

メカニカルシールの表面テクスチャ形状最適化における機械学習活用の検討 Shape Optimization of Surface Textured Mechanical Seals by Machine Learning

イーグル工業（正）*王 岩

Iwa Ou*

*Eagle Industry Co., Ltd.

1. はじめに

メカニカルシールは各種回転機械の軸封部に使用され、内部の流体の漏洩を防ぐ密封装置の一種である。その重要な機能として、流体の密封と潤滑が挙げられる。メカニカルシールのしゅう動面間に流体膜を形成すれば摩擦抵抗の低減が図れる一方、隙間が生じ、流体が漏れやすくなる。一方、隙間を小さくすれば漏れは少なくなるが、摩擦抵抗が上昇する。この二律背反を解決するため、徳永らは表面テクスチャリング技術を用い、密封もしくは潤滑機能を有する溝（以下、表面テクスチャ）を付与し、トルク低減と高密封性の両立を実現した^{1,2)}。

表面テクスチャで発生する圧力分布は流体潤滑理論に基づき計算され、シール性・潤滑性の向上に寄与している。アプリケーション毎に作動条件が異なるため、その都度表面テクスチャ形状の最適化が行われる。この過程で大量の解析データが生成される。著者は機械学習を用いてこれらのビックデータを活用し、代替モデル（サロゲートモデル）を構築することで流体潤滑解析の支援が可能であることを示した^{3,4)}。

本報では、機械学習モデルによって作成した流体潤滑解析の代替モデルを用いて形状を最適化し、流体潤滑解析を用いた場合と比較した。また、形状最適化における、深層学習ならではの活用方法についても検討したので紹介する。

2. ディープニューラルネットワークによる表面テクスチャの性能予測

まず、表面テクスチャで広く使用されるスパイラル型の形状について、形状パラメータから負荷容量等の評価値をDNN(Deep Neural Network, ディープニューラルネットワーク)によって予測する機械学習モデルを構築した。

2.1 学習データ

溝幅、溝深さ、角度、スパイラル本数等が異なった形状について、8000件の学習データと2000件の検証用データを流体潤滑解析で作成した。入力値は形状パラメータの5つ、出力値は負荷容量の1つ、作動条件は固定とした。

2.2 モデル構築

機械学習モデルには入力値と出力値を3層の中間層で繋げたシンプルなDNNを採用した。なお各層のユニット数は100とし、バッチサイズは128、損失関数はMSE (Mean Squared Error, 平均二乗誤差)、最適化関数はAdam (Adaptive Moment Estimation)、活性化関数はtanh (Hyperbolic tangent function, 双曲線正接関数)を使用した。

2.3 学習結果

学習時における損失関数 (Loss Function) の推移を Fig. 1(a)に示す。損失関数とは正解値と、予測値とのズレの大きさを示す関数であり、値が小さくなるほど良いモデルであることを示す。学習データ、検証データともに学習回数 (Epoch) に伴い損失関数が減少しており、正常に学習が進んでいることがわかる。次に検証データにおける負荷容量について、流体潤滑解析によって求められた真値と、DNNによる予測値の散布図を Fig. 1(b)に示す。学習の結果、負荷容量を2.7%の誤差精度で予測可能なDNNが構築された。

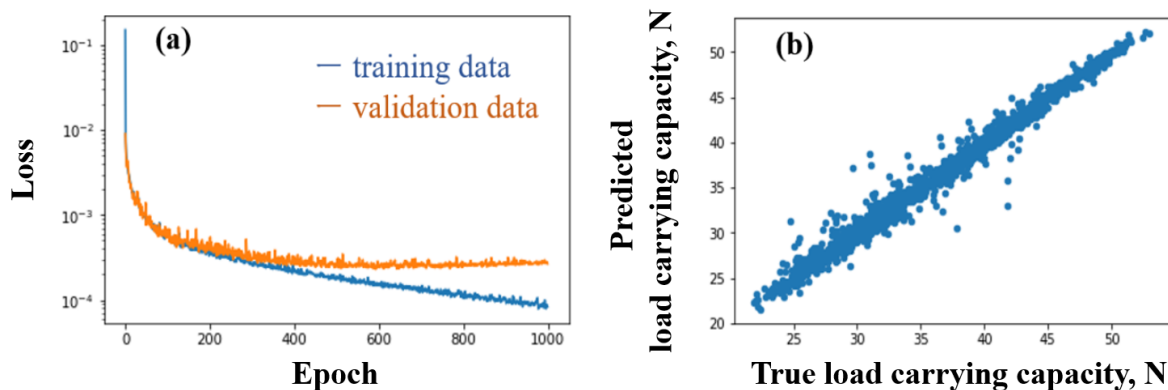


Fig. 1 (a) loss value for training data (yellow) and validation data (blue) as a function of learning cycle (epoch).
(b) Scattered plot of true load capacity and estimated value.

