

IoT・機械学習を活用した機器の稼働状態評価（第2報）

機械電子科 太田幸宏

Operation status evaluation of equipment using IoT and machine learning (2nd Report)

OHTA Yukihiko

The purpose of this research is to retrofit IoT to equipment that has been in operation for a long period of time and to construct an operation diagnostic model using the Maharanobis-Taguchi (MT) method. Regarding the ability of the MT method to determine whether operation is normal or not, it is shown that this method is more capable of making judgments compared to two other machine learning clustering methods. In addition, for the operation diagnosis of motors that are often used in factories, the operation diagnosis model is trained using vibration data during normal operation acquired by retrofitting IoT to electric fans, and is able to set appropriate judgment thresholds even without vibration data during abnormal operation. We show that the amount of calculation required can be reduced by applying factor-effect analysis.

Keywords:IoT(Internet of Things), machine learning, MT method

本研究は、長期稼働している機器に後付け IoT 化を行い、MT法で稼働診断モデルを構築することを目的としている。MT法の正常稼働か否かを判別する能力について、他の機械学習のクラスタリングの2つの手法と比較して、この手法が高い判別能力があることを示す。また、工場で多用されているモータの稼働診断として、扇風機に後付け IoT 化して取得した正常稼働時の振動データで学習した稼働診断モデルで、異常稼働時の振動データがなくても適切な判定閾値が設定できること、さらに、要因効果解析を適用することで計算規模の縮小ができることを示す。

キーワード：IoT (Internet of Things)、機械学習、MT法

1 はじめに

生産現場で長時間稼働する設備を保全するには、作業員が現場で日常的に点検する必要がある。また、一旦、不具合が発生すると修理が終わるまで生産ができないため、多大な損失が生じる。そのため、僅かな予兆を即座に診断する技術が求められている。

そこで、長期稼働する機器に対してセンサーと通信モジュールからなる IoT デバイスを後付けし稼働状態の見える化を行い、取得したデータを学習した稼働診断モデルで長期稼働する機器の稼働状態が正常か否かを診断する技術の開発を行った。今回、稼働診断に用いる機械学習は、長期稼働している機器から容易に大量に取得可能な正常稼働時のデータのみで学習ができるMT（マハラノビス・タグチ）システムのひとつMT法を適用した¹⁾。この手法は、多変量解析に品質工学の理論を融合させたもので、多入力-出力の数値モデルを構築する。この出力値のことをマハラノビスの距離という。第1報では、

市販されている小型 IoT デバイスで、扇風機のモータの回転により発生する振動を計測し、その振動データからMT法により稼働状態の評価を行った²⁾。第2報では、MT法と他機械学習を比較してこの手法の判別能力の優位性を示し、さらに、MT法の特徴を利用した判定閾値の設定及び要因効果解析による計算時間の短縮について示す。

2 方法

2.1 機械学習の判別性能の比較

機械学習は、回帰、分類、クラスタリングの三つに大別できる³⁾。本研究の目的は、長期稼働する機器の稼働状態が正常か否かを診断するシステムの構築であり、分類を使用するのが適当と考えられる。しかし、分類の数値モデルの学習には、異常稼働時のデータが大量に必要であり、その取得は困難である。そこで、クラスタリングの手法を使用して、あるグループのデータのみで数値モデルを学習し、学

学習済み数値モデルに別グループのデータを入力したとき、学習に使用したグループではないと判別する性能について、MT法とK-means クラスタリング、混合ガウス分布 (GMM) クラスタリングの3種類で比較した。学習に使用するデータセットは、プログラミング言語 Python の機械学習ライブラリ scikit-learn の wine データセットを用いた。このデータセットは、表1の13項目からなる3種類のワインのデータで、データ数は178個である。図1に各入力の散布図を示す。図1を俯瞰して見てもヒストグラム、分布図ともに特徴的なピークは見られず、3種類のデータを容易に分類できないことが確認できる。判別用に入力するデータは、学習に使用したデータの平均値と標準偏差で基準化した。判定閾値は、学習済み数値モデルに学習に使用したデータを入力させたときの出力値の平均値 m と標準偏差 σ を求め、 $m + 3\sigma$ の値とした。

