

論文 / 著書情報
Article / Book Information

論題(和文)	ディープラーニングを用いたマルチスケール定常熱伝導解析
Title(English)	Multiscale Analysis Using Deep Learning for Steady State Heat Conduction
著者(和文)	西田 猛哲, 鈴木 良郎, 轟 章, 水谷 義弘
Authors(English)	Takanori NISHIDA, Yoshiro SUZUKI, Akira TODOROKI, Yoshihiro MIZUTANI
出典(和文)	計算力学講演会講演論文集, , ,
Citation(English)	The Computational Mechanics Conference, , ,
発行日 / Pub. date	2018, 11

ディープラーニングを用いたマルチスケール定常熱伝導解析

Multiscale Analysis Using Deep Learning for Steady State Heat Conduction

○学 西田 猛哲^{*1}, 鈴木 良郎^{*1}, 轟 章^{*1}, 水谷 義弘^{*1}

Takanori NISHIDA^{*1}, Yoshiro SUZUKI^{*1}, Akira TODOROKI^{*1} and Yoshihiro MIZUTANI^{*1}

^{*1} 東京工業大学 Tokyo Institute of Technology

In recent years, deep learning using convolution neural network (CNN) has made great achievements in the field of image recognition. However, there are few applications of deep learning using convolution neural network in the field of numerical simulation. In this study, we propose a new multiscale analysis method, termed the “CNN-based DDM” which combines CNN with a multiscale technique, the domain decomposition method (DDM). In the DDM, we first divide an entire (global) domain into multiple local domains. We then analyze each local domain by a conventional numerical scheme, e.g., a standard finite difference method (FDM) solver, and obtain relation between dependent-variable values at outer grid points of the local domain. The global domain can be analyzed efficiently and rapidly using the relations of all the local domains. In the proposed “CNN-based DDM”, the CNN constructs the relation between variable values at outer grid points of each local domain based on the shape, size, and material property distribution of the local domain. We analyzed the linear steady state heat conduction fields with 2-dimensional non-periodic and heterogeneous thermal conductivity distribution using the proposed method, DDM and FDM, respectively. The proposed method calculated the temperature distribution almost equivalent to that calculated by FDM. We tested two types of CNNs. The smaller CNN conducted the local analysis more quickly than the standard FDM. From the above, it is suggested that the proposed method is useful for reducing the computational cost of the DDM.

Key Words : Deep learning, Convolutional neural network, Numerical simulation, Multiscale analysis, Heat conduction

1. 緒 言

ディープラーニング (Deep Learning, DL) とは, 多層ニューラルネットワーク (Deep Neural Network, DNN) を利用した機械学習の一手法である. 特に DNN の一種である畳み込みニューラルネットワーク (Convolutional Neural Network, CNN) は, 画像認識において大きな成果を上げている. 2012 年, Google¹⁾ は画像内の猫や人間を認識する CNN を開発し, 更に猫や人間と判定される確率を最大化する画像を抽出することに成功した. この成果により, CNN が猫や人間の視覚的な特徴を抽出できることが示唆された.

このように CNN を用いた DL は画像認識の分野において大きな成功を収めているが, 物理現象のシミュレーション (数値解析) 分野での活用例は少ない. そこで本研究では, CNN と領域分割法²⁾ (Domain Decomposition Method, DDM) を融合した新しいマルチスケール解析手法 CNN-based DDM を提案する. また, 提案手法を用いて非一様かつ非周期的な物性分布を持った 2 次元領域に対して定常熱伝導解析を実行し, 解析精度および解析時間を検証する.

2. CNN-based DDM の概要

図 1(a) のような非一様かつ非周期的な熱伝導率分布を持った 2 次元領域に対する定常熱伝導問題を例に, CNN-based DDM の概要について述べる. なお, 温度を変位や電位に, 熱流量を応力や電流密度に置き換えることで, 本手法を弾性解析や静電場解析に適用することができる. CNN-based DDM の計算過程は, 「ローカル解析」と「グローバル解析」の 2 種類に大別される.




Fig. 1 Non-periodic and heterogeneous global domain in (a) and the procedure of local analysis of the CNN-based DDM in (b).

