

製造プロセスにおける予知保全

時系列データの異常検知技術の構築

新井宏章・青柳大志*・狩野幹大*

Predictive maintenance in the manufacturing process
Construction of anomaly detection technology for time-series data
ARAI Hiroaki, AOYAGI Hiroshi and KANO Motohiro

製造設備の予知保全を行うため、正常状態のデータから異常検知を行う技術を構築した。製造現場では様々なデータや不良の発生が考えられるため、代表的なデータに対して様々な異常検知モデルを適用した。その結果、データの性質に応じて適切なモデルを選択する必要があることが分かった。

キーワード：予知保全、異常検知、k近傍法、自己回帰モデル、特異スペクトル変換、ホテリングT²、混合ガウス分布、サポートベクターマシン、オートエンコーダ

In order to perform predictive maintenance of manufacturing equipment, we built technologies to detect anomalies from data of normal conditions. Since various data and defects can occur at factory, so we applied different models for anomaly detection to representative data. As a result, we found that it is necessary to select an appropriate model according to the nature of the data.

Keywords: predictive maintenance, anomaly detection, k-nearest neighbor method, autoregressive model, singular spectrum transformation, Hotelling's T-squared distribution, Gaussian mixture distribution, support vector machine, autoencoder

1 はじめに

故障などのトラブルにより製造設備が停止すると納期の遅延につながるため、時間とコストをかけても定期保全（メンテナンス）を行う必要がある。しかし、保全時期より前に故障することや、まだ使える部品を交換することから無駄が生じることが多い。

そこで本研究では予知保全システムを開発することを目的とする。予知保全は現在の状態から故障までの残存期間を算出し、事故や不良を未然に防止する方法である。

予知保全を行うには段階がある。

- ① 現在、正常に機能しているか把握する（異常検知）。
- ② 故障に至るまでの時間を予測する。

今年度は基礎技術である①について取組んだ。製造現場に異常検知を適用するにあたり、

異常状態のデータを収集することは時間及びコストの観点から現実的ではない。そのため、正常状態のデータから異常検知する技術構築を目標とした。また、本研究では既已取得したデータ（オフラインデータ）を用いた。

2 方法

本研究は製造現場に適用することを念頭に置いている。製造現場では様々なデータや不良の発生が考えられるため、網羅的に対応できるように表1に示すデータを題材とした。本稿ではこの内、一般家庭において使用するドライヤを稼働したときの異常検知について報告する。ドライヤを選定した理由は、1つ目にモータ、ファンやヒータなどの製造現場にありふれた構成部品から成り立っている点、2つ目に身近な家電であることから異常検知をイメージすることが容易な点である。

表 1 対象データ

データ	概要
ドライヤ	ドライヤを稼働した時の加速度や温度などを測定したデータ
ランダム振動試験	振動試験機に設置した試験片のひずみと加速度を測定したデータ
NASA のターボファンエンジン ¹⁾	NASA の公開しているターボファンエンジンの定期保全のデータ
風力発電タービン ²⁾	風力発電機の加速度を測定したデータ
心拍波形 ³⁾	心電図のデータ。一定間隔で周期性のあるデータ

2. 1 実験装置

ドライヤの稼働データを収集するための測定システムを図1に示す。固定の影響を可能な限り小さくするため、ドライヤは空中に吊り、ゴムひもで固定した。電源のオン/オフの制御はコンセントタイマを使用した。図1のタイムチャートに示すように、1周期を10分として、ドライヤのオンの最初の3分間をデータ収集対象期間とした。データはデータロガ（キーエンス製NR600）により収集した。

測定する物理量、センサごとのサンプリング周波数及びセンサごとの測定時間を表2に示す。熱電対以外は2分50秒から3分までの10秒間を測定した（以後、これを「1回分のデータ」と呼ぶ）。測定したデータの例としてCH1の加速度の波形を図2に示す。

表 2 測定する物理量

物理量	センサ	サンプリング周波数	測定時間
加速度	小野測器製 NP-3211	10 kHz	2分50秒 ~3分
電流	マルチ計測器製 CTF-50A		
流量	愛知時計電機製 TRX		
温度	K 熱電対	10 Hz	0秒~3分