表1 wine データセットの入力項目

No.	入力項目
1	alcohol (アルコール度数)
2	malic_acid (リンゴ酸)
3	ash (灰分)
4	alcalinity_of_ash (灰分のアルカリ度)
5	magnesium (マグネシウム)
6	total_phenols (全フェノール含量)
7	flavanoids (フラボノイド)
8	nonflavanoid_phenols (非フラボノイドフェノール)
9	proanthocyanins (プロアントシアニン)
10	color_intensity (色の濃さ)
11	hue (色相)
12	od280/od315_of_diluted_wines (希釈ワイン溶液の OD280/OD315)
13	proline (プロリン)

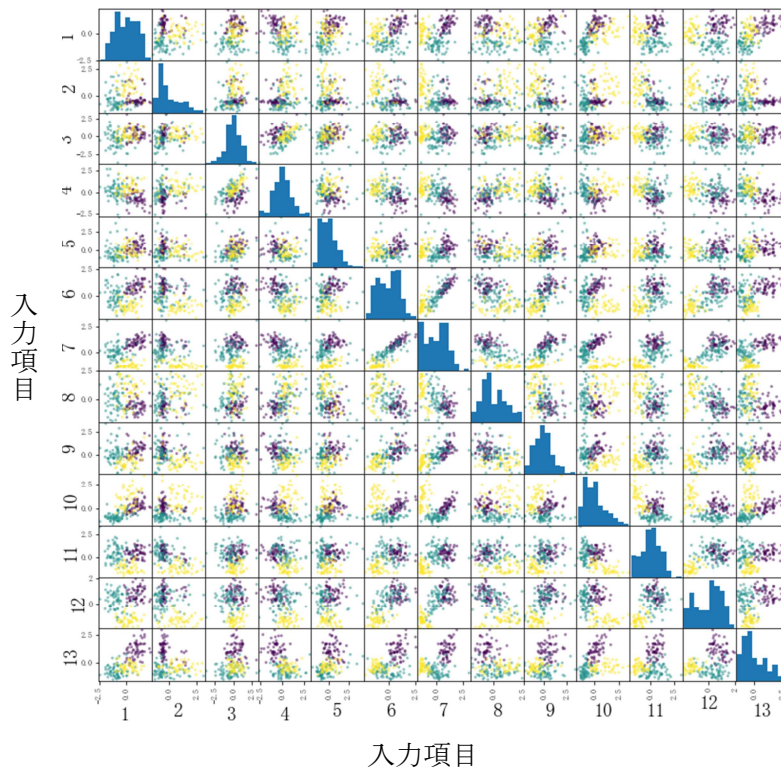


図1 wine データセットの各入力の散布図

● : ワイン1 ● : ワイン2 ● : ワイン3
 対角のグラフは各入力のヒストグラム


2.2 モータの稼働診断

工場で多用されているモータについて、MT法を用いて稼働診断するシステムを構築することを目標として、異常稼働状態を実験できる扇風機のモータを診断対象にしてシステムを構築した。このシステムでは、モータの回転により発生する振動データからモータの稼働状態の診断を行う。振動計測には、無線通信機能と慣性計測ユニットが搭載された小型 IoT デバイス「M5StickC Plus (M5Stack 製)」を使用した。計測した振動データはパソコンに送信し、モータの稼働状態を評価した。サンプリング周波数 1kHz で 0.5 秒間計測した振動データは、周波数データに変換後、周波数軸を 100Hz 間隔の 5 つの領域に分割し、その領域に描画されるグラフの重心位置の値を MT 法の入力とした⁴⁾ (図 2)。したがって、このシステムでは 10 入力 1 出力の数値モデルとなる。


MT 法を機器の稼働状態の診断に用いると、以下の 3 つの特徴を利用できる。

- ・ 正常稼働している機器から取得できるデータだけで稼働診断モデルの学習が可能
- ・ 正常稼働か否かの判定閾値は、学習済みモデルに正常稼働時のデータを入力すると χ^2 分布となることを利用して容易に設定可能
- ・ 各入力の出力値への寄与度を解析できるため、正常稼働ではないと判定したとき、出力値を大きくしている入力項目の特定が可能