2・1 ローカル解析

ローカル解析では、図 1(b)のようにグローバル領域を複数の小領域（ローカル領域）に分割し、ローカル領域の各格子の中心に格子点を配置する。ローカル領域の境界上に存在する格子点を境界格子点 (Boundary grid point)、それ以外の格子点を内部格子点 (Internal grid point)、内部格子点のうち最外周部に位置する格子点を内部境界格子点 (Internal boundary grid point) と呼び、これらの格子点における温度を格納したベクトルをそれぞれ $\mathbf{u}^0$ 、 $\mathbf{u}^I$ 、 $\mathbf{u}^{IB}$ と定義する。通常の DDM では、ローカル領域に有限差分法 (Finite Difference Method, FDM) などの解析を実行することで、 $\mathbf{u}^I$ と $\mathbf{u}^0$ の関係を表す行列 A^L が得られる。

$$\mathbf{u}^I = A^L \mathbf{u}^0 \quad (1)$$

一方提案手法では、FDM などの既存の数値解析手法ではなく、CNN を用いてローカル解析を行う。具体的には、図 1(b)のように、ローカル領域の熱伝導率分布を入力すると、式(1)中の行列 A^L を出力するような CNN を用いる。CNN の構築方法については 3.2 節にて述べる。

また、グローバル解析を実行する際には、ローカル領域内の全内部格子点の温度ではなく、内部境界格子点の温度のみを考慮する。内部境界格子点と境界格子点の温度の関係式は、式(2)より次のように得られる。

$$\mathbf{u}^{IB} = \mathbf{a}^L \mathbf{u}^0 \quad (2)$$

以上の計算を全ローカル領域に対して実行し、式(1)の行列 A^L および式(2)の行列 $\mathbf{a}^L$ を取得する。

2・2 グローバル解析

グローバル解析では、まず全ローカル領域の境界格子点および内部境界格子点の温度を求める。ローカル解析により得られた各ローカル領域における式(5)をまとめて次のような連立方程式を作成する。

$$\mathbf{u}^G = A^G \mathbf{u}^G \quad (3)$$

ここで、 $\mathbf{u}^G$ は全ローカル領域の境界格子点および内部境界格子点の温度をまとめたベクトルである。式(3)に境界条件を課して解くことで、全ローカル領域の境界格子点および内部境界格子点の温度を求めることができる。

次に、全内部格子点の温度を求める。ローカル解析により、各ローカル領域の境界格子点から内部格子点の温度を求めるための行列 $\mathbf{A}^L$ が得られているので、式(4)により内部格子点の温度を求めることができる。これにより、グローバル領域全体の温度分布が得られる。

3. CNN-based DDM による解析例

3.1 解析モデル

解析モデルを以下に述べる。

- ・ グローバル領域は、図 2 に示す 2 次元の正方形であり、1 辺の長さは 1 である。
- ・ グローバル領域は非一様かつ非周期的な熱伝導率分布を持つ線形定常温度場である。
- ・ 解析領域は、微小正方形を縦に 362 個、横に 362 個並べたものである。微小正方形の 1 辺の長さは 1/362 である。
- ・ 各微小格子の熱伝導率は 0.01-1.00 の一様分布からランダムに設定する。ただし、各微小正方形内の熱伝導率は一様であり、等方的である。
- ・ 境界温度は、図のように 4 隅の温度を設定し、4 隅以外の境界温度はそれらを線形補間したものとする。
- ・ 本稿では、異なる熱伝導率分布の例題を 10 個解析し、10 題の平均誤差により解析精度を検証する。

3.2 ローカル解析に用いる CNN の構築

ローカル解析に用いる CNN の教師データとして以下を作成する。

- ・ 入力データ：解析モデルと同様に各微小格子を 0.01-1.00 の一様分布からランダムに設定したローカル領域（サイズ 20 セル×20 セル）の熱伝導率分布
- ・ 出力データ：入力データを FDM 解析することにより得られる式(1)の行列 $\mathbf{A}^L$

