

機械学習を用いた高温下における摩擦・摩耗特性の予測

Prediction of Friction and Wear Characteristics at High Temperature by Machine Learning

IHI (正) *義久 順一 IHI (正) 小宮山 翔子 IHI (正) 山崎 崇広 IHI (正) 柴田 愛

IHI (非) 斎藤 弘樹 兵庫県立大 (正) 鷺津 仁志

Junichi Yoshihisa*, Shoko Komiyama*, Takahiro Yamazaki*, Ai Shibata*

Hiroki Saitou*, Hitoshi Washizu**

*IHI Corporation, **University of Hyogo

1. はじめに

企業や研究機関には膨大な量の摩擦試験のデータが存在し、これらのデータの活用と試験過程で得られた知見をもとに新たな製品開発のための設計や運用に際して問題となる事象の原因究明と対策がなされてきた。このような取組みの積み重ねを経て、特定の条件においては摩擦・摩耗特性の推定が一定の水準で可能になっている。ただし、全くの未知の条件や材料の場合には、パラメータを振った摩擦試験を実施して、材料の優劣を比較評価する帰納的な過程となり、その効率化のためには研究者の経験知による試験条件や候補材料の絞り込みに個人の技量・勘所を働かせる必要があり、データが最大限に活用されているとは言いにくい。

近年の機械学習の発展は目覚ましく、トライボロジー分野においてもマテリアルズインフォマティクスの取組みが広がっており¹⁾、Tribo-informatics やトライボフォーキャストの言葉が報告中に見られる。Tribo-informatics が初めて用いられたとされる報告内²⁾でその概念が示され、航空機エンジン可変静翼機構の軸受部分を対象に基礎的な摩擦試験により摩擦係数と摩耗量が精度良く予測することが可能であると報告されている。

また、Nosonovsky らの報告³⁾では、アルミ合金のトライボロジー特性に関する論文から材料物性と摩擦・摩耗特性的データセットを整え、複数の機械学習を用いてデータ駆動型のインフォマティクスを行い、摩擦係数と比摩耗量が精度よく予測できることがわかっている。

これらの報告に見られるように、トライボロジー研究のデータ駆動型への転換に向けて様々な取組みが行われております、試験条件や材料物性のビッグデータをAIに学習させ、摩擦係数や摩耗量の予測モデルを構築し、活用することによって、摩擦・摩耗特性に影響する因子が特定されることが期待される。影響因子が特定できれば、例えば特定の材料物性値に着目した材料開発を行う、材料成分や物性値から摩擦・摩耗特性を予測するといったことができるようになり、効率的に製品の最適設計ができる可能性がある。

そこで、筆者らの過去の摩擦試験結果^{4,5)}に材料物性データを追加し、機械学習により予測器を構築して、材料組合せと試験条件から高温下における摩擦・摩耗特性の予測を行った。本報では結果と得られた課題について報告する。

2. 機械学習による予測手法

2.1 学習データ

学習データには過去に筆者らが実施したしゅう動材料の摩擦・摩耗特性の試験データと材料の熱的・機械的物性を用いた。摩擦試験データの取得に用いた高温摩擦試験装置の概略を Fig. 1 に示す。装置は温度制御した電気炉内にて摩擦試験が可能な構造を有し、炉外のモータとロッドの一端が接続され、反対側に錘を付加する。錘により供試体接觸面に荷重を負荷し、モータの運動に合わせて円柱試験片が平板試験片上を往復運動し、供試体同士が摩擦する。試験中の摩擦抵抗をロードセルにより計測した。複数の温度条件のもと、試験中の平均摩擦係数および表面に付着した凝着物の大きさ（凝着高さ、試験後に計測）を試験データとして用いた。

供試体の材質にはステンレス鋼、ニッケル合金を用い、それらは鍛造・鋳造により成形されている。材料物性として、高温雰囲気での材料軟化・酸化に関連する熱特性（比熱、熱伝導率、融点、線膨張係数）および機械強度（密度、引張強度、0.2%耐力、ヤング率、硬さ）、材料組成を用いた。これらの材料物性の全てのデータを欠損なく揃えることは難しく、文献値で補えない部分には熱平衡計算ソフトウェア JMatPro を用いて物性値の温度依存性を予測し、材料物性の欠損値の一部を補完した。

