

CNNによるサロゲートモデルと重ね合わせの原理を用いた温度予測手法の基礎検討

Basic study of temperature prediction method using CNN-based surrogate model and superposition principle.

入来院美代子, 岩田進裕

Miyoko Irikiin, Yukihiro Iwata

パナソニック コネクト株式会社 技術研究開発本部 先進技術研究所

(〒570-8501 大阪府守口市八雲中町3丁目1番1号, E-mail: irikiin.miyo@jp.panasonic.com)

CNN-based surrogate model (deep learning) is under development to speed up CFD calculations. In order to use the surrogate model for design development, it is necessary to improve the generalizability of the surrogate model. We have exploited the principle of superposition as one of the solutions to this problem. For the multiple heating elements that make up the model, their temperature distributions are predicted individually. We have devised a method to predict the temperature of the entire model by merging the temperature distributions of multiple heating elements in the model. Radiation and convection phenomena, for which the superposition principle does not hold, are also considered.

Key Words: CFD, Deep Learning, CNN, superposition principle

1. 背景および目的

製品開発の熱設計において、CFDによる実機開発前の事前検討は不可欠な開発設計プロセスとなっている。また、シミュレーターおよびハードウェアの進化によって詳細な構造を再現する大規模モデルの評価も可能となっているため、益々広く活用されている。

しかしながら、筆者らが対象としているモデルでは、数時間から十数時間の計算時間を要し、設計変更にインタラクティブに対応するため、計算の高速化が求められている。

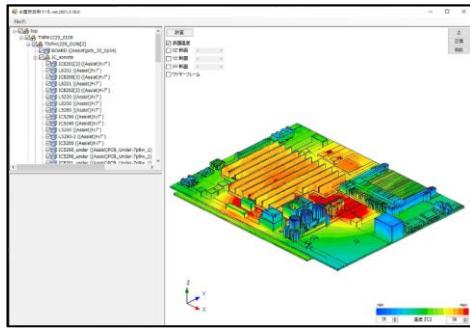


図-1 AI 热設計ツール

この課題に対して、数年前からディープラーニング(CNN)による計算高速化に取組んでいる。CFDの入力情報(構造、物性値、発熱量など)の空間分布を画像情報として表現し、CNNベースで学習したネットワークを用いて、温度分布を予測するサロゲートモデルを開発し、

独自開発のAI熱設計ツールに実装することで製品開発への適用が進みつつある。

図-1は、開発したAI熱設計ツールである。従来、基板の熱設計を対象としたCFDで、十数分かかっていた計算が本ツールを利用することで1秒以内に計算ができるため、開発設計における大幅な効率向上が期待できる。

しかしながら、ツールに組み込むサロゲートモデルを開発していく上で汎化性に課題があることが分かった。ある商品のA基板の温度予測をターゲットとして、サロゲートモデルを開発した。このサロゲートモデルの学習データはA基板をベースとして、放熱板の形状や発熱体の位置、発熱量等可能な限りランダムで作成した。ただし、全てを網羅することは不可能であるため、設計上位置が固定されている部品や発熱量が小さく熱設計に大きな影響を与えないと考えられる部品は位置を固定している。このサロゲートモデルはA基板の設計に利用するには十分な精度であるが、同じ商品のB基板を予測したところ予測精度は良くなかった。B基板についてもA基板と同様に学習データを作成し学習することで、A基板と同精度のサロゲートモデルを開発できると考えられるが、そのように一品一様でサロゲートモデルを開発するやり方では、予測したい基板や機種が変わることにサロゲートモデルを開発しなければならず、工数がかかるため商品開発への適用は困難である。

画像認識の分野では、既存の学習済みサロゲートモデルのデータは今まで新たに追加したサロゲートモデルのみを学習する転移学習や学習済みサロゲートモデルの一部と追加したサロゲートモデルの一部を活用し微調整を行うファインチューニングの手法を活用して、高品質なデータが大量にある領域の知識を転移し、少ないデ