上記の教師データを CNN に学習させることで、ローカル領域の熱伝導率分布を入力すると式(1)の行列 $\mathbf{A}^L$ を出力する CNN、つまりローカル解析を実行する CNN を構築することができる。CNN は入力画像の特徴抽出能力に優れており、本手法でも画像認識と同様に CNN がローカル領域の熱伝導率分布が持つ特徴を正確に抽出し、その特徴が正しく反映された行列 $\mathbf{A}^L$ を出力することが期待される。本稿では以下の 2 つの CNN をそれぞれ構築した。なお、CNN の学習に使用した教師データ数は 18,000 である。

- ・ CNN 1：畳み込み層 6 層＋全結合層 1 層を持った CNN
- ・ CNN 2：畳み込み層 17 層＋全結合層 1 層を持った ResNet

3.3 解析結果

本問題の厳密解は存在しないので、解析モデル全体を FDM 解析することにより得られた温度分布を参照解として、提案手法の解析精度を検証する。解析領域境界部を除いた全格子点における、提案手法による解と FDM 解




Fig. 2 Example problem of non-periodic and heterogeneous global domain.

との平均平方二乗誤差 (Root Mean Square Error, RMSE) および平均絶対誤差率 (Mean Absolute Percentage Error, MAPE) (10 題の平均値) を表 1 に示す. また, 算出された解析モデル全体の温度分布の例を図 3 に示す. CNN 2 を使用した提案手法と FDM との MAPE は 0.45% と小さく, 提案手法は既存の解析手法とほぼ同等の温度分布を算出可能であると言える.

FDM, DDM および CNN-based DDM の解析時間を表 2 に示す. CNN 1 を使用した場合の CNN-based DDM のローカル解析時間は, DDM のローカル解析時間と比較して約 70%削減されている. これは, 提案手法が既存の DDM と比較し計算コストの面で優位に立つことができることを示している. しかし解析精度の良い CNN 2 を使用した場合の CNN-based DDM のローカル解析時間は, DDM のローカル解析時間の約 8 倍となっている. これは CNN 2 の計算量が, DDM のローカル解析 (FDM 解析を使用) の計算量を大きく上回っているためだと考えられる. ローカル解析の計算時間短縮のため, 精度を落とさずに CNN を小規模化することが今後の課題である.

4. 結 言

マルチスケール解析手法の 1 種である DDM において, 既存の数値解析手法ではなく CNN を使用してローカル解析を実行する新しいマルチスケール解析手法 CNN-based DDM を提案した. 提案手法を用いて 2 次元定常熱伝導解析を実行した結果, 提案手法は一般的な FDM 解析とほぼ同精度の温度分布を取得できた. 提案手法のローカル解析に小規模な CNN を使用した場合は通常の DDM より解析時間が短縮されることを示し, 提案手法が DDM の計算コスト削減に有用であることが示唆された.

文 献

- (1) Quoc V. Le, Marc'Aurelio Ranzato, Rajat Monga, Matthieu Devin, Kai Chen, Greg S. Corrado, Jeff Dean and Andrew Y. Ng. Building High-level Features Using Large Scale Unsupervised Learning. Appearing in Proceedings of the 29th International Conference on Machine Learning. Edinburgh, Scotland, UK. 2012.
- (2) Clint N. Dawson, Qiang Du, Todd F. Dupont, A Finite Difference Domain Decomposition. Algorithm for Numerical Solution of the Heat Equation, Math. Comp., vol. 57, 63–71, 1991.

Table 1 RMSEs and MAPEs in temperature of the direct FDM analysis and those of the CNN-based DDM analysis.

	RMSE [°C]	MAPE [%]
	$\times 10^{-3}$	
CNN 1	30.8	5.3
CNN 2	2.75	0.45




Fig. 3 Typical examples of temperature distribution: the direct FDM analysis (left); the CNN-based DDM analysis (right).

Table 2 Analysis time consumed for the direct FDM analysis, the DDM analysis, and the CNN-based DDM analysis when analyzing the non-periodic stationary temperature field described in Fig. 2.

		Local analysis [sec.]	Global analysis [sec.]	Total [sec.]
	FDM	-	258	258
	DDM	13.5	130	144
CNN-based DDM	CNN 1	4.00	127	131
	CNN 2	112	104	216