各データを Table 1 に示す。

2.2 予測器の構築と評価

材料物性と摩擦試験の試験条件を説明変数とし、摩擦係数および凝着高さを予測することを目的としている。

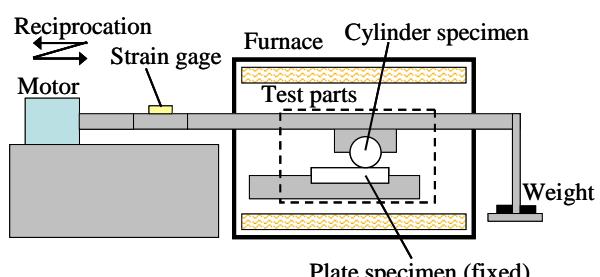


Fig. 1 Schematic of the test rig

Table 1 Explanatory variable

Test conditions	Temperatures (300 ~ 1,000 °C), Load, Sliding speed, Number of cycles, Material combination (7types of materials for Cylinder, 13types of materials for Plate)	
Material characteristics	Mechanical characteristics	Density, Young's Modulus*, Yield strength*, Tensile strength*, Hardness
	Thermal characteristics	Thermal conductivity*, Specific heat*, Melting point, Liner expansion coefficient*

*Characteristics at room temperature and high temperature

材料物性データに欠損があることと摩擦試験自体のデータ数が少ないとから、機械学習において一般に用いられる勾配ブーストと決定木を組合せた学習手法である XGBoost (eXtreme Gradient Boosting) によりパラメータ最適化せずに予測器を作成した。データ点数 64 点に対し、Leave One Out により予測精度を評価した。予測器の精度評価には決定係数 R^2 、二乗平均平方根誤差 RSME を用いた。 R^2 値は 1 から 0 をとり、1 に近いほど回帰直線の説明力があることを示す。また、RSME は線形回帰を最小化する指標で 0 に近いほど誤差は小さいことを示す。

3. 予測結果、評価および考察

XGBoost により平均摩擦係数を予測した結果を Fig. 2 に、凝着高さを予測した結果を Fig. 3 に示す。横軸の実験値に対して縦軸に予測値を示している。平均摩擦係数の予測器の精度は R^2 値が 0.61、RSME が 0.17 であった。また、凝着高さの予測器の精度は、円柱試験片では R^2 値が 0.20、RSME が 34、平板試験片では R^2 値が 0.26、RSME が 41 であった。これらの結果より、平均摩擦係数については一定の精度で予測することができたと評価した。

一方で凝着高さの予測では何れの試験片でも分散が大きく、実測と予測の間に大きなかい離があり、予測器としては不十分である。円柱試験片と平板試験片では平板試験片の方がよりかい離が大きくなつた。

凝着高さ自体は、摩擦過程において摩擦面で凝着とせん断により脱離が繰り返し行われることから、凝着物の形成が試験終了のタイミングに影響を受け、ばらつきやすいが、予測器自体を改善する必要がある。

