

# 機械学習における学習データの最適化法とそれを用いたしゅう動面状態監視法

## Optimization method of learning data in machine learning and moving surface condition monitoring method using it

福井大・工（正）\*本田 知己 福井大・工（非）下方 康弘

Tomomi Honda, Yasuhiro Shimokata

University of Fukui

### 1. 緒言

機械設備の故障の多くはそれを構成する機械要素の摩耗に起因することが報告されており、将来に向けた設備診断法として、機械要素の表面状態を監視・診断し、それに基づいて保全することが極めて重要であると言える。著者らは、模擬汚損油中で摩擦摩耗試験を行い、複数のセンサから得られる測定データをもとに機械学習を行うことでしゅう動面の異常を検知できること、さらに、学習方法の最適化手法において  $k$  分割交差検証により適切な学習区間を選定することで異常検知の精度を向上できることを明示した<sup>(1)</sup>。本報では、より実環境に近い条件での異常を模擬するため、模擬汚損油を用いるのではなく、時間の経過のみでしゅう動面が寿命に至るように設定された条件下で行った試験データに対して機械学習を援用した解析を行い、定常運転下で発生する異常を自動で検知するシステムの構築と学習方法・学習前データ処理方法の最適化について検討した。

### 2. 試験方法および供試材料

回転するリング試験片外周面に固定したブロック試験片を押し付けて摩擦させるブロック・オン・リング方式のすべり摩擦試験を行った。本試験機は片当たりを抑制するために首振り機構が設けられており、試験片同士が常に線接触する。潤滑方法はリング試験片の側面に給油し、リングの回転と油の粘性を利用して潤滑させる、かきあげ潤滑方式を採用した。潤滑油は試験部の下部に設けられたオイルバスに溜まりポンプで循環される。潤滑油はオイルタンクから静電浄油機を介して循環されるため、しゅう動面には摩耗粒子を含まない清浄な潤滑油が常に供給される。試験条件を表 1 に示す。初期荷重として 300 N 負荷し、300 秒(1800 m)ごとに荷重をステップ状に 300 N ずつ、1500 N まで負荷した。その後 1500 N で約 100 km しゅう動した後、試験を終了した。潤滑油には基油に粘度指数向上剤のみが添加されたパラフィン系鉱物油を用いた。試験中に、摩擦係数、試験片温度、AE 値および半径方向・周方向加速度、インバータ出力電流値、オンライン・パーティクルカウンタによる摩耗粉の粒径および粒子数を同時に測定した。ブロック試験片にはすべり軸受材料 WJ2(ホワイトメタル第 2 種)、リング試験片には S55C を用いた。試験片の接触面にはラッピングによる鏡面研磨が施された。

Table 1 Test conditions

Load, N	300 → 1500
Sliding velocity, m/s	6.0
Test time for running-in, sec.	300
Lubricating oil	Paraffinic oil
Oil temperature, °C	60±2
Kinematic viscosity@60 °C, mm <sup>2</sup> /s	10.37

### 3. 機械学習による解析システムと学習データの最適化

機械学習によるデータ解析には、アダコテック社の AdaMonitor を用いた。このプログラムは複数のデータを一括処理してスカラー化できるため、正常・異常の判別が容易に行える特徴があり、正常なセンサデータの学習およびしきい値の設定を行うことで、正常から外れた現象の検知を可能とする。

本測定データのように、現象の事象と出力値が一对一に対応する突発型のデータ評価には計数処理が有効であることから、異常検知にも有用な処理であると考えられる。しかしながら、単位時間あたりに設定されたしきい値を超えた数を計測する計数処理を施すことで一定の時間間隔ごとの不連続なデータになるため、機械学習に適用するにはこれらにもデータ補間処理を施す必要がある。ここでは計数処理データや計測システム上一定の間隔で計測することが困難なオンライン・パーティクルカウンタ、インバータ出力電流値に線形的な補間処理を施した。

各パラメータの寄与度の比較には、縦軸に True Positive Rate(TPR)、横軸に False Positive Rate(FPR)としてプロットすることで得られる ROC 曲線(Receiver Operating Characteristic curve)の曲線下面積(Area Under The Curve, AUC)で比較した。

### 4. 試験結果および考察

#### 4・1 すべり距離に伴う測定データの変化

すべり距離に伴う各測定データと荷重の変化を図 1 に示す。摩擦係数、試験片温度および摩耗粉粒子数の挙動からすべり距離 10 km 付近でなじみが完了したと推察される。すべり距離 40 km 付近で摩擦係数と試験片温度が上昇した後に両者ともに低下した。これは、すべり距離 40 km 付近で一時的に焼付きが生じたものの、焼付きに伴う温度上昇によってしゅう動面が軟化・平滑化し、再び定常状態に戻ったと考えられる。一方で、図 1 よりこれらの変化をインバータ出力電流や AE 値、加速度電圧値の測定データから人が判断することは困難であることがわかる。