9月から2月まで4400回分のデータを測定し、合計稼働時間は約220時間（毎日5分間使用した場合、約7年に相当）であった。執筆時点（2023年3月）では故障に至っていないが、新品の状態（9月）と稼働後（2月）のドライヤの音圧を測定したところ人の聴覚でも違いが分かる程度に稼働音が異なり、状態が変化していることを確認した。

2. 2 異常検知の流れ

データ分析の流れを図3に示す。収集したデータ（生データ）に対し、ノイズ除去等の前処理を行う。次に入力データの中から重要な情報（特徴量）を抽出した後、異常状態を検知するためのモデルを作成する。そのモデルを実装し、現場で運用する。次項から前処理、特徴抽出及び異常検知モデルの作成について詳細を報告する。

2. 2. 1 前処理

異常検知モデルは正常データから学習して作成した。その際、生データに含まれるノイズの影響によりモデルの学習がうまくいかないことがある。複数の物理量を使用する場合には物理量ごとのスケールの違いが問題になることもある。この問題を解決するために移動平均処理と標準化を行った。また、後に示すクラスタリングによる異常検知については、主成分分析⁵⁾による次元の削減を行った。

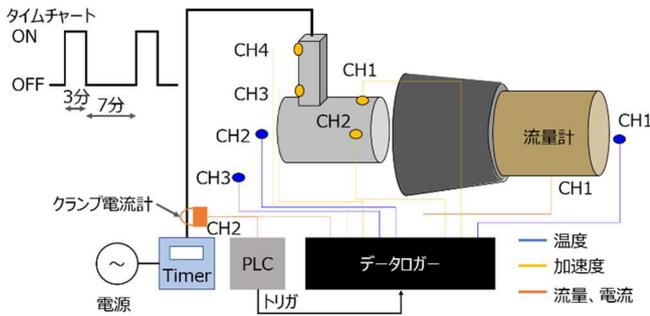


図 1 測定システム

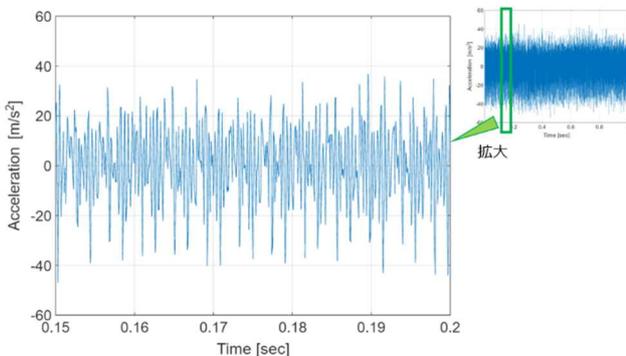


図 2 加速度



図 3 異常検知の流れ

表3 異常検知モデル

モデル	概要
k近傍法 (kNN)	訓練データと観測データの距離を異常度とする
自己回帰 (AR) モデル	訓練データに AR モデルを当てはめデータを予測し、観測データと比較したときのマハラノビス距離を異常度とする
クラスタリング	訓練データから確率密度関数を当てはめ、確率密度が小さいとき異常とする
オートエンコーダ	ネットワークへの入力データと一致するデータを出力し、それらの差（再構成誤差）を異常度とする。長短期記憶ネットワーク（LSTM）、畳み込みニューラルネットワーク（CNN）、全結合層ネットワーク（FC）等がある。

2.2.2 特徴量抽出

前処理後のデータを用いて異常検知することができるが、データから重要な情報を表す量（特徴量）を使用すると異常検知の精度が向上する場合がある。特徴量の抽出にはMATLABの機能の診断特徴デザイナー⁴⁾を使用した。時間領域の特徴量である平均値、ピーク値、実効値など、周波数領域の特徴量であるパワースペクトル密度のピーク周波数、ピーク値など1回の測定に対し合計96(加速度4CH×24)の特徴量を算出した。

2.2.3 異常検知モデル

異常を検知するために訓練データからモデルを作成した。そのモデルと観測データを比較し、異常度を算出することで異常の判定を行う。図4に異常検知のイメージを示す。異常検知モデルには様々な手法があるが、本稿では製造現場で扱うことの多い時系列データに適すと考えられる表3に示すモデルを検証した。

