

表面テクスチャリング設計における機械学習の活用

Feasibility study of machine learning for surface texturing

イーグル工業（正）*王 岩

Iwa Ou*

*Eagle Industry Co., Ltd.

1. はじめに

表面テクスチャリング（以降表面テクスチャ）は機械機器のしゅう動面上に付与される表面改質の一種であり、トライボロジー特性を向上する効果を有することが知られている。各種回転機械の軸封部に使用されるメカニカルシールでは、表面テクスチャを付与することで、しゅう動面間に形成される流体膜によるトルク低減と、漏れた流体を回収する機構による高密封性の両立が実現可能であると報告されている^{1,2)}。表面テクスチャで発生する圧力分布はレイノルズ方程式に基づく流体潤滑計算により求められ、潤滑性・密封性が評価される。アプリケーション毎に作動条件が異なるため、その都度、形状最適化が行われ、この過程で大量の解析データ（ビッグデータ）が生成される。

著者は機械学習（本稿では主に深層学習を示すこととする）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)}。また表面テクスチャ設計における、深層学習ならではの活用方法について公開文献を元に検討したので紹介する⁵⁾。

2. 機械学習を用いた性能予測

代表的な表面テクスチャの形状としてスパイラル形状を例に、機械学習の適応性を検証した。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、10000件のデータを流体潤滑解析で作成した。ここで入力値は形状パラメータの5つ、出力値は負荷容量（潤滑性能の指標）の1つ、作動条件は固定とした。これら入力と出力の関係性を、シンプルなDNN(Deep Neural Network、ディープニューラルネットワーク)により学習させ、負荷容量を2.7%の誤差精度で予測できるDNNモデルを作成した。このDNNモデルと遺伝的アルゴリズムを組み合わせ、スパイラル形状の最適化を実施した。また比較のため、従来通り流体潤滑解析による形状最適化と比較した。Fig.1にそれぞれの最適形状を示す。DNNモデルで流体潤滑解析とほぼ同様なスパイラル形状が得られていることがわかる。また、DNNモデル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。このような代替えモデルを用いることで、計算時間を短縮できるのが機械学習の利点のひとつである。また著者が行った検証では⁵⁾、作動条件と出力を入れ替えることで、通常では困難な逆問題へのアプローチが可能で、非常に有効的な活用方法だと言える。

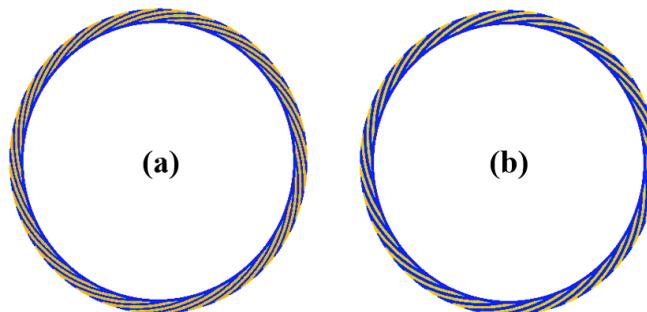


Fig. 1 Optimal shapes derived from (a) machine learning and (b) hydrodynamic lubrication calculation)⁴⁾

3. 機械学習を用いた圧力分布予測

前章では形状のパラメータから性能値を予測するモデルであったため、汎用性に欠けるといった問題点がある。筆者はこれを解決するため、形状を表現するメッシュデータそのものから圧力分布が予測できるか、つまり、高次元データから高データの予測が可能か検証した。

表面テクスチャ形状の例として、両回転対応型レイリーステップ形状を選定した。また機械学習モデルにはColorizationモデルのひとつであるU-Netを用いた。ColorizationとはDNNを用いて白黒の画像や動画をカラー化する手法である。そこで著者は表面テクスチャ形状から圧力分布を求めることは、Colorizationと同じ色付け問題と捉えることができると考えた。また比較のため、畳み込み層のみで全結合されたオートエンコーダ（Convolutional Neural Network AutoEncoder, CNN-AE）でも学習を試みた。

Fig.2の左から順に、表面テクスチャ形状、流体潤滑解析で計算された圧力分布（真値）、CNN-AEで予測された圧力分布、U-Netで予測された圧力分布の例をそれぞれ極座標系で示す。CNN-AEでは、真値に比べると圧力分布の形状が崩れ、正確な予測できていない一方、U-Netでは動圧部の形状・高さを精度良く再現できていることがわかる。

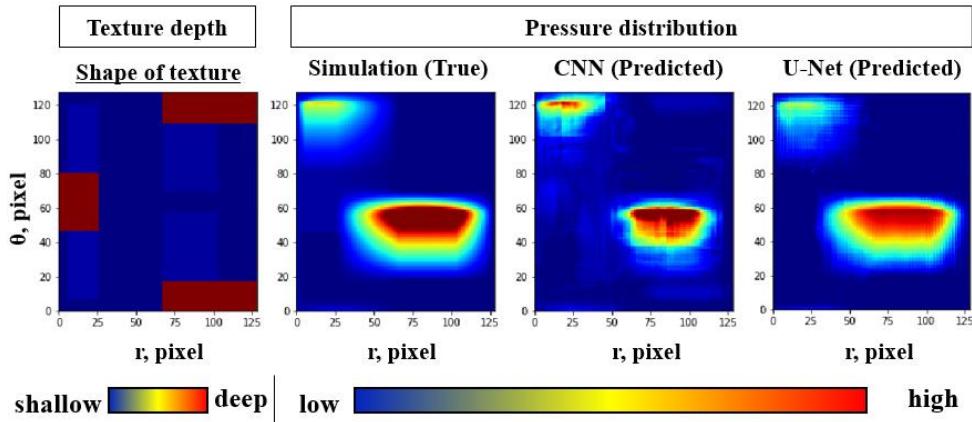


Fig. 2 Shape of surface texturing and pressure distributions³⁾.

4. 深層学習ならではの表面テクスチャ設計の検討

前章までは主に計算時間短縮が主な機械学習活用の目的であり、既存の設計領域を超えることはない。機械機器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、表面テクスチャ設計における、深層学習ならではの活用方法について分野外の公開文献を元に検討したので紹介したい^{4,5)}。

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、ゲームAIやロボット制御に広く用いられている。強化学習では①状態、②報酬、③行動をといった基本要素を設定する必要がある。これを表面テクスチャにおいては、①作動条件、形状、②性能値、③形状の変化に当てはめることで活用できると考えられる。分野外の実例としては航空機の翼型に用いられるNACA翼形状の最適化での適用例が報告されている⁶⁾。

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、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、表面テクスチャ設計に適応できると考えられる。分野外の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⁷⁾。

5. おわりに

本稿ではメカニカルシールの表面テクスチャ設計を対象として、流体潤滑解析で得られたビッグデータを機械学習によって活用することで、計算時間の大幅短縮や、逆問題への適応、高次元データの予測等の可能性を示すことができた。また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。これらの手法を用いることで、より良い性能を持った表面テクスチャや、斬新的な表面テクスチャ形状の探索が期待できる。

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、トライボロジーカンファレンス2021秋 松江予稿集(2021)A23.
- 4) 王：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、トライボロジーカンファレンス2022秋 福井予稿集(2022)A2.
- 5) 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における流体潤滑解析、トライボロジスト第67巻第12号(2022)838.
- 6) 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.
- 7) 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.