## 4・2 各パラメータの寄与度

機械学習に使用する各パラメータが異常検知精度に与える影響を調べるため、摩擦係数および包絡線検波の処理を施していないAEの原波形信号(以下、AE RF)から得られる学習結果とそれに各測定パラメータ1つを加えることで得られる学習結果を比較した。摩擦係数とAE RFのみを使用したAUC 0.564を上回る場合、そのパラメータは摩擦係数とAE RFによって算出される異常検知に対して異常検知精度の向上に寄与し、逆に下回る場合は、異常検知精度の低下を招くことを示す。摩擦係数とAE RFに加えた各パラメータのAUCを図2に示す。図中の(Step)はステップ状補間を、(Linear)は線形的補間を示す。突発型の波形を出力するAE値および加速度において、いずれも1分間ごとに計数処理を施してデータ間を線形的に補間したデータを追加したAUCが高い値を示した。また、粒子数においても線形的に補間したデータのAUCが高くなっていることから、補間処理においてステップ状補間に比べ線形的補間が異常検知に適したデータ処理であることがわかった。

## 4・3 機械学習による異常検知

機械学習に使用するデータは、図2に示す各パラメータの寄与度より、それぞれ1分間毎の計数処理を施したAE包絡線検波信号、半径方向・周方向加速度電圧値および線形補間処理を施した8-16  $\mu\text{m}$ と17-100  $\mu\text{m}$ の粒子数データの5つを用い、摩擦係数を用いなかった。しゅう動面の状態を把握する上で摩擦係数は非常に重要であるが、実機環境下において摩擦係数を測定することは困難であるため、ここではあえて学習データから外した。図3から、異常値が学習データとして使用していない摩擦係数の挙動を捉えられていることから、現場において計測が困難な摩擦係数や接触面温度などの測定データを必要とせず、異常診断が可能であると推察される。実際の異常診断にはしきい値を設けることで異常を判定するが、今回の学習結果においてもしきい値を設けることで、すべり距離40 km付近で発生したと考えられる焼付きの前兆を検知し、異常の早期発見が可能になることが示唆された。

## 5. 結 言

- (1) 各パラメータの寄与度をAUCにより比較することで、異常検知精度の向上に対して突発型の信号が得られるセンサ測定値の計数処理が有効であること、また、データの補間方法として線形的な補間が適していることがわかった。
- (2) 各パラメータの寄与度および学習区間の選定から判断した最適な方法で学習を行なった結果、実環境化において測定が困難である摩擦係数や接触面温度を必要としない、異常検知の可能性が示された。

## 参考文献

- (1) 橋本優花, 本田知己, 他4名: 日本機械学会論文集, 84, 868 (2018) 18-00275

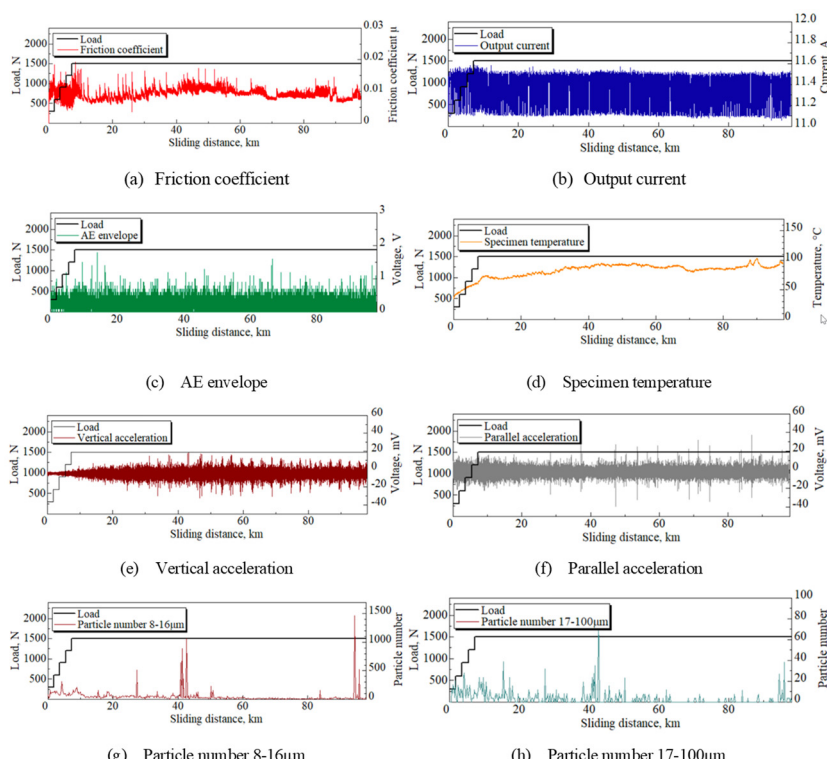


Fig.1 Variation of each parameter and load as a function of sliding distance




Fig.2 Contribution of each parameter by AUC




Fig.3 Friction coefficient and abnormality index by machine learning