

数値計算・実験データからの潤滑油中の摩擦ダイナミクスの ディープラーニングによる解析

Analysis of friction dynamics in lubricants
from numerical and experimental data using deep learning

兵庫県大・情（正）*山口 翔太郎 兵庫県大・工（正） 木之下 博 兵庫県大・情（正）鷺津 仁志

Shotaro Yamaguchi*, Hiroshi Kinoshita*, Hitoshi Washizu*

*University of Hyogo

1. はじめに

近年、機械的接触部における摩擦現象の解明と制御は、輸送機械や精密機器の高効率化・長寿命化に直結する重要課題となっている。特に、焼き付きのような急激な摩擦異常は、部品寿命やシステムの信頼性を大きく左右するため、その発生メカニズムを解明し、予兆を捉える診断技術の確立が強く求められている。しかし、摩擦・摩耗の進行過程は荷重、速度、温度、表面粗さ、潤滑条件など多くの因子が複雑に相互作用する多次元的かつ非線形な現象であり¹⁾、従来の経験則や単純な物理モデルのみでは予測が難しい。さらに、焼き付きが発生する摩擦界面の直接観察や実時間での計測手法が限られていることも、現象理解を困難にしている要因の一つである。

一方、近年注目を集める機械学習、特に畳み込みニューラルネットワーク（Convolutional Neural Network; CNN）を用いたデータ駆動型アプローチは、実験データやシミュレーションデータから摩擦挙動の特徴を自動抽出し、未知条件下での予測や異常検知に応用できる可能性が示されている。トライボロジー分野においても、CNNを用いた摩擦界面像からの摩擦力推定が報告されており、木之下らはポリアセタール（POM）の摩擦界面 SEM 像を対象として CNN を適用し、高精度な摩擦力推定が可能であることを示している²⁾。

しかしながら、焼き付きのような急激かつ非線形な摩擦異常を対象とした CNN の応用研究は依然として限られており、その予兆を含めた摩擦力変動の画像ベース推定に関する知見は十分に蓄積されていない。

本研究では、ステンレスとサファイアガラスの pin-on-plate 試験機を用いて、焼き付きが発生するまで往復しゅう動試験を行い、得られた摩擦力の時系列データと摩擦界面画像からデータセットを構築した。このデータセットを用いて CNN による学習を行い、摩擦挙動の特徴抽出と焼き付き予兆検知の可能性を検討した。本研究は、将来的な潤滑条件下での摩擦ダイナミクス解析や異常診断手法の確立に向けた基礎的な検討である。

2. 実験データ

2.1 試験条件

本研究では、pin-on-plate 試験機を使用し、焼き付きが発生するまで往復しゅう動試験を行った。試験片は直径 20 mm、厚さ 3 mm のサファイアガラスをディスク側に、直径 6 mm の高炭素クロム軸受鋼（SUJ2）球をピン側に用いた。荷重は 200 N、しゅう動周波数は 2.5 Hz、しゅう動幅 4 mm に設定した。

2.2 摩擦力計測およびデータ取得

摩擦力は試験機に内蔵したロードセルを用いてサンプリング周波数 1 kHz で計測した。摩擦力の時系列データは、測定器のノイズや微小な振動などで上下に細かく振れる。そのため Python スクリプトを用いてスムージングをかけ、平均摩擦力を算出し、代表値として整理した。

2.3 学習用データセット作成

取得した摩擦力の時系列データおよび摩擦界面の動画から、深層学習用の画像データセットを構築した。摩擦力は CSV 形式で記録されており、各フレームに対応する摩擦力を同時に取得した。摩擦界面の動画からは、あらかじめ設定した領域をフレームごとに切り出して画像化した。代表的な摩擦力の大小に対応する摩擦界面画像を Fig.1 に示す。低摩擦状態 (a) では界面構造が比較的均一である一方、高摩擦状態 (b) では表面粗さの増加や摩耗粉の堆積が確認され、画像上の質感にも顕著な違いが見られる。これらの画像と対応する摩擦力値を記録した CSV ファイルを作成し、データセットとして整理した。

最終的に、約 700 枚の摩擦界面画像と摩擦力データからなる学習用データセットを構築した。




Fig.1 Representative friction interface images: (a) low-friction state, (b) high-friction state.

