

空力設計における機械学習を用いた形状最適化

日大生産工(院) ○吉沢 昇馬 日大生産工 沖田 浩平

1. 緒言

近年、機械学習の発展により、流体解析においても計算コストの削減や設計最適化の効率化が期待されている。また、機械学習を用いた手法は、高速な予測と形状最適化に有用であることが知られている。

この計算コストにおいて、サロゲートモデルを用いることで高コストな流れ場の計算回数精度を維持しつつ削減し、効率的に解析を行う手法がある。Forrester¹⁾は、航空機の翼形状最適化問題に対して、クリギングモデルを用いたサロゲートベース最適化手法を提案し、効率的に最適形状を探索できることを示している。また、Maulik²⁾は、深層ニューラルネットワークを用いたサロゲートモデルを構築し、航空機の翼形状最適化問題に適用することで、従来の手法よりも高精度な予測が可能であることを示している。

本研究では、OpenFOAMを用いた流体解析と機械学習モデルであるサロゲートモデルを組み合わせ形状最適化を効率的に行う手法を検証した。

2. 形状最適化のためのプログラム構築

2.1. プログラムの概要

以下の手順で形状最適化を行った。

- ① 初期形状の設定と面積・エッジ長の計算
- ② ランダムな形状生成
- ③ OpenFOAMによる流体解析
- ④ 圧力データの取得
- ⑤ ②から③の繰り返しによりデータセット作成
- ⑥ 機械学習によるサロゲートモデル構築
- ⑦ サロゲートモデルを用いた形状の最適化
- ⑧ 最適化された形状を次サイクルの初期形状として①からの手順を繰り返す。

2.2. 初期形状の設定

初期形状として、半径0.5mの円に外接する32分割した多角形を採用した。この形状の頂点座標を初期形状として定義した。

2.3. ランダム形状の生成と流体解析

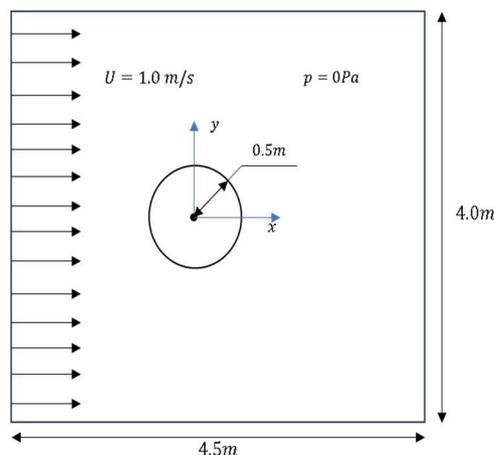


Fig. 1 初期形状と解析条件

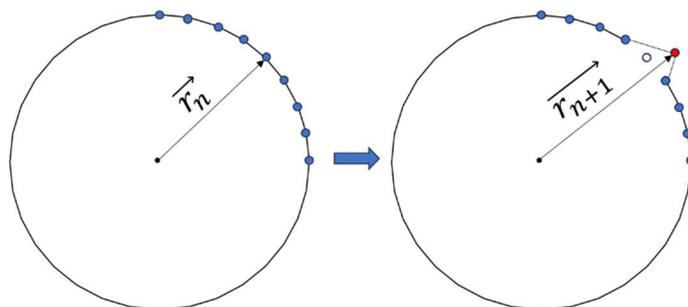


Fig. 2 座標の移動

各サイクルにおいて、初期形状にランダムな摂動を加えた形状を生成する。生成した形状は以下の4つの条件を満たすように調整した。

- ・初期形状の面積 S_0 とランダムに生成された形状の面積 S_n が乖離率0.1%以下であること

$$S_n \leq S_0 \pm \frac{1}{1000} S_0 \dots \textcircled{1}$$

- ・自己交差がないこと
- ・凹面形状を防ぐためエッジの角度を制限
- ・頂点座標の移動距離を ± 0.01 の範囲に制限

$$\vec{r}_{n+1} = \vec{r}_n \pm 0.01 \vec{e} \dots \textcircled{2}$$

- ・生成する範囲を(2,2)から(-2,2)の範囲内とする
- 生成された形状をSTLファイルとして保存する。

2.4. OpenFOAMによる流体解析とデータセットの作成

解析ではblockMesh, snappyHexMesh, simpleFoamを順次実行し, 定常状態の圧力データを取得する. 解析結果から, 各頂点に最も近い圧力値を取得する. 得られた頂点座標と圧力値の組をデータセットとして保存する.

