がわかる。さらに、異物あり試験片についてはおおよその挿入層の予測ができてることがわかる。赤外線応力測定による表面主応力和分布のノイズや、輪郭における応力値の揺らぎの影響で正確な概形は予測されず、複数の層間において異物ありと予測されていることもわかる。一方、異物の平面位置予測はおおよそ正しい位置を予測できていることもわかる。このため、異物あり試験片に対する予測結果について、平面位置予測の一致率 R と異物挿入層の予測 P の両方の指標を用いて予測結果を定量評価する。それぞれのテストデータに対する平面位置予測の一致率 R と異物挿入層の予測 P を表 4 に示す。異物平面位置の一致率 R は、異物サイズが小さい場合数値的に劣るが、Ground Truth より 2 mm 広いサイズ内に収まっていることを確認した。さらに、異物挿入層の位置を確率的に導出した際、全ての異物を挿入したテストデータにおいて正しい層における P が 0.5 より大きい結果となった。

6. 結論

本研究では、健全短冊形 CFRP 試験片と異物としてブリプレグ層間にテフロンシートを挿入した短冊形 CFRP 試験片に対し、FEM と赤外線応力測定から得られる表面主応力和分布を用いて異物の 3 次元情報を予測した。その結果、以下の項目を確認した。

- 3 次元 CNN を用いて、学習に使用していない赤外線応力測定による表面主応力和分布から異物あり・なしを正確に判別することができること。
- 3 次元 CNN を用いて、おおよその異物挿入層の予測と平面位置予測ができること。
- 異物平面位置一致率 R は、Ground Truth より 2 mm 広いサイズ内に収まっていること。
- 異物挿入層の位置を確率的に導出した際、全てのテストデータにおいて正しい層における異物挿入層の予測 P が 0.5 より大きい結果となること。

本研究の手法により、既存手法である X 線透過法や超音波測定法で発生する、超音波測定、放射線透過法などの既存の非破壊検査手法で必要とされている多大な労力と時間、安全管理、経済的負担、計測技術者の経験を必要としない内部欠陥推定が可能であり、既存手法の代替手法となる可能性がある。

参考文献

- [1] Ning, F. D., Cong, W. L., Pei, Z. J., & Treadwell, C. (2016). Rotary ultrasonic machining of CFRP: a comparison with grinding. *Ultrasonics*, **66**, 125-132.
- [2] Christensen, Richard M. Mechanics of Composite Materials. Courier Corporation, 2012.
- [3] Scarponi, C., & Briotti, G. (2000). Ultrasonic technique for the evaluation of delaminations on CFRP, GFRP, KFRP composite materials. *Composites Part B: Engineering*, **31**(3), 237-243.
- [4] Sultan, M. T. H., Worden, K., Pierce, S. G., Hickey, D., Staszewski, W. J., Dulieu-Barton, J. M., & Hodzic, A. (2011). On impact damage detection and quantification for CFRP laminates using structural response data only. *Mechanical Systems and Signal Processing*, **25**(8), 3135-3152.
- [5] Sakagami, T., & Kubo, S. (2002). Applications of pulse heating thermography and lock-in thermography to quantitative nondestructive evaluations. *Infrared Physics & Technology*, **43**(3-5), 211-218.
- [6] Sakagami, T., Izumi, Y., Shiozawa, D., Fujimoto, T., Mizokami, Y., & Hanai, T. (2016). Nondestructive evaluation of fatigue cracks in steel bridges based on thermoelastic stress measurement. *Procedia Structural Integrity*, **2**, 2132-2139.
- [7] Byon, O., & Nishi, Y. (1998). Damage identification of CFRP laminated cantilever beam by using neural network. In *Key Engineering Materials* (Vol. **141**, pp. 55-64). Trans Tech Publications Ltd.
- [8] Hasebe, S., Higuchi, R., Yokozeki, T., & Takeda, S. I. (2023). Multi-task learning application for predicting impact damage-related information using surface profiles of CFRP laminates. *Composites Science and Technology*, **231**, 109820.
- [9] Kojima, Y., Hirayama, K., Endo, K., Hiraide, K., & Muramatsu, M. (2022). Inverse estimation method for internal defects based on surface stress of carbon-fiber-reinforced plastics using machine learning. *Advanced Composite Materials*, 1-13.
- [10] Bengio, Y., Goodfellow, I., & Courville, A. (2017). *Deep learning* (Vol. **1**). Cambridge, MA, USA: MIT press.
- [11] 神畠敏弘. (2010). 転移学習. 人工知能, 25(4), 572-580.
- [12] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, **60**(6), 84-90.
- [13] Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., ... & He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, **10**(1), 43-76.