ータ数で精度の高いサロゲートモデルを作成することができる。これらの方法を参考にしたが、汎化性の高いサロゲートモデルを作成することは困難であった。

そこで筆者らは、重ね合わせの原理を利用して、モデルを構成する複数の発熱体について、その温度分布を個別に予測し、これらを融合してモデル全体の温度を予測する手法を考案したので報告する。

なお、CNNベースのネットワークによって計算を高速化する試みとしては、西田らによるCNNと領域分割手法を融合したマルチ解析手法[1]、鈴木らによるCNNを前処理として利用したポアソンソルバーの高速化手法[2]、中村らによるオートエンコーダ型CNNのチャネル乱流現象への適用[3]が報告されているが、本研究が対象としている温度予測へのCNNベースのネットワークの適用とは異なる。

2. 理論

2.1 CFD モデル

本報告における計算対象を図-2に示す。回路基板を単純化したモデルで基材と発熱体から構成されている。

発熱体は1個以上（図-2は発熱体10個）であり、回路基板は2種類の基材からなる。

サイズは、回路基板は縦160mm・横160mm・高さ1mm、発熱体は縦10mm・横10mm・高さ1mmである。物性値は、回路基板は基材A（熱伝導率36W/m·K）、基材B（4W/m·K）の2種類、発熱体は熱伝導率36W/m·Kである。発熱量は、発熱体1個当たり0.5~3.0Wである。また、グリッド数は、面内は64×64、回路基板厚み方向は1である。

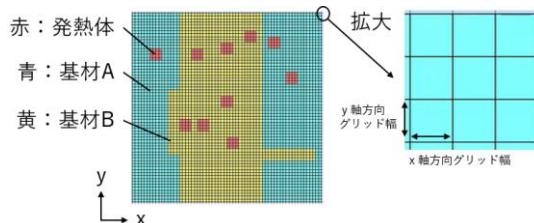


図-2 CFD モデル

2.2 CNN 概要

今回開発したサロゲートモデルはCNNネットワークのひとつであるU-Netをベースとしている。

U-Netは、Olafらによって生物医学のために開発されたSemantic Segmentation手法で、MICCAI (Medical Image Computing and Computer-Assisted Intervention) 2015で発表されている。

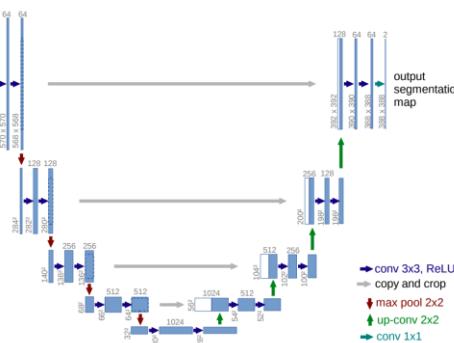


図-3 U-Net (参考文献[5]引用)

図-3は、U-Netのネットワーク図で、エンコーダとデコ

ーダからなるモデルである。エンコーダは入力された画像を何度も畳み込み、画像の特徴を抽出し、デコーダはエンコーダによって抽出された特徴から、逆畳み込みという畳み込みと逆の処理をおこなうことで、入力画像と同じサイズの画像を出力する。逆畳み込みで特微量マップを拡大するためのアップサンプリングでは、物体の位置情報をとらえることが難しいため、U-Netでは、各層において、エンコーダの特微量マップをデコーダの特微量マップと結合することでこの問題を解決している。

U-Netの最大のポイントは、このエンコーダの特微量マップとデコーダの特微量マップを結合するところで、これはスキップ接続といわれ、このオペレーションによってピクセル単位での高精度な分類が可能となっている。

このU-Netをベースとして、構造情報（発熱量、面内および厚み方向の熱伝導率、輻射率、XYZ各軸方向のグリッド幅）を入力として、温度分布を予測するサロゲートモデルを開発している。

2.3 提案手法

本報告では、重ね合わせの原理を用いて、発熱体1個ずつの温度の予測を足し合わせる方法を提案する。理由としては、重ね合わせの原理によって汎化性向上が期待できることと、商品開発においては、高密度設計・防塵設計のため熱伝導現象が支配的であることである。