2.5. 機械学習によるサロゲートモデル構築

データセットを用いて, サロゲートモデルであるニューラルネットワークを学習する. モデルは頂点の座標(x, y)を入力とし, 対応する圧力値を出力する. 最適化手法には各座標に対して個別の学習率を計算する目的でAdamを採用した.

2.6. 形状の最適化

学習したサロゲートモデルを用いて, 形状の最適化を行う. 最適化の目的は, すべての頂点における圧力の絶対値を最小にすることである. さらに, 以下の制約条件を損失関数にペナルティ項として加える.

- ・エッジ長の維持 (エッジ長損失)

$$\lambda_{edge} = 1 \times 10^4 \dots \textcircled{3}$$

- ・自己交差の回避 (自己交差損失)

$$\lambda_{intersection} = 1 \times 10^6 \dots \textcircled{4}$$

- ・形状の滑らかさの維持 (滑らかさ損失)

$$\lambda_{smoothnes} = 1 \times 10^4 \dots \textcircled{5}$$

- ・目的に対する重み (圧力損失)

$$\lambda_{ipressure} = 1 \times 10^3 \dots \textcircled{6}$$

最適化にはPyTorchを用い, 学習率は0.0005に設定した. 最適化後の形状は, 次のサイクルの初期形状として使用する. このサイクルを60回繰り返した.

3. 結果

本研究では, OpenFOAMによる流体解析とサロゲートモデルを組み合わせた形状最適化手法を検証した. 各サイクルにおいて, 初期形状にランダムな摂動を加えた形状を生成し, 流体解析により圧力データを取得した. これらのデータを用いてサロゲートモデルを学習し, 圧力値を最小化するよう形状を最適化した.

最適化の過程で, 各サイクルのサンプル0の座標と圧力データを取得し, 解析によるデータとして保存した. また, すべてのサイクルが終了した後, 得られた最終形状に対して再度流体解析を行い, 同様に座標と圧力データを取得した.

結果として, サロゲートモデルを用いた形状最適化により, 圧力分布が効果的に改善されることが確認できた. 初期形状から最終形状にか

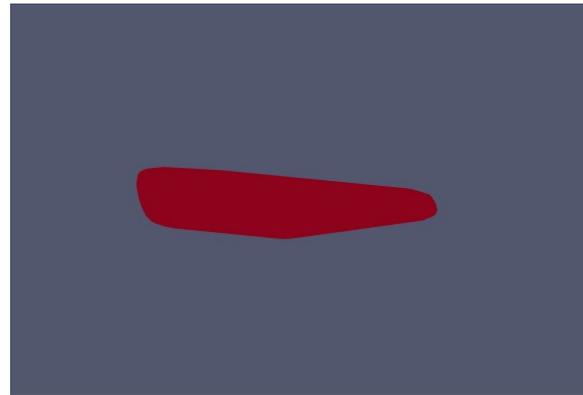


Fig 3 得られた形状

けて, 形状が滑らかに変化し, 圧力の高い部分が緩和されていることがわかる.

さらに, 面積やエッジ長の制約を考慮することで, 形状の物理的な妥当性を維持しながら最適化を進めることができた. 得られた形状をFig.3に示す.

サロゲートモデルについては, 過学習が起きやすく, 学習率を下げ, サイクルを増やすことで目的の形状から乖離してしまいことを防ぐ必要があることが分かった.

OpenFOAMとサロゲートモデルを組み合わせた本手法が確認できた.

4. 結言

OpenFOAMを用いた流体解析と機械学習モデルであるサロゲートモデルを組み合わせ形状最適化を行うことができた. 講演ではサロゲートモデルによって推測される各座標の圧力値と実際に解析によって得られる圧力値の比較や最適化の手法について具体的に説明する.

5. 参考文献

- 1) Forrester, A. I. J., Sobester, A., & Keane, A. J. (2005). Surrogate-Based Optimization of Aerodynamic Shapes. *AIAA Journal*, 43(5), 1052-1060.
- 2) Maulik, R., & Straub, D. (2016). Deep Neural Networks for Surrogate Modeling in Aerodynamic Shape Optimization. *AIAA Journal*, 54(9), 2886-2895.