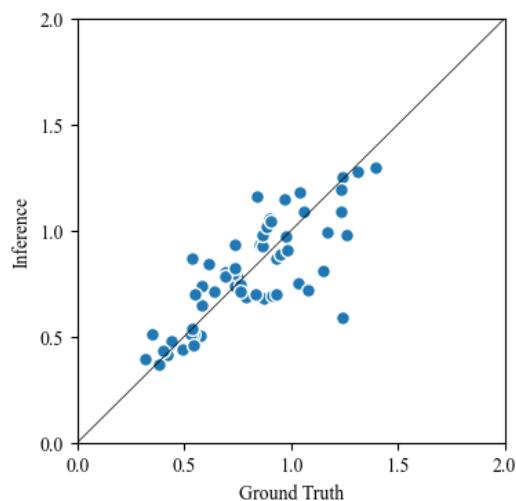


Fig. 2 COF prediction using XGBoost

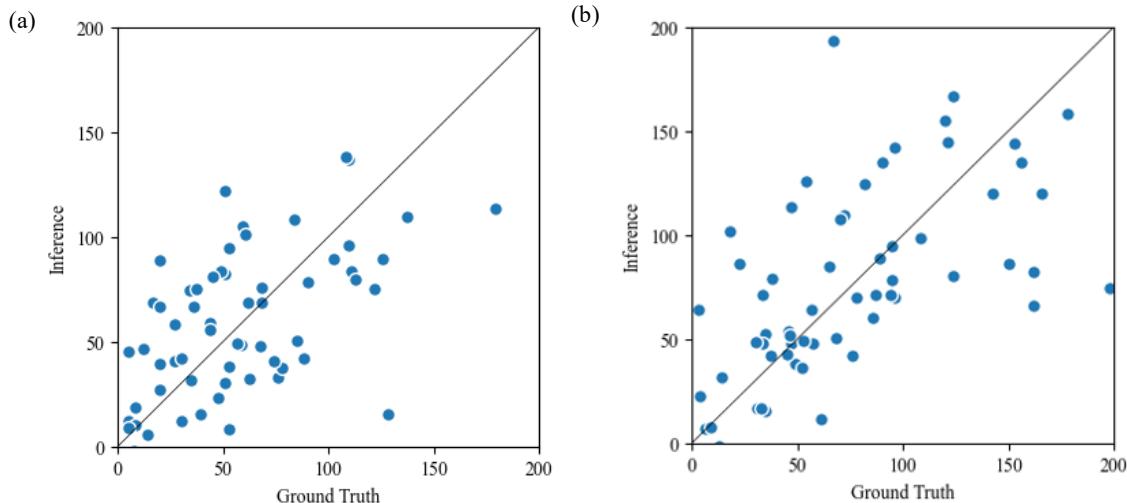


Fig. 3 Height of Adhesion prediction using XGBoost
(a) Cylinder specimen, (b)Plate specimen

4. 課題

過去の試験データを用いて高温中の摩擦・摩耗特性の予測を機械学習により行った。さらに予測精度を向上させていくための現時点における課題を整理した。

4.1 試験データ不足の補完

上述の予測はデータ点数 64 点で実施したが、材料物性の欠損のために機械学習に使用できなかったデータが存在する。欠損データ取得はデータ補完の確実な方法である。さらに、大量のビッグデータを集めることによってデータ駆動型の機械学習が実現できれば、データ欠損の影響を小さくすることができると考えられるが、一社単独では難しく複数の機関の協力体制構築が必要となる。複数機関の協力のためには企業間でのデータの秘匿性維持がボトルネックとなるが、データの秘匿性は維持しながら予測モデルのみを共有する連合学習という手法⁶⁾があり、他の分野では実施例もみられる。この枠組みをトライボロジー分野に転用できれば、ビッグデータを用いたデータ駆動型の Triboinformatics が実現できると考えられる。

4.2 物理モデルの導入

予測に用いた説明変数は Table 1 に示すように試験条件と強度と熱特性に関する材料物性である。高温環境において金属材料は熱で軟化し、摩擦面は酸化が進む中でせん断が加わり、凝着摩耗が進行すると考えられる。これらの実現象に関連する例ええば酸化膜の物性を説明変数とすることを検討していく必要があると考えられる。

4.3 材料物性のデータセットの整備

多くの材料データが必要となるため、多くは論文や文献から取得する。物質・材料研究機構の MatNavi や Materials Project などの公共のデータベースが充実しているが、今後、4.1 に記載の活動と並んでトライボロジー用途のデータベースの整備が進むことを期待する。

5. まとめ

摩擦試験データと材料物性を用いて、高温下における摩擦係数と凝着高さを機械学習により予測器を構築し、予測精度を評価した結果、平均摩擦係数については一定の精度で予測ができた一方で、凝着高さについては予測精度改善の課題が残った。また、予測精度を向上させるための課題を整理した結果、試験データ不足の補完、物理モデル導入、材料物性のデータセット整備を考慮していく必要があると考えられる。これらの課題に対応するためには一社だけではなく複数の機関との連携を模索していくことが重要である。

謝辞

本研究を遂行するにあたり機械学習による予測と結果についての議論にご協力いただいた兵庫県立大学の深谷剛君と堀尾巴人君に深く感謝いたします。

文献

- 1) M. Marian & S. Tremmel: Current Trends and Applications of Machine Learning in Tribology-A Review, *Lubricants*, 9, 86 (2021)
- 2) Z. Zhang, N. Yin, S. Chen, C. Liu : Triboinformatics: Concept, architecture, and case study, *Friction*, 9 (2021) 642-655
- 3) S. Hasan, A. Kordjazi, P. K. Rohatgi, M. Nosonovsky: Triboinformatic modeling of dry friction and wear of aluminum base alloys using machine learning algorithms, *Tribology international* 161 (2021) 107065
- 4) 義久, 斎藤, 佐分, 高橋, 堀内, 山崎, トライボロジー会議予稿集 (鳥取 2004-11) 203
- 5) 義久, 佐分, 高橋, 堀内, 山崎, トライボロジー会議予稿集 (鳥取 2005-11) 117
- 6) 米谷, 連合学習入門, 精密工学会誌, 8, 87 (2021) 662-665