本研究では、図 3 のように扇風機の羽根の一枚におもり (0.1g) を 1 個から 3 個付加して稼働させたときの振動データ (W1、W2、W3) が、正常稼働時のデータ (W0) ではないと診断できるか検証した。そのとき、稼働判定に使用する閾値は、数値モデルの入力数と同じ 10 を自由度とする χ^2 分布で 5% を占める値を設定した。また、要因効果解析することで、稼働診断に寄与していない入力項目を検出し、その入力項目を削減することで、計算時間を削減しても同様な稼働診断ができることを検証した。



(1) 振動データ



(2) 周波数データ

図2 入力の前処理

×:各領域のグラフの重心位置




図3 振動計測風景

- : 小型 IoT デバイス
- : おもり付加位置

3 結果および考察

3.1 機械学習の判別性能の比較

図4にワインの種類毎にMT法による13入力1出力の数値モデルを学習させ、そのモデルに全ての種類のデータを入力したときの出力値の分布と、表

2に判定閾値を、表3に正解率を示す。表3に示したように、入力項目の相関関係を考慮したMT法はどの学習データを用いても正解率が最も高く、特にワイン2でその差は顕著であった。

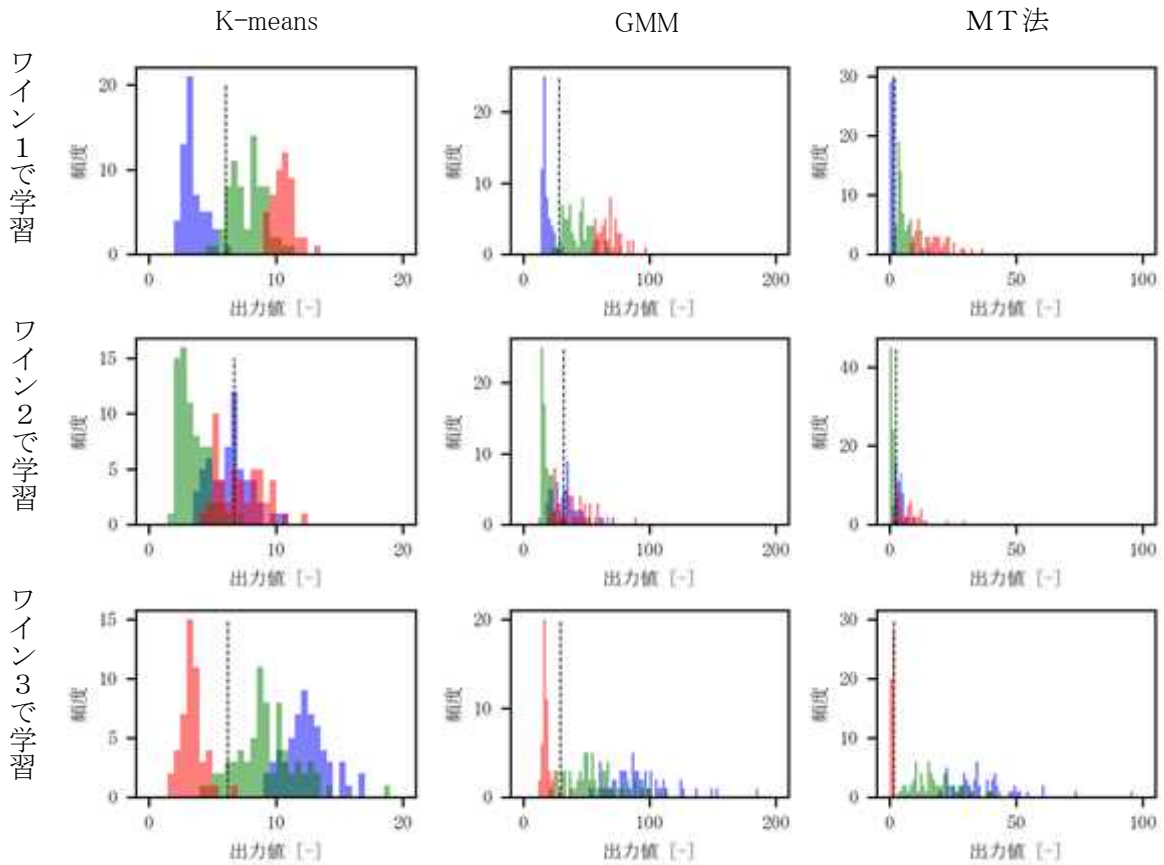


図4 各機械学習の出力分布

■ : ワイン1データの出力、 ■ : ワイン2データの出力、 ■ : ワイン3データの出力、 -- : 判定閾値

表2 判定閾値

機械学習	モデル学習に使用したデータ		
	ワイン1	ワイン2	ワイン3
K-means	6.071	6.760	6.248
GMM	28.577	32.154	29.670
MT法	2.006	2.499	1.953

表3 正解率

機械学習	モデル学習に使用したデータ		
	ワイン1	ワイン2	ワイン3
K-means	96.1	68.0	94.4
GMM	97.2	74.7	96.1
MT法	98.3	91.0	100.0

3.2 モータの稼働診断

ここで用いる判定閾値は、3.1 と異なり、MT法の特徴のひとつである学習済み数値モデルに正常稼働時のデータを入力すると入力項目数と同じ自由度の χ^2 分布になることを利用して設定した。今回、この χ^2 分布で赤い領域の5%を占める値 18.31 とした (図5)。




図5 判定閾値の設定

■ : W0 (正常)
 - : χ^2 分布 - : 判定閾値