熱移動は熱伝導、輻射、対流の3形態に分けられる。熱伝導については重ね合わせの原理を用い、輻射と対流については温度補正のサロゲートモデルを用いて温度予測する。

重ね合わせの原理は、線形的な系一般に成立する特徴的な原理であり、式(1)のように二つ以上の入力が同時に与えられたときに系が返す応答がそれぞれの入力が単独に加えられた場合に返される応答の総和となることをいう。この原理は線形微分方程式に適用できる。

$$F(x_1+x_2) = F(x_1) + F(x_2) \quad (1)$$

熱伝導は、熱伝導方程式（式(2)）で示される。熱伝導に関する熱伝導方程式は温度に対する線形微分方程式であるため、重ね合わせの原理が成立し、温度の重ね合わせが可能である。

$$\frac{\partial T}{\partial \tau} = \alpha \left(\frac{\partial^2 T}{\partial x^2} + \frac{\partial^2 T}{\partial y^2} + \frac{\partial^2 T}{\partial z^2} \right) + \frac{q}{\rho c} \quad (2)$$

T: 温度, τ : 時間, α : 热伝導率, xyz: 座標
 ρ : 密度 c : 比熱 q : 単位体積当たりの発熱量

一方、対流と輻射に対しては重ね合わせの原理が成立しない。理由は以下に述べる。

対流はナビエストokesの方程式（式(3)）で示される。この式は、流れに対する2階非線形偏微分方程式であるため、流れに対する重ね合わせはできない。したがって、流れによって移動する熱（温度）も重ね合わせはできない。

$$\rho \left\{ \frac{\partial v}{\partial t} + (v \cdot \nabla) v \right\} = -\nabla p + \mu \nabla^2 v + \rho f \quad (3)$$

$v(r, t)$: 流速, $p(r, t)$: 流体にかかる圧力
 f : 単位体積当たりに流体にかかる外力

輻射はシテファン=ボルツマンの法則（式(4)）で示さ

れる。この式から、輻射エネルギーは絶対温度の4乗に比例するため、温度に対する重ね合わせはできない。

$$E = \varepsilon\sigma T^4 \quad (4)$$

E : 輻射エネルギー ε : 輻射率 (0~1)
 σ : 5.67×10^{-8} (ステファン・ボルツマン定数)
T : 絶対温度 (物体表面の温度)

学習データは全て CFD で作成し、正解温度は CFD の計算結果とする。

提案手法については、学習フェーズと推論フェーズに分けて説明する。最初に学習フェーズについて図-4 のフローに沿って詳しく説明する。

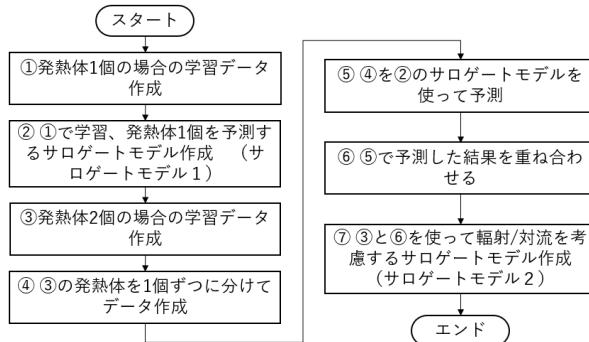


図-4 学習フェーズのフロー

① 回路基板に発熱体1個だけが搭載された学習データを作成する。学習データの一例を図-5に示す。サイズ等は図-2と同じである。発熱体の位置、発熱量、基板の基材の異なる部分のサイズや位置はランダムで振る。

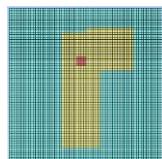


図-5 学習データの一例

② ①の学習データを使って学習をする。入力情報は発熱量、熱伝導率(面内方向/厚み方向)、輻射率、xyz各軸方向のグリッド幅の7レイヤーであり、出力情報は温度分布である。この学習済みのネットワークをサロゲートモデル1とする。(図-6)