3. CNN による学習

構築した摩擦界面画像データセットを用いて、畳み込みニューラルネットワーク (CNN) による摩擦力の推定モデルを学習した。本研究では、摩擦界面画像から摩擦力を回帰的に予測するタスクを設定し、画像と摩擦力値との関係を学習させた。

4. 結果と考察

Figure 2 に、実験で測定された摩擦力の時間変化を示す。特に 25～30 秒付近では、摩擦力が短時間（約 2 秒）で急激に上昇しており、この期間は取得できる摩擦界面画像の枚数が少ない。この傾向は、Fig. 3 に示す摩擦力の頻度分布においても、焼き付き前後（概ね 20～30 N 付近）のデータ数が少ないことから裏付けられ、学習データの偏りや予測精度への影響が示唆される。

学習過程においては、エポック数の増加とともに摩擦力予測の精度が向上した。エポック 2001 における訓練データおよびテストデータに対する予測結果を Fig. 4 および Fig. 5 に示す。いずれの場合も、実測値と予測値の間に明瞭な相関が確認され、特に低・中・高摩擦力の各領域において点群が直線的に分布していることから、摩擦界面画像の視覚的特徴が摩擦力に反映されていることが示唆される。また、テストデータに対しても訓練データと同様の傾向が得られており、過学習の兆候は見られなかった。このことから、本モデルは摩擦界面画像から摩擦力を一定の精度で予測可能であり、摩擦状態の把握や異常検知への応用が期待できる。

注目すべき点は、摩擦力の増加に伴って摩擦界面画像の特徴が段階的に変化していることであり、これをモデルが自動的に学習していると考えられる。すなわち、低摩擦力域では界面が比較的均一で明瞭な特徴を示すのに対し、高摩擦力域では摩耗粉の付着や表面構造の複雑化が生じ、画像の濃淡や質感に変化が現れる。CNN はこうした視覚的变化を捉え、摩擦力に応じた出力を生成していると推察される。

以上の結果から、学習データが限定される条件においても、本モデルは焼き付き前後を含む広範な摩擦力変化をおおむね予測可能であり、急激な摩擦状態の変化にも一定のロバスト性を有することが示唆された。このことは、CNN が摩擦現象に内在する非線形性や多次元性を画像から抽出し、統計的に学習できることを示しており、従来の物理モデルでは捉えきれない摩擦特性の理解に資する有用な手段であるといえる。

5. おわりに

本研究では、摩擦界面の画像を用いて摩擦力を推定するための CNN モデルを構築し、焼き付き現象を含む摩擦状態に対しても良好な予測精度が得られることを示した。特に、急激な摩擦力変化を伴う焼き付き現象に対しても、画像情報に基づく学習が可能であることを確認し、摩擦界面画像が摩擦状態の特徴を有していることが示唆された。

また、摩擦力の大小に応じた画像特徴の違いを CNN が捉えていることが、訓練データおよびテストデータにおける予測結果の相関性から明らかとなった。一方で、焼き付き前後の領域においては、短時間の急変動によりデータ数が少なく、予測精度のばらつきも一部で確認された。

今後は、この課題に対応するため、高速度カメラを用いて焼き付き前後の領域の画像取得頻度を高め、この領域における学習データの拡充を図る予定である。さらに、サーモカメラを併用し、温度分布を含むマルチモーダル画像を用いた学習へと拡張することで、摩擦力推定の精度向上と、焼き付きの早期検知への応用を目指す。

文献

- 1) T. Nakahara: A model of seizure based on Burwell and Strang's concept of wear mode transition, In Proceedings of the 31st Leeds-Lyon Symposium on Life cycle tribology, (2005) 547.
- 2) 木之下ら：畳み込みニューラルネットワークを用いた POM 摩擦界面その場観察像からの摩擦力推定，トライボロジー会議 2023 春 東京 B20 (2023).




Fig. 2 Time evolution of the friction force measured in seizure point.




Fig. 3 Frequency Distribution of Friction Force




Fig. 4 Predicted vs measured friction force (training data, epoch 2001).




Fig. 5 Predicted vs measured friction force (test data, epoch 2001).