

## 機械学習による炭素繊維の異方性弾性係数の予測

日大生産工(院) ○松浦 玲斗 日大生産工 平山 紀夫 染宮 聖人

## 1. 緒言

炭素繊維強化プラスチック(以下, CFRP)は比強度・比剛性が高いことから, 航空機や自動車などの構造部材として幅広く採用されている. このようなCFRPを用いた製品の設計開発では, CFRPの異方性弾性係数を事前に予測する必要がある.

一般的に, CFRPの異方性弾性係数を算出する手法として, 複合側や均質化法に基づく数値材料試験が挙げられる. しかし, どちらの手法も炭素繊維の異方性弾性係数が必要であるが, 炭素繊維の直径は約7 $\mu\text{m}$ と非常に細いため, 異方性弾性係数を材料試験で測定することは困難である.

そこで本研究では, 数値材料試験で得られたCFRPの異方性弾性係数と炭素繊維の異方性弾性係数の関係性をニューラルネットワーク(以下, NN)に学習させ, 炭素繊維の異方性弾性係数を予測することを目的とする. 本報告では, NNに学習させるデータ(以下, 訓練データ), 訓練データとは別の未知のデータ(以下, テストデータ), 数値材料試験から得られた正解のデータ(以下, 教師データ)の3種類のデータを用いて炭素繊維の異方性弾性係数の予測精度を調査した.

## 2. NNの概要と学習環境

## 2.1 NNの概要

NNは人間の脳神経(ニューロン)の情報処理を模範した数理モデルであり, 重みとバイアスの2つのパラメータを更新することでNNは学習する. その汎用性の高さから, 現在では様々な分野で応用されている.

本研究では, 順伝播型NNを採用した. 入力層にはCFRPの独立した各方向の弾性係数, せん断弾性係数, ポアソン比, 繊維体積含有率の計6ユニットを用意した. また, 出力層には炭素繊維の異方性弾性係数の計5ユニット, 中間層には, 2層(それぞれ75ユニット)を用意した.

## 2.2 学習アルゴリズムの構成要素

本研究で使用するNNの計算手法には誤差逆伝播法を採用した. また, 損失関数には二乗和誤差関数を用い, 以下の式で計算される.

$$L = \frac{1}{2} \sum_k (y_k - t_k)^2 \quad (1)$$

ここで,  $y_k$  はNNの出力,  $t_k$  は教師データ,  $k$  は出力層のユニットを表している. また, 最適化アルゴリズムにはAdam最適化法を採用した. Adamは勾配降下法を基盤に, 勾配の平均と分散

を利用して学習率を適宜調整できるため計算効率が高く, 非線形な学習にも適している手法であり, 深層学習で最も多く使用されるアルゴリズムとなっている. なお, 以下の式で各パラメータを更新する.

$$\begin{cases} m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \end{cases} \quad (2)$$

$$w_t = w_{t-1} - \alpha_t \frac{m_t}{\sqrt{v_t} + \epsilon} \quad (3)$$

ここで,  $m$  は1次モーメント,  $v$  は2次モーメント,  $g$  はパラメータの勾配,  $t$  はEpoch数を表している.

## 2.2 NNの学習手順

NNによる情報処理手順を以下に示す. はじめに, モデルの設定として, 入力層, 中間層, および出力層のユニット数や, 学習率 $\eta$ , 学習回数(Epoch)などのハイパーパラメータを設定する. ここで, Epochとは全学習データすべてを1度モデルに入力し, 学習を1周完了することを表している. 本研究では, 学習データをtrain\_size, ミニバッチサイズをbatch\_sizeとしたとき, 1Epoch当たりの学習回数 $F$ は以下のように求めた.

$$F = \frac{\text{train\_size}}{\text{batch\_size}} \quad (4)$$

ここで, 本研究で使用する訓練データ数は70000個, バッチサイズが1024個であるため, 1Epoch当たりの学習回数は次式のように求まる.

$$\frac{70000}{1024} \approx 68 \quad (5)$$

以上より, 本研究での1Epoch当たりの学習回数は68回となる. 今回のNNの学習では10000Epochとして学習を行った.

## 2.3 データセット

今回の学習では訓練データとテストデータの2種類を用意した. 訓練データは, パラメータ(重みやバイアス)を更新し, NNを学習させるために使用した. 一方で, テストデータはモデルの汎化性能を評価するためのみに用いられ, NN学習には用いていない. また, 訓練データおよびテストデータは, 均質化理論に基づく数値材料試験で計算した. この数値材料試験で得られた炭素繊維の異

方性弾性係数を訓練データおよびテストデータとし、本モデルの妥当性を確認した。

### 3. 解析結果と考察

本モデルから得られた予測結果とテストデータの関係図とその誤差率をFig.1からFig.5に示す。Fig.1からFig.5に示すように、NNの学習した結果、各方向の縦弾性係数およびLT面のポアソン比の予測精度が高いことが確認された。一方で、TZ面のポアソン比およびせん断弾性係数は誤差率が8%を超えており、予測精度が低いことが確認された。