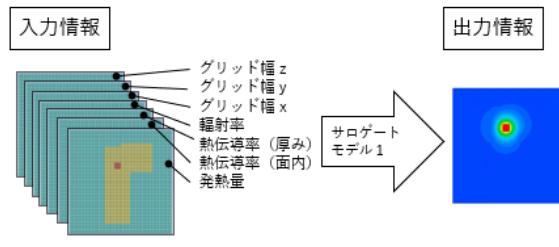


図-6 データ構造

図-7に今回検討したネットワークの構造を示す3DConvolution, MaxPooling, 3DconvolutionTranspose をベースにしたモデルで、2箇所 SkipConnection を使って情報を伝達している。また、ネットワークへの入力データは標準化を適用している。

3DConvolution, MaxPooling, 3DconvolutionTranspose をベースにしたモデルで、2箇所 SkipConnection を使って情報を伝達している。また、ネットワークへの入力データは標準化を適用している。

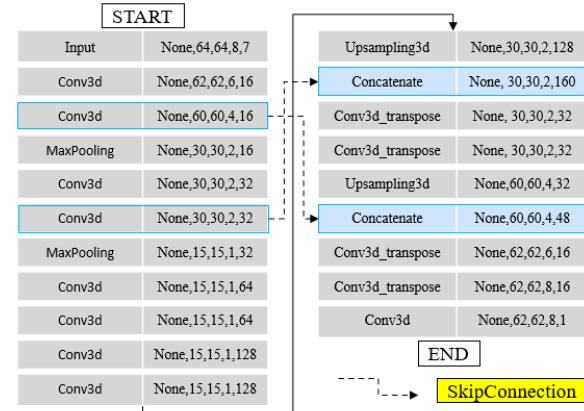


図-7 ネットワーク構造

③ 輻射と対流を考慮するためのサロゲートモデルを作るために、学習データを作成する。

輻射と対流は、任意の位置において、発熱体Aだけが発熱したときの温度上昇と発熱体Bだけが発熱したときの温度上昇、発熱体C、発熱体D…を足し合わせることで温度を予測することはできない。つまり、温度を予測するにあたって個々の発熱体を独立して考えることができず、複数個の発熱体が同時に発熱した時の温度上昇による影響を考えなければならない。この影響を考慮するために最も少ない個数である発熱体2個で学習することとする。発熱体サイズ等は図-2と同じである。発熱体の位置、発熱量、基板の基材の異なる部分のサイズや位置はランダムで振る。

④ ③の発熱体を1個ずつに分けたデータを作成する。(図-8)

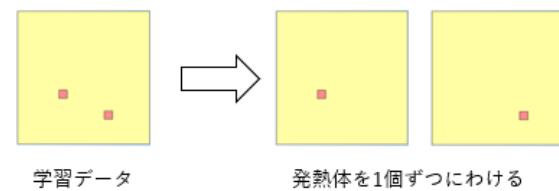


図-8 発熱体を1個ずつに分けたデータ

⑤ ④の発熱体を1個ずつに分けたデータをサロゲートモデル1で予測する。(図-9)

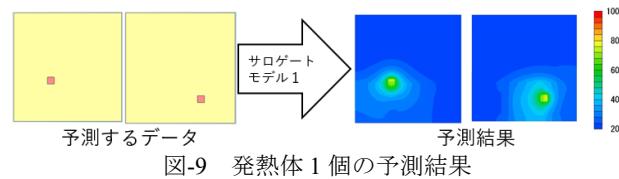


図-9 発熱体1個の予測結果

⑥ ⑤で予測した結果を同じ位置のグリッド毎に足し合わせる。この結果を重ね合わせ後の温度予測とする。(図-10)

⑦ 入力情報を⑥の重ね合わせで予測した温度の結果(熱伝導○、輻射/対流×)、出力情報を③のCFDの計算結果(熱伝導/輻射/対流○)として学習する。これによって、重ね合わせとCFD結果の差分(輻射/対流の差分)を学習