この判定閾値で稼働診断結果を図6に示す。おもりを付加したときの振動データの数値モデルの出力値が、おもりを付加していないときの振動データのみで設定した判定閾値を用い、すべて異常稼働であると診断できた。




図6 稼働判定結果

■ : W0 (正常) ■ : W1 (異常)
 ■ : W2 (異常) ■ : W3 (異常)

2水準系直交表 L16⁵⁾ を用いて、要因効果解析した結果を各入力の寄与度として図7に示す。図中の寄与度が高い2つの赤い領域の入力項目1、2、5、6の4つで再度数値モデルの学習及び診断をした結果を図8に示す。この結果から、入力数を削減しても削減前と同様に稼働診断できることが確認できた。この要因効果解析は、数値モデルの出力値を大きくする入力項目を見つけることができるため、今回の事例と異なる稼働診断する機器の各所の温度、圧力、電力などを入力項目とした場合、異常稼働と診断したときに寄与度が大きな入力項目をセンシングしている箇所が不具合を発生していると推測できる。




図7 異常稼働データの入力毎の寄与度

■ : W1 ■ : W2 ■ : W3




図8 入力項目削減した稼働判定結果

■ : W0 (正常) ■ : W1 (異常)
 ■ : W2 (異常) ■ : W3 (異常)

4 まとめ

長期稼働機器の稼働診断に適用したMT法が、K-means クラスタリングとGMMクラスタリングと比較して、高い判別能力があることを確認した。

また、モータの稼働診断にMT法を適用し、正常稼働時のデータのみで学習した数値モデルで、想定できる正常稼働時のデータ分布から設定した判定閾値を使って正常稼働か否かを高い確率で診断できることも確認できた。MT法では、2水準系直交表を用いて要因効果解析をすることで、数値モデルの入力項目を削減しても同様に稼働診断できるため、計算規模の縮小や不具合要因の解明にも有効である。

参考文献

- 1) 鈴木真人：「試して究める！品質工学 MT システム解析法入門」，初版（日刊工業新聞社，東京）（2012）.
- 2) 太田幸宏：IoT・機械学習を活用した機器の稼働状態評価（第1報）. 静岡県工業技術研究所研究報告，第16号，123-124（2023）.
- 3) 毛利拓也 他：「scikit-learn データ分析実践ハンドブック」，初版（秀和システム，東京）（2019）.
- 4) 鈴木真人：「MT法を用いたFFT重心監視」による信号監視システムの提案. 品質工学会誌，26（6），pp. 16-22（2018）.
- 5) 鶴田明三：「これでわかった！超実践 品質工学」，初版（日本規格協会，東京）（2016）.