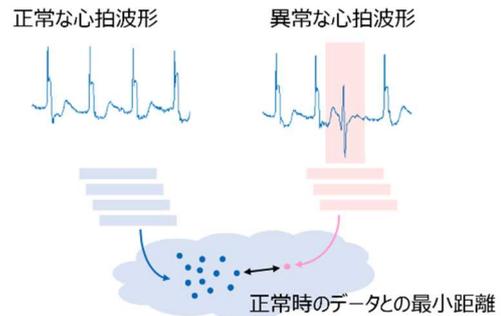


図4 異常検知のイメージ⁶⁾

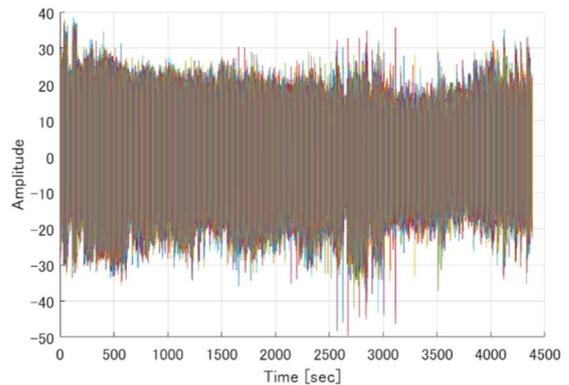


図5 加速度の時間波形

3 結果

加速度センサCH3のデータを図5に示す。データ量が多いため、1回の測定（10秒間）の内初めの1秒間のみ取り出し、色分けして連結した。時間経過とともに加速度の振幅が減少しているが、突発的に振幅が大きくなることもある。そのため、振幅のみから正常か異常状態かの判断は困難である。

各異常検知手法を適用した結果を図6から図9に示す。k近傍法（図6）では、生データに対して異常度の算出を行った。1回目の測定データを訓練データとした。試験時間の経過とともに異常度が上昇し、2800回目の測定から減少していることが伺える。仮に閾値を4.8に設定すると2800回目の測定で異常と判定することができる。

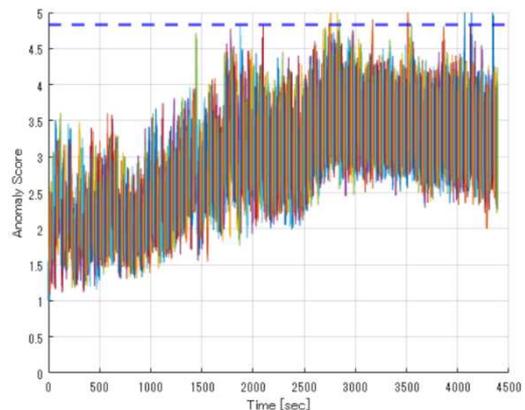


図6 k近傍法による異常検知

自己回帰モデル（図7）では、生データに対して異常度の算出を行った。1回目の測定データを訓練データとした。試験の中期や後期において大きく異常度が上昇したが、k近傍法と比較して増加の傾向は見られなかった。