し、このネットワークをサロゲートモデル2とする。

(図-11)

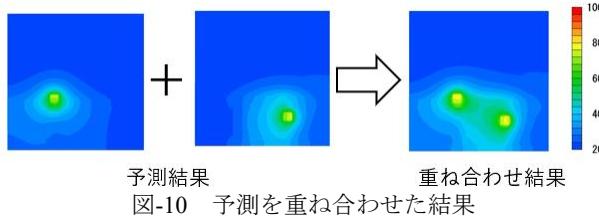


図-10 予測を重ね合わせた結果

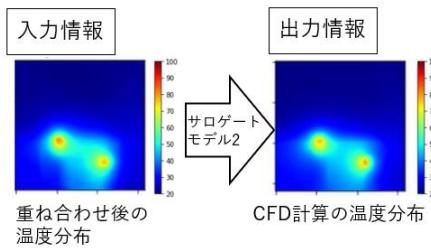


図-11 対流・輻射補正のサロゲートモデル

次に推論フェーズについて、図-12 のフローに沿って詳しく説明する。

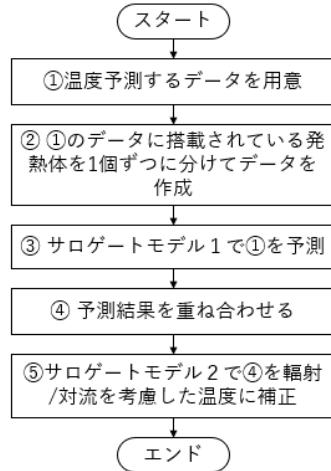


図-12 推論フェーズのフロー

① 温度予測するデータを用意する。

② ①の発熱体を1個ずつに分けたデータを作成する。
(図-13)

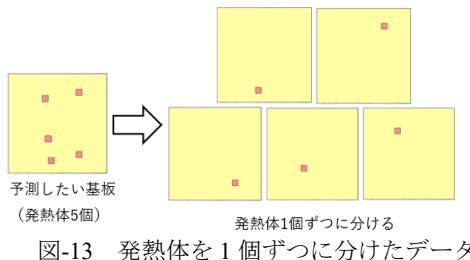


図-13 発熱体を1個ずつに分けたデータ

③ ①の発熱体1個ずつに分けたデータをサロゲートモデル1で予測する。(図-14)

④ ③の予測結果を同じグリッド毎に足し合わせる。
(図-15)

⑤ ④の重ね合わせの温度分布を入力にして、サロゲートモデル2を使って、輻射/対流を考慮した温度を予測する。
(図-16)

