

# 機械学習を用いた高温摩擦・摩耗特性の予測における材料種の影響

## Influence of Material Types on Predicting High-Temperature Friction and Wear Characteristics Using Machine Learning

IHI (正) \*柴田 愛    IHI (正) 義久 順一    IHI (正) 山崎 崇広  
IHI (非) 斉藤 弘樹    IHI (非) 宮澤 優斗    兵庫県立大 (正) 鷲津 仁志

Ai Shibata\*, Junichi Yoshihisa\*, Takahiro Yamazaki\*

Hiroki Saito\*, Yuto Miyazawa\*, Hitoshi Washizu\*\*

\*IHI Corporation, \*\*University of Hyogo

### 1. はじめに

高温環境下で稼働するジェットエンジンや車両過給機等の回転機械のしゅう動部では、過酷な条件下での摩擦・摩耗が問題となる場合が多く、低摩擦な材料や表面処理の適用による対策がとられている。一般に、しゅう動材料の摩擦・摩耗特性を把握するためには摩擦試験の実施が不可欠であり、解析や計算のみでしゅう動材料を選定することは困難である。近年、Tribo-informatics<sup>1,2)</sup>と呼ばれる、過去に取得してきた膨大な摩擦試験データを活用する取組みが広がっており、機械学習を用いて摩擦・摩耗特性を予測できる可能性が示唆されている。筆者らは、しゅう動材料の選定効率を向上させることを目的に機械学習により高温環境下の摩擦・摩耗特性を予測してきた。既報<sup>3)</sup>ではNi基合金の相手材を13種のNi基合金および鉄鋼材料としたときの摩擦係数を予測し、予測に高温の熱特性や硬さに関連するMo含有量、融点、試験温度等のパラメータが重要であることを明らかにした。今回は、材料種の違いが摩擦・摩耗特性の予測に及ぼす影響について調査すべく、鉄鋼材料を対象に予測器を構築し、予測に重要なパラメータを分析した結果を報告する。

### 2. 機械学習による予測手法

#### 2.1 試験データ

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。試験装置は電気炉内で試験片同士を接触させた状態で高温雰囲気での摩擦が可能である。炉外に錘をかけて試験面に荷重を負荷し、モータにより円柱試験片側を往復運動させ、2面間に摩擦を生じさせる。試験中の摩擦抵抗をロードセルにより計測し、しゅう動開始から終了までの動摩擦係数の平均値を求め平均摩擦係数とした。試験条件は、温度 25～1000℃、荷重 11N、しゅう動速度 10cycle/min、往復しゅう動回数 100cycles とした。円柱試験片 (φ12×20mm) と平板試験片 (12×35×6mm) には、10種類の鉄鋼材料を用い、計 36 点の試験データを取得した。




Fig. 1 Schematic of the Test Rig

#### 2.2 予測器の構築

予測アルゴリズムには、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) を用い、Leave One Out 法により交差検証を実施した。

説明変数には、Table 1 に示す材料物性および化学組成を用いた。材料物性 (熱伝導率、線膨張係数、ヤング率、0.2%耐力、引張強度) は試験温度における値を使用し、文献により整備した。欠損値の一部は熱平衡計算ソフトウェア JMatPro (Sente Software 社) を用いて温度依存性を予測することで補完した。

予測精度は、決定係数  $R^2$  および二乗平均平方根誤差 RMSE (Root Mean Square Error) を用いて評価した。 $R^2$  値は 1 に近いほど回帰直線の説明力があることを示し、RMSE は目的変数と同じ単位で誤差の大きさを表す。ここでの予測精度は Leave One Out 法による交差検証の結果であるため、予測結果の各点の予測モデルがそれぞれ異なるという点に注意が必要である。さらに、全試験データを用いて機械学習させたモデルに対して特徴量の重要度 (F スコア) を算出し、さらに特徴量寄与度を SHAP (SHapley Additive exPlanations) により分析した。F スコアは特徴量が XGBoost の分岐に使用された回数と予測誤差の減少効果に基づいて算出され、F スコアが高いほど予測器がその特徴量に依存していることを表す。SHAP はその特徴量を無くすことによる予測値の変化により算出され、その特徴量が予測値を増加させるか減少させるかを理解することができる。

Table 1 Explanatory Variable

Test Conditions	Temperatures (300 ~ 1000°C), Load (11N)	
Material Characteristics	Thermal Properties	Thermal Conductivity*, Melting Point, Linear Expansion Coefficient*
	Physical and Mechanical Properties	Density, Young's Modulus*, Yield Strength*, Tensile Strength*, Hardness
	Chemical Composition	Fe, C, Si, Mo, Ni, Cr, Mo, Ti, Al, Co etc... (20 Elements)

\*Characteristics at Test Temperature

### 3. 予測結果と考察

鉄鋼材料を対象に高温しゅう動下の平均摩擦係数を予測した結果を、横軸に実験値、縦軸に予測値として Fig. 2 に示す。平均摩擦係数の予測器の精度は  $R^2$  値が 0.63, RMSE が 0.14 であった。これは、特徴量が平均摩擦係数を概ね説明できていることを示す。

特徴量の重要度 (F スコア) を Fig. 3 に示す。F スコアから、既報の平板の Mo 含有量や試験温度、平板の融点よりも平板の C 含有量や室温硬さ、線膨張係数のパラメータが重要であることがわかった。予測に用いた鉄鋼材料には Mo は多く含まれないため Mo 含有量の重要度が低いことは妥当である。また、他のパラメータについては材料の硬さおよび高温における軟化に関連するパラメータが重要であると読み取ることができる。SHAP による寄与度分析の結果、平板試験片の C 含有量が多いほど、また、平板試験片の室温硬さが硬いほど平均摩擦係数は低くなる傾向が認められた。これは、硬い材料ほど単位荷重あたりの真実接触面積が小さくなり摩擦係数が低下するという既存の知見<sup>4)</sup>と関連しており、さらに、C 含有量の多い材料では、材料中の炭化物による硬度向上が平均摩擦係数の低下に寄与していると考えられる。




Fig. 2 Predicting Average Coefficient of Friction




Fig. 3 Feature Importance

### 4. まとめと課題

鉄鋼材料を対象に高温しゅう動下で平均摩擦係数の予測器を構築した結果、試験条件や材料物性、化学組成により概ね予測可能であった。予測に重要なパラメータは材料種で異なるものの、材料の硬さおよび高温における軟化に関連する項目が共通して重要であった。さらに、SHAP による分析から、C 含有量が多く硬質なほど平均摩擦係数が低くなる傾向が示され、既存の知見と合致する結果であった。

### 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藤田 晃徳君と柏原 祥人君に深く感謝いたします。

### 文献

- 1) M. Marian & S. Tregmel: Current Trends and Applications of Machine Learning in Tribology-A Review, Lubricants, 9 (2021), 86.
- 2) Z. Zhang, N. Yin, S. Chen, C. Liu : Tribo-informatics: Concept, architecture and case study, Friction, 9 (2021), 642-655.
- 3) 柴田・義久・小宮山・山崎・斉藤・宮澤・鷲津：トライボロジー会議予稿集（秋 名護 2025-10）, 533-534.
- 4) Bowden, F.P. and Tabor, D., The Friction and Lubrication of Solids, Oxford University Press, 1950, Chapter 2, 24-57.