

多様な動作パターンをもつ機器に適用可能な振動データを用いた故障予兆検知手法

小林 一樹 関根 理敏

日本国内の深刻な少子高齢化による労働人口の減少を背景に、AI(Artificial Intelligence)・IoT(Internet of Things)技術を活用した製造の効率化に対するお客様ニーズが拡大している¹⁾。特に、熟練作業でなければ感知できない異常や機器が故障する前兆となる事象を早期かつ自動で捉えるAI技術に大きな期待が寄せられている。

OKIではAI技術の一つである機械学習を用いた独自の振動解析アルゴリズムを用いた故障予兆検知に取り組み、さまざまな製造機器に対する実証実験を重ねている²⁾。これまでの経験上、異常検知対象となる機器は振動パターンが時間経過で変化しない単調動作機器と、動作箇所が時間とともに推移して振動パターンが頻繁に変化する機器(以下、多様な動作パターンをもつ機器)に大別される(図1)。前者の機器群には工作機械のボールネジや空調用の大型ポンプなどが該当し、後者の機器群にはロボットアームや金属加工装置などが該当する。

従来の異常検知手法では後述する理由のため多様な動作パターンをもつ機器を対象とした異常検知が難しく、課題となっている。この課題に対し、本稿では多様な動作パターンをもつ機器を対象とする新たな異常検知技術を紹介する。

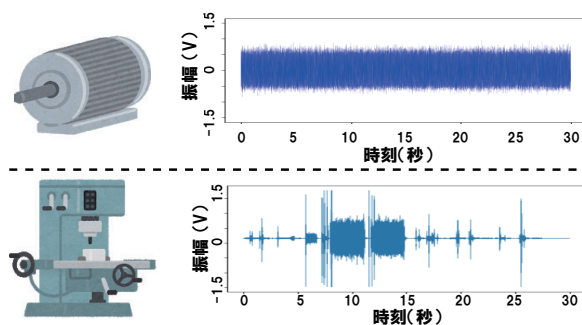


図1 異常検知対象機器と振動波形の例
(上:単調動作機器、下:多様な動作パターンをもつ機器)

多様な動作パターンをもつ機器の異常検知の難しさ

多様な動作パターンをもつ機器では動作ごとに正常な振動状態が異なるため、動作パターンの数だけ機器の正常・異常を判定する基準(判定モデル)を用意し、それらを

適宜切り替えることで異常検知をする。そこで、振動データを動作パターンごとに切り出し・分類した上で従来手法を適用する方法を試行したところ、以下の三つの課題に直面した。

・課題1

振動データを切り出し・分類するだけでも多くの工数を要する。また、複数名で作業する場合に切り出し・分類の基準が統一されていないために同じデータに対するアノテーション(意味付け)結果が異なるという問題もある。

・課題2

動作パターンが多い場合、人手によってパターンごとに適した特徴量を選択し、判定モデルを用意する方法は負担が大きい。

・課題3

製造機器を対象とした異常検知では機器の異常動作時のデータ収集ができず、正常データと異常データの両方を必要とする「教師あり」での異常検知ができない場合がある。

開発手法の特長

前述の三つの課題を解決する新たな振動異常検知手法(以下、開発手法)の特長を説明する。

まず、振動データの特徴量抽出方法として、開発手法では特徴量抽出に深層学習を用いることで特徴量選択を自動化する。このとき、「教師なし」の深層学習を利用することで機器の異常動作時のデータを必要としない異常検知が可能となる。また、振動データから特徴量を抽出するモデル(以下、特徴量抽出モデル)を作成する際、振動データを動作パターンごとに切り出し・分類する必要がない方法で学習データを与える。

次に、抽出された振動特徴量と制御情報から特定された動作パターン情報に基づいて、機器の振動異常度を推定するモデル(以下、異常度推定モデル)を作成する。開発手法では機器の制御情報を取得することで動作パターン

を特定し、その結果に応じて判定モデルを逐次切り替える。制御情報の例としては、機器の制御信号や動作を開始してから経過時間などがある。

モデル作成方法及び異常度推定方法の詳細は次節以降で解説する。

変分オートエンコーダー

開発手法では「教師あり」での異常検知ができない場合を想定し、「教師なし」の深層学習を利用することで、機器の異常動作時のデータを必要としない検知方式を実現している。ここでは、開発手法で採用した「教師なし」の深層学習手法である変分オートエンコーダー³⁾(Variational Autoencoder:以下VAEと略す)を簡単に解説する。

VAEは入力されたデータを出力で再現するように学習するオートエンコーダー³⁾(Autoencoder:以下AEと略す)の一種である。AEでは入力されたデータから特徴量を抽出することで圧縮(エンコード)した後、圧縮した特徴量から入力データと同じ次元数のデータを出力(デコード)する。その際、入力データと同じデータを正解データとして用いることで、「教師なし」での学習が可能となる。

