

深層学習を用いた応力場予測に関するデータ拡張手法

Data augmentation method for stress field prediction using deep learning

豊吉巧也¹⁾

Takuya Toyoshi

1) 博(工) 愛知工科大学 工学部 機械システム工学科 准教授

(〒443-0047 愛知県蒲郡市西迫町馬乗50-2, E-mail: takuya.toyoshi@g.aut.ac.jp)

Data augmentation is generally used to improve prediction accuracy, and four arithmetic operations or random noise addition are performed on the original learning data. This paper proposes an effective data augmentation method for deep learning to predict analysis results, such as the finite element method. This method focuses on the appearance probability of learning data and aims to improve prediction accuracy efficiency. As a result of examining the prediction of the stress distribution of the 2-dimensional finite element analysis result, the effectiveness of the method was shown.

Key Words : Deep learning, Data augmentation, Finite Element Method, Stress Field Prediction

1. はじめに

畳み込みニューラルネットワーク (Convolutional neural network, CNN) や[1,2]グラフニューラルネットワーク (Graph neural networks, GNNs) [3]などを用いた、有限要素法などによる数値解析結果を、深層学習技術を用いて予測する研究が、近年数多く報告されている。これらは、ある一定数の学習データを学習し、深層学習モデル (以下、学習モデル) を生成する。この学習モデルの予測精度を向上させるためには、学習データの拡張 (以下、データ拡張) は有効な手段の一つである。CNNにおいて、入力として画像を使う場合では、画像の反転、拡大縮小、回転、ノイズ付与などがデータ拡張手法として用いられる。一方で、数値解析結果の予測においては、入力および出力が数値となるため、ノイズ付与によるデータ拡張が考えられる。このような場合、平均値が元の値となるようにノイズを付与する必要があることに加え、許容される範囲についても慎重な検討が必要である。

本稿では、学習データの出現確率に着目したデータ拡張手法を提案する。2次元の有限要素解析結果の応力場の予測を対象に、提案手法の有効性について検討した。

2. 解析および予測対象

応力場の予測に用いる学習データとなる、有限要素法による解析条件を図1に示す。解析対象は幅50 mmの平板に12.5 mmの円孔を有する厚さ2 mmの平板とし、対称の境界条件より1/4モデルでの解析を行なった。四角形二次要素を用いて解析を行い、解析によって得られた節点応力 (σ_{yy}) を学習する。解析に用いた要素数および節点数はそれぞれ、900, 2821である。学習データ量の削減のため、学習には中間節点以外の節点の値を用いるため、1つ

の解析で学習に用いる節点数は961となる。荷重 P は1 kNごとに、1 kN~10 kNの10ケースの解析を行い、すべての値がゼロとなる0 kNの全11ケースのデータを用意した。





図-1 学習データとして用いる解析対象および条件

3. 深層学習モデルとデータ拡張

前述の有限要素解析結果から、5 kNの結果を除く10ケースのデータを用いて学習モデルを生成し、5 kNの結果を予測対象とした。学習モデルの生成および応力場予測の概要を、図2に示す。学習モデルの入力は節点の x, y 座標と荷重 P とし、出力を節点応力 σ_{yy} とした。また、学習モデルは表1に示す構成とし、Pytorchにより実装した。最適化関数にはAdam, 損失関数には平均二乗誤差 (MSELoss), 活性化関数にはSiLUを用いた。

学習モデルの生成には、すべての学習データ (全サンプル) から、ランダムに抽出したデータを用いて学習を行う、ミニバッチ学習を用いた。ここで、ランダムに抽出するデータ数をミニバッチサイズ b と、ミニバッチサイズは128とした。また、全サンプルの1回の学習を終えることを1エポックとよび、エポック数の上限は200とした。

Network learning



Stress field prediction




図-2 深層学習モデルの生成と応力場予測の概要

表-1 深層学習モデルの構成

Layer	Layer (type)	Input size	Output size
1	Input	3	3×128
2	Fully connected	128×128	128×128
3	Activation (SiLU)	128×128	128×128
4	Fully connected	128×128	128×128
5	Activation (SiLU)	128×128	128×128
6	Fully connected	128×128	128×128
7	Activation (SiLU)	128×128	128×128
8	Fully connected	128×128	128×128
9	Activation (SiLU)	128×128	128×128
10	Fully connected	128×128	128×128
11	Output	128×128	1