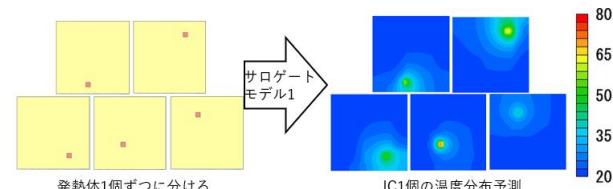


図-14 IC1個の予測結果

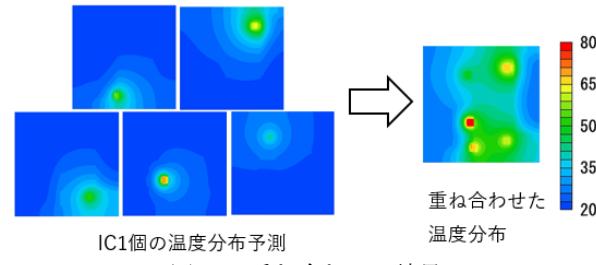


図-15 重ね合わせの結果

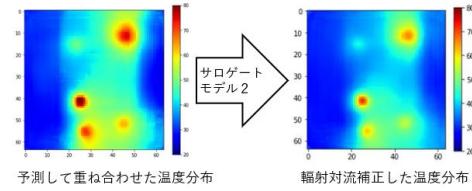


図-16 輻射/対流補正前後の温度分布

3. 結果および考察

発熱体10個搭載した基板を100データ(以下、データセットA)用意し、このデータの温度予測し、本手法の有効性を検討する。

まず、2.3 提案手法の学習フェーズで示すようにデータを300個作成し学習する。このネットワークをサロゲートモデル1とする。

サロゲートモデル1で回路基板に発熱体1個を搭載したデータ100個を予測した結果を図-17、図-18に示す。図-17は100データ全てにおいて、グリッド毎に正解温度と予測温度の誤差を算出し、温度帯域毎に平均誤差を示したグラフであり、図-18は任意のデータの基板面の温度分布を比較している。この結果からサロゲートモデル1は全温度帯域に置いて4%以内の予測誤差であり非常に精度が高いことが分かる。

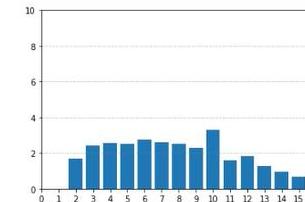


図-17 温度帯域毎の予測誤差(横:温度帯域/縦:誤差(%))

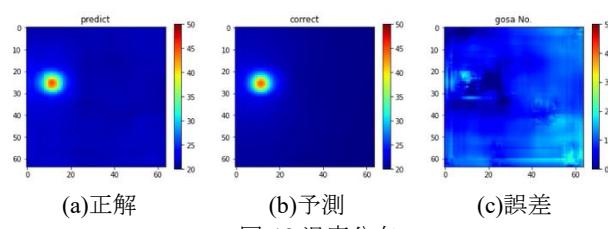


図-18 温度分布

データセット A をサロゲートモデル 1 で温度予測をした結果を図-19、図-20 に示す。図-19 は温度帯域毎に温度誤差平均を示したグラフ、図-20 は任意のデータの基板面の温度分布を比較している。発熱体 1 個のデータで学習させたサロゲートモデル 1 でデータセット A を予測すると誤差 10%以上となる。また温度分布の結果から発熱体の位置はとらえているものの温度の絶対値は全く合っていない。この結果から発熱体 1 個で作成したサロゲートモデル 1 は発熱体同士の影響を学習することが難しいと考えられる。

次にサロゲートモデル 1 で予測した温度を重ね合わせた結果を示す。図-21 は温度帯域毎の温度予測誤差、図-22 は任意のデータの基板面の温度分布である。このように重ね合わせた温度の結果はサロゲートモデル 1 でダイレクトに予測した結果より良くなっている。最後に輻射/対流補正用のサロゲートモデル 2 を使って、図-21、22 で示した重ね合わせの温度を補正する。補正用のサロゲートモデル 2 は発熱体 2 個を搭載したデータを 100 個用意し学習した。図-23 は補正後の温度帯域毎の予測誤差、図-24 は補正後の任意のデータの基板面の温度分布を示す。

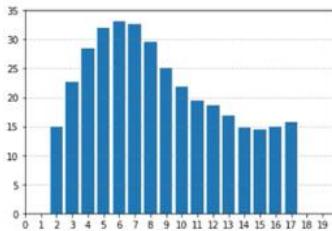


図-19 温度帯域毎の予測誤差(横:温度帯域/縦:誤差(%))

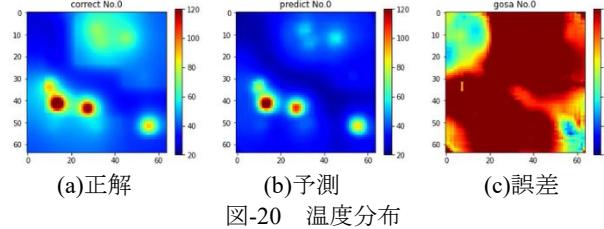


図-20 温度分布

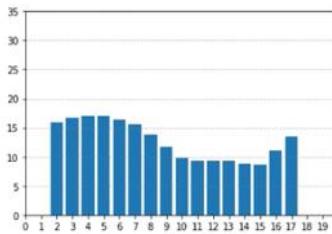


図-21 温度帯域毎の予測誤差(横:温度帯域/縦:誤差(%))