3. 代替モデルを利用した表面テクスチャ形状の最適化

クラウド環境を想定し、前項で作成したDNNモデルをウェブアプリとして実装した専用サーバを立て、遺伝的ア

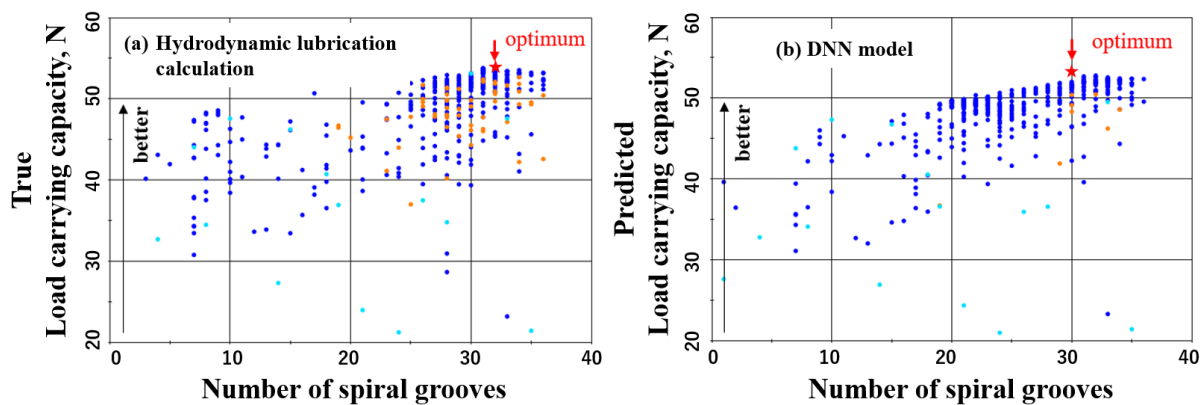


Fig. 2 Shape optimization by Hydrodynamic lubrication calculation (a) and DNN (b)

ルゴリズムに基づく形状最適化時に流体潤滑解析と切り替えができるように設計した。形状最適化の目的関数は負荷容量最大化とした。

スパイラル本数を例として、流体潤滑解析による形状最適化の推移を Fig. 2(a)に、DNN による最適化推移を Fig. 2(b)に示す。DNN は流体潤滑解析に比べ非効率的な探索が目立つものの、流体潤滑解析で最適だと示された 32 本に近く、30 本という結果が得られている。さらに、DNN による最適化に要した実時間は、流体潤滑解析の 1/100 と大幅に短縮できた。

4. その他深層学習の手法による形状最適化の検討

機械要素の形状最適化には昔から、トポロジー最適化に代表される勾配法、遺伝的アルゴリズムや応答曲面を用いた手法、モンテカルロ法、その他にも多数の手法が活用されてきた。これらも与えられたデータから法則性を見つけ出し、形状を最適化するという観点で見れば、機械学習の一種であると言える。一方で、近年話題となっている深層学習では、データの表現性が大幅に向上したことにより、様々な新規手法が提案されている。これらの中から、形状最適化における、深層学習ならではの活用方法について検討したので紹介したい。

4.1 強化学習

強化学習とは環境の状態をエージェントが観測し、学習を繰り返しながら取るべき行動を決定する手法のことで、ゲーム AI やロボット制御に広く用いられている。強化学習で重要な要素となる状態、報酬、行動を形状最適化問題に合わせて工夫することで活用できると考えられる。実例としては翼形状の最適化での適用例が報告されている⁵⁾。

4.2 生成モデル

生成モデルとは、与えられた学習データがどのように生成されているか学習するモデルのことで、学習データの特徴を持った新しいデータを生成することができ、特に画像処理分野での利用が進んでいる。生成モデルで今までになかった形状を生成しつつ、性能評価も同時に行うことで、形状最適化に適応できると考えられる。実例としてはレドックスフロー電池の流路最適化での活用例が報告されている⁶⁾。

5. おわりに

メカニカルシールのスパイラル型の表面テクスチャ形状を対象に、機械学習モデルを用いて形状最適化を行い、流体潤滑解析ベースの最適形状に近い形状を得ることができた。特に最適化の初期～中期段階で積極的に使用し、後期段階で流体潤滑ベースに移行することで、最適化時間を短縮するとともに精度も担保できると考えられる。

また本稿では代替モデルによる計算時間の短縮として深層学習を活用する例を述べたが、深層学習ならではの活用方法として、強化学習や生成モデルを検討した。今後これらの手法を用い、形状ルールに縛られない、より良い性能を持った表面テクスチャ形状や、これまでになかった斬新的な表面テクスチャ形状の探索を目指していく。

文献

- 1) 徳永・上村・山本：密封機構と摩擦低減機構を有するメカニカルシールの開発と性能評価-理論的検討-, トライボロジスト第 58 巻 第 2 号(2013) 102.
- 2) 徳永・杉村・山本：密封機構と摩擦低減機構を有するメカニカルシールの開発と性能評価-実験的検討-, トライボロジスト第 60 巻 第 5 号(2015) 332.
- 3) 王：機械学習を活用したメカニカルシールの表面テクスチャリング設計への試み, 第 10 回トライボロジー秋の学校 in 愛知 (2019)
- 4) 王：機械学習を用いたメカニカルシールの表面テクスチャで発生する圧力分布の予測, トライボロジー会議 2021 秋 松江予稿集 (2021) A23.
- 5) 服部・米倉：深層強化学習を用いた LPT 翼形状の最適化, ながれ 38 (2019) pp. 89-92.
- 6) Kentaro Yaji, Shintaro Yamasaki & Kikuo Fujita: Data-driven multifidelity topology design using a deep generative model: Application to forced convection heat transfer problems, Comput. Methods Appl. Mech. Engrg. 388 (2022) 114284.