

機械学習を用いた高温下における摩擦・摩耗特性の予測と評価

Prediction and Evaluation of Friction and Wear Properties at High Temperatures  
Using Machine Learning

IHI（正）\*柴田 愛    IHI（正）義久 順一    IHI（正）小宮山 翔子    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\*, Shoko Komiyama\*, Takahiro Yamazaki\*

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

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

1. はじめに

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必要であり、設計段階においてしゅう動材料を選定する場合、経験知や個人の勘所により効率が大きく左右される。トライボロジー分野において、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（Tribo-informatics<sup>1,2)</sup>）が広がっており、機械学習を用いて摩擦・摩耗特性を予測することで、効率的に製品の最適設計ができる可能性がある。筆者らは既報<sup>3)</sup>において、高温下の金属材料の摩擦・摩耗特性を予測することを目的に、100点未満の少ない試験データを用いて機械学習による予測器を構築した。本研究では、予測器の使用目的に合わせて目標精度を設定し、目標達成のために必要な試験データ数について調査した。

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 および 30N、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、18 種類の鉄鋼材および Ni 基合金を用いた。




Fig. 1 Schematic of the Test Rig

2.2 予測器の構築

平均摩擦係数を予測するため、試験データ 80 点を用いて Leave One Out 法により公差検証を実施した。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）を用いた。

説明変数には、Table 1 に示す高温雰囲気での材料物性および化学組成を用いた。材料物性（熱伝導率、融点、線膨張係数、引張強度、0.2%耐力、ヤング率、室温硬さ、密度）は文献により整備したが、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  $R^2$  を、予測誤差は二乗平均平方根誤差 RMSE 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、RSME 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 法による公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。

Table 1 Explanatory Variable

| Test Conditions          | Temperatures (25 ~ 1000℃), Load (11, 30N) |   |
|--------------------------|---|---|
| Material Characteristics | Thermal Properties                        | Thermal Conductivity*, Melting Point, Liner 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

平均摩擦係数の予測結果を、横軸に実験値、縦軸に予測値として Fig. 2 に示す。予測精度は  $R^2$  値が 0.81 であり、概ね予測できていると評価できる。予測誤差は RMSE が 0.12 で試験平均誤差約  $\pm 0.05$  に比べ誤差は大きい。例えば、しゅう動材料選択時のスクリーニングに使用し、候補を絞り込んだ上でしゅう動試験により確認試験を行うことで効率的にしゅう動材料の選択が可能となると考えられる。もう一段階進んで、しゅう動試験が不要となるまで高精度に予測するには、より多くの試験データの追加が必要になると考えられる。

そこで、試験誤差と同等の RMSE0.05 を目標とする場合を想定し、必要な試験データ数を調査した。Fig.3 に試験データ点数と予測精度および予測誤差の関係を示す。これは、試験データ数が任意の数になるように母数からランダムに 5 回データを抜き出して予測し、その予測スコア  $R^2$  値および RSME の平均を算出したものである。この結果から、予測誤差を小さくするには膨大な試験データが必要であると推測され、目標精度の実現は難しいことがわかった。これは、目標精度に対して試験データの誤差が大きく、学習に限界があるためであると考えられる。

予測精度を目標精度に近づけるためには、学習させる試験データ数を増やすだけでなく質の向上が必要であり、予測誤差が大きいしゅう動材料の組合せに着目して関連の試験データを学習させること、異常値を除去することが有効である。また、予測に有効な説明変数を見つけ出す取り組みも重要である。




Fig. 2 Predicting the Average Coefficient of Friction




Fig. 3 Relationship between Number of Data and Prediction Accuracy

### 4. まとめと今後の展望

100 点未満の少ない試験データ数でも、機械学習により高温しゅう動下の摩擦特性を概ね予測できることがわかった。また、試験データ数と予測精度の関係から、予測の目的によっては膨大な数の試験データが必要となり得ると推測された。設計における実用性を考慮すると、摩擦特性だけでなく摩擦特性の予測も重要である。今後は、摩擦特性の予測で得られた知見を活用し、摩擦特性の予測に取り組んでいく。

### 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. Tremmel: 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) 義久・小宮山・山崎・柴田・斉藤・鷲津：トライボロジー会議予稿集（春 東京 2024-5）, 21-23.