予測対象となる出力の節点応力 σ_{yy} は、学習時に0.0~1.0の範囲で正規化を行う。正規化された節点応力について、階級数を10（階級の幅を0.1）としたときの確率分布を図3に示す。学習データ全体において応力の値が低い節点の出現確率が高く、高い節点の出現確率が低い分布となり、出点確率に極端な偏りがあることが図3より確認できる。このような場合、ノイズを付与するデータ拡張では、予測精度の向上が困難であることが予想できる。




図-3 データ拡張前の確率分布

ここでデータ拡張として、各階級のデータの出現確率 P_r が、どの階級においても近い値となるような P'_r となるように、式 (1)を使いデータを拡張する。拡張するデータ数は、1回の拡張において、拡張するデータと同数とする。そのため、拡張数を n とすると、拡張後のデータ数は、最初のデータ数 $\times 2^n$ となる。この手法に基づいて、データを4回拡張（以降、拡張数4とよぶ、データ数は元のデータ数の 2^4 倍）したときの各拡張時の各区間の出現確率の変化を図4に示す。図4より、各階級のデータの出現確率が0.1に近づいていることが確認できる。

$$P'_r = \frac{1/P_r}{n_{bins} - 1} \quad (1)$$




図-4 データ拡張ごとの確率分布

4. 結果

(1) 拡張されたデータを用いた学習について

拡張前の学習データを拡張数0とし、拡張数1~4の学習データを用いて学習モデルをそれぞれ生成した。各拡張数での学習における損失値の推移を、図5に示す。




図-5 各拡張数での損失値の推移

すべての学習において、損失値が減少後に増大するような過学習の傾向は確認されなかった。拡張数0や1dでは、損失値がスパイク状に高い値を示すことが確認できるが、拡張数が大きくなるに従い、それらが低減していること

が確認できる。

次に、拡張数0～4の学習モデルによる予測精度を図6に示す。どの拡張数においても、エポック数が増えるに従い、予測精度が向上していることが確認できる。拡張数1では、学習開始時の正解率は拡張数0に比べて低い値を示すが、エポック数が3を超えると精度は逆転することが確認できる。拡張数4では、学習開始時から90%を超える予測精度で学習が進んでいることが確認できる。これらの結果から、深層学習における予測精度は学習データの出現確率に影響を受けることが確認され、本提案手法によるデータ拡張が学習に対して有効であることが確認された。




図-6 学習時の正解率の推移

(2) 応力場の予測結果について

拡張数0～4の学習モデルにより、荷重 $P=5\text{kN}$ の応力場を予測したときの予測誤差の最大値と最小値を図7に示す。予測誤差の最小値は $10^{-2} \sim 10^{-4}$ オーダーであり、データ拡張による大きな変化は確認されなかった。一方、予測誤差の最大値は、データの拡張数に応じて低減することが確認された。5kNの予測結果に対して、拡張数3以降では最大予測誤差が1MPaを下回ることが確認され、全体的にも拡張数が大きくなるにつれ最大予測誤差が低下していることが確認できる。




図-7 各拡張数での予測誤差

拡張数4の学習モデルによる応力場の予測結果を図8に示す。応力場の予測誤差の最大値および最小値はそれぞれ0.554 MPa, 4.270×10^{-4} MPaであった。




図-8 応力場の予測結果 (拡張数4)

5. さいごに

本稿では、応力場のような数値解析結果を、深層学習を用いて予測する際の、予測精度向上に向けたデータ拡張手法を提案し、その有効性について検討した。提案手法により学習時の損失値が効率よく低下することが確認された。また、少ないエポック数でも高い予測精度を示すことが確認された。

学習データに含まれない応力場の予測は、提案したデータ拡張により、1 MPa以下の予測誤差で応力場を予測することが可能であることが確認された。これらの結果から、本提案手法のようなデータの出現確率を一定に近づけるデータ拡張手法は、数値解析解を深層学習によって予測する場合に有効であることがいえる。

本稿でのデータ拡張手法は、異なる事象への応用も視野に含め、シンプルとなるよう提案しているため、幅広く利用されることが期待できる。

参考文献

- [1] 豊吉巧也, 小澤暦世, 泰地隆平, 和田義孝: 畳み込みニューラルネットワークを用いた疲労き裂進展の予測 (第1報 単一のなめき裂に対する予測), 日本機械学会論文集, Vol.88, No.915, 12pages, 2022.
- [2] Nie, Z., Jiang, H. and Kara, L. B.: Stress field prediction in cantilevered structures using convolutional neural networks, J. Comput. Inf. Sci. Eng., Vol.20, No.1, 8pages, 2022.
- [3] Maurizi, M., Gao, C. and Berto, F.: Predicting stress, strain and deformation fields in materials and structures with graph neural networks, Scientific Reports, Vol.12, No.21834, 12pages, 2022.