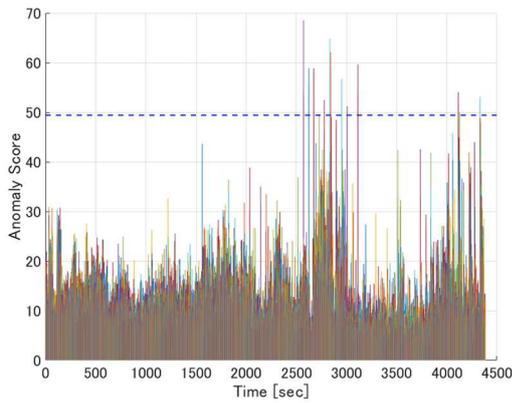


図7 自己回帰モデルによる異常検知

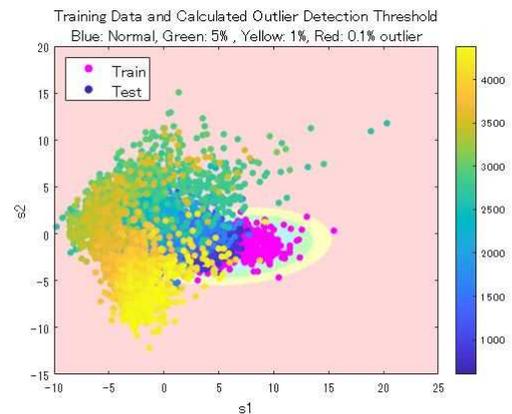


図8 クラスタリングによる異常検知

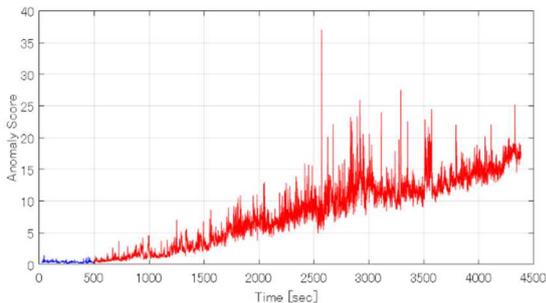


図9 LSTMによる異常検知

クラスタリング（図8）では、特徴量に対して標準化及び主成分分析を行った。横軸に第一主成分、縦軸に第二主成分を示し、測定時間（単位：秒）を色で表現した。試験が後半になるにつれ、左に推移している様子が伺える。初期の600回分のデータを訓練データとし、混合ガウス分布により正常状態の範囲を設定し、確率密度を閾値とすれば異常状態を判定可能な見通しが得られた。

LSTM（図9）では、特徴量を抽出後、さらに標準化を行い、オートエンコーダで訓練した。初期の500回分のデータを訓練データとした。試験時間の経過とともに異常度が上昇していることが分かった。

ドライヤのデータに対してk近傍法及びLSTMでは稼働時間の経過とともに異常度が上

昇し、クラスタリングでも正常状態からの推移が確認できた。これらは先述の9月と2月の稼働音の違いを反映したものと考えられ、各手法の妥当性を確認することができた。

4 まとめ

表1の他のデータに対しても異常検知を実施した。現場への適用のしやすさの観点から評価した結果を表4に示す。この表から、データに応じて適切な手法を選択する必要があることが分かった。また、製造現場の様々なデータや不良の発生に対応可能な異常検知のノウハウを蓄積することができた。

今後の課題は異常状態を判定する閾値の設定である。製造現場ごとに解決したい問題は異なり、適切な閾値は異なる。企業の知見やノウハウを活用し、暗黙知を形式知化できるように今後取組みたい。

表4 対象データへの異常検知の適用

対象		ドライヤ	ランダム振動試験	ターボファン (NASA)	風力発電タービン	心拍波形 qtdbse1102
部分時系列	KNN	★★★★★	★★★★★	★	★★★★	★★★★★
	AR	★	★★★★★	★	★★★★	★
	SST	-	★★★★★	★★	★★	★★★★
Clustering	T ²	★★★	★★★	★★★	★★★	-
	GMM	特徴量 (SVMで代用)	(SVMで代用)	★★★★	(SVMで代用)	↑
	SVM	★★★★	★★★★	★★★★	★★★★	↑
Deep Learning	FC	-	-	(適用不可) ※	-	★
	CNN	時系列	↑	★★★★	↑	★★★★
	LSTM	↑	↑	★★★★★	↑	★★★★
	FC	↑	★★★★★	-	★★★★★	-
	CNN	特徴量	↑	★★★★★	↑	★★★★
LSTM	↑	★★★★★	↑	★★★★★	↑	

※測定ごとにデータ長さが異なるため。

★★★★★：非常に良好
 ★★★★：良好
 ★★★：実用レベル
 ★★：見込みあり
 ★：見込みなし
 -：実施せず

参考文献

- 1) NASA Turbofan Jet Engine Data Set
<https://www.kaggle.com/datasets/behrad3d/nasa-cmaps>
- 2) 風力タービン高速ベアリングの経過予測
<https://jp.mathworks.com/help/predmaint/ug/wind-turbine-high-speed-bearing-prognosis.html>
- 3) 心電図データセット
<https://www.cs.ucr.edu/~eamonn/discords/qtdbse1102.txt>
- 4) 診断特徴デザイナー
<https://jp.mathworks.com/help/predmaint/ref/featuredesigner-app.html>
- 5) 井出 剛：入門 機械学習による異常検知-Rによる実践ガイド-, コロナ社, p. 124(2015)
- 6) 異常検知
<https://jp.mathworks.com/discovery/anomaly-detection.html>