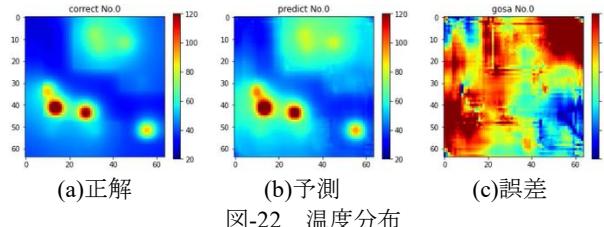


図-22 温度分布

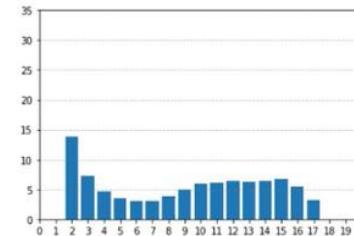


図-23 温度帯域毎の予測誤差(横:温度帯域/縦:誤差(%))

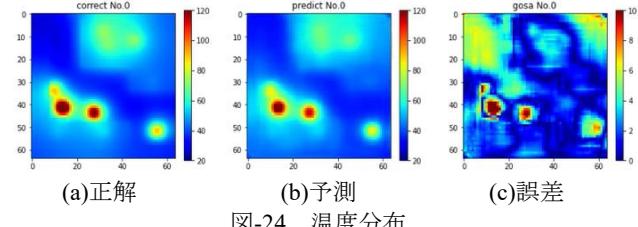


図-24 温度分布

輻射/対流を考慮して補正するとほぼ全温度帯域で精度 10%以内を達成できている。本手法は、発熱体の個数が変更になっても対応することができ、汎化性の高い手法と言える。

4. 結論

重ね合わせの原理を利用して、回路基板を構成する複数の発熱体について、その温度分布を個別に予測し、これらを融合してモデル全体の温度を予測する方法を提案し、簡易モデルにおいて、その有効性を示すことができた。

また、重ね合わせの原理が成立しない輻射および対流現象に関する少ないデータ数でサロゲートモデルを作成し、単純に重ね合わせた結果に補正をすることで温度予測の精度を向上させた。

従来、予測したい基板の学習データは、それらをベースとして部品配置や発熱量をランダムに決めていたため、その学習データに含まれていないパターンは精度よく予測できない課題があった。しかしながら、提案手法である発熱体 1 個を搭載した場合のサロゲートモデルによる重ね合わせによる温度予測は、様々な基板毎にサロゲートモデルを作る必要がなくなり、汎化性の高い手法である可能性を示せた。

今後は発熱体以外の部品の搭載（放熱部品等）等複雑な構造へ対応可能な技術の開発を進める予定である。

謝辞

近畿大学 教授 和田義孝先生には、共同研究を通して、本研究の取組について有益な助言をいただき、感謝の意を表する。

参考文献

- [1]西田猛哲、大鈴木良郎、轟章、水谷義弘：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、数値力学講演会論文集、2018
- [2]鈴木隆洸、大道勇哉、他：畳み込みニューラルネットワークを用いた非圧縮CFDにおけるポアソンソルバーの高速化、数値流体力学シンポジウム講演論文集、B05-1、2018
- [3]中村太一、深瀬康二、他：オートエンコーダを用いた

チャネル乱流の機械学習、数値流体力学シンポジウム
講演論文集、B10-1、2019

[4]鈴深見開、深瀬康二、平 邦彦：チャネル乱流における
機械学習3次元超解像解析、日本機械学会流体工学部門
ニュースレター「流れ」、2020年2月号、Art. 4 (2020).

[5]O.Ronneberger,P.Fischer, and T.Brox:U-net:Convolutional
networks for biomedical image segmentation, in International
Conference on Medical image computing and computer-
assisted intervention, Springer, pp. 234–241 (2015).