これらの結果から、TZ面のポアソン比、せん断弾性係数の学習データの改良が必要であることが明らかになった。

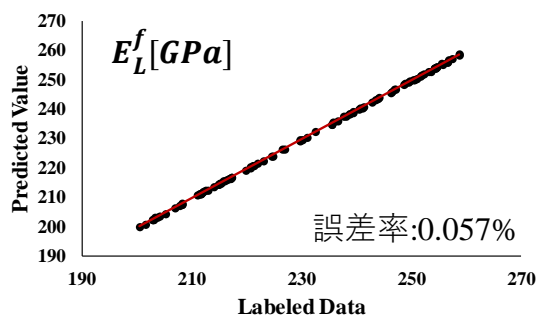


Fig.1 Accuracy of predicting the L-direction elastic modulus

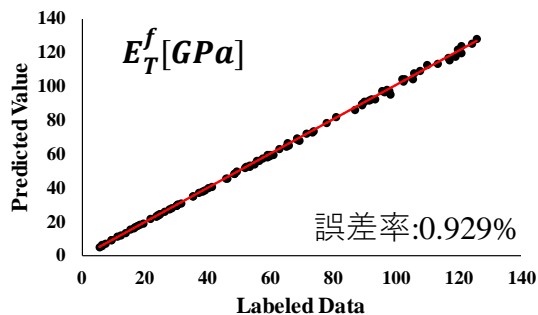


Fig.2 Accuracy of predicting the T-direction elastic modulus

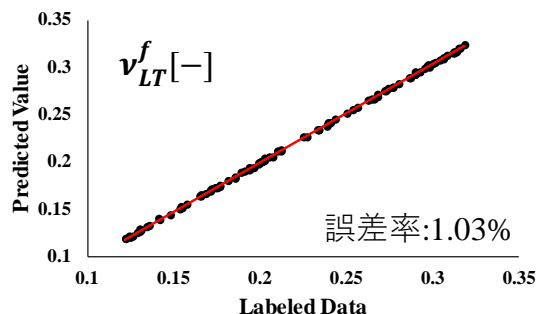


Fig.3 Accuracy of predicting the LT-direction Poisson's ratio

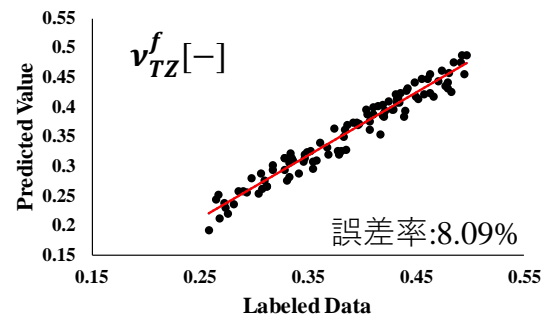


Fig.4 Accuracy of predicting the TZ-direction Poisson's ratio

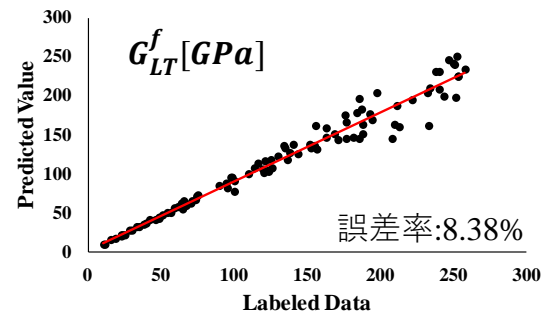


Fig.5 Accuracy of predicting the LT-direction shear modulus

### 4. 結言

本研究では、機械学習であるNNを用いて独立した炭素繊維の異方性弾性係数の予測精度を評価した。その結果、LおよびT方向の縦弾性係数、ならびにLT面ポアソン比は高い予測精度が得られた。一方で、TZ面のポアソン比およびせん断弾性係数に関しては予測精度が比較的低いことが明らかになった。

今後は、入力する学習データの構成や分布を見直すことで、モデルの汎化性能の向上を図り、予測精度の更なる向上を目指す。また、実際にCFRPを作製し、材料試験によって得られた弾性係数を本モデルに入力することで、炭素繊維の異方性弾性係数を予測できるか調査する。

### 参考文献

- 1) 邊吾一, ニューラルネットワークと複合材料・構造設計, 日本複合材料学会誌, 27巻, 1号, (2001), Vol.27, No.1, p17-22
- 2) 斎藤康毅 編 「ゼロから作るDeep Learning」-Pythonで学ぶディープラーニングの理論と実装- 株式会社オライリー・ジャパン, (2018) pp.39-164
- 3) 福田博, 邊吾一 編 「複合材料の力学序説」 古今書院, (2015) pp.81-82
- 4) 牛島省 編 「数値計算のためのFortran90/95プログラミング入門」 森北出版株式会社, (2022) pp.1-131