一方、VAEでは入力データが平均 μ 、分散 σ^2 の確率分布に従うと仮定し、入力データから特徴量として μ と σ^2 を抽出した後、入力データと同じデータを出力するように学習する(図2)。このように、入力データが確率分布に従うと仮定することで、AEを用いた場合と比べて構造化された連続的な潜在空間を学習可能である。




図2 変分オートエンコーダー

モデルの作成方法及び異常度推定の方法

本節では特徴量抽出モデル及び異常度推定モデルの作成方法とモデルを用いた異常度推定方法を、学習段階と推論段階に分けて説明する。なお、ここでは機器が動作を開始してから経過時間を制御情報に用いることを想定する。

(1) 学習段階

図3に学習段階での処理を示す。学習用の振動データは機器の正常動作時に取得することを前提とし、特徴量抽出モデル作成用と異常度推定モデル作成用の2つに分けて利用する。特徴量抽出モデルの作成手順は次のとおりである。

・特徴量抽出モデル作成用の振動データをフーリエ変換することでスペクトログラムを計算する。(a-1)

ここで、スペクトログラムとは周波数ごとの振動パワーを短時間ごとに計算することで得られる、時刻・周波数別の振動パワー情報であり、以下では時間軸方向の次元数を T とする。

・a-1で得られたスペクトログラムの時間軸方向の平均値を計算する。(a-2)

・a-2で得られた結果を学習前の特徴量抽出ネットワークへ入力し、モデルを学習する。(a-3)

ここで、手順a-2でスペクトログラムの時間軸方向の平均値を計算し、手順a-3で特徴量抽出ネットワークの学習データとして与えることで事前の動作パターンごとの切り出し・分類を不要としている。また、得られた特徴量抽出モデルは異常度推定モデルの作成及び推論段階で利用される。

異常度推定モデルの作成手順は次のとおりである。

・異常度推定モデル作成用の振動データをフーリエ変換することでスペクトログラムを計算する。(b-1)

・b-1で得たスペクトログラムを時刻 $t(t=1,2,\dots,T)$ ごとに切り出し、a-3で得られた特徴量抽出ネットワークへ入力することで得られるエンコーダー部の出力(図2の μ と σ^2)を時刻 t での特徴量として用いる。(b-2)

・b-2で得た結果を異常度推定モデルの学習データとして与える。異常度推定の方法はさまざま考えられるが、統計的な距離に基づく異常度推定の場合は学習用の振動データ $X_k(k=1,2,\dots,K)$ から抽出した各時刻 t の特徴量 y_{tk} を用いて、時刻 t ごとに正常状態の特徴量分布を学習する。 K は異常度推定モデルの学習データの個数である。(b-3)

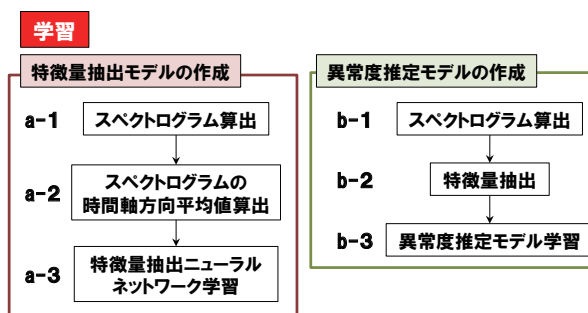


図3 学習段階の処理

(2) 推論段階

学習段階で得られた二つのモデルを用いた異常度推定の方法を説明する(図4)。

- ・評価対象の振動データをフーリエ変換することでスペクトログラムを計算する。(c-1)
- ・c-1で得たスペクトログラムを時刻 t ごとにa-3で得られた特徴量抽出ネットワークへ入力することで特徴量 $y_i(t=1, 2, \dots, T)$ を得る。(c-2)
- ・c-2で得られたモデルを用いて機器の異常度を推定する。(c-3)




図4 推論段階の処理

図5に、ある時刻 t での特徴量 y_i の分布例を示す。この図から、特徴量の分布が機器の正常・異常によって分離する場合とそうでない場合があると分かる。このような違いが生じる理由を補足する。多様な動作パターンをもつ機器では動作箇所が時間とともに推移する。そのため、機器に何らかの異常がある場合でも異常箇所が動作する時刻では特徴量の分布が正常・異常間で分離し、異常箇所が動作しない時刻では分布の違いが見られないと推測される。異常度推定(c-3)ではこの正常・異常間での分布の違いに注目し、正常状態の特徴量分布 $y_{i,n}$ と評価データの特徴量 y_i との統計的な距離に基づき異常度を算出する。




図5 ある時刻 t での特徴量 y_i の分布 (正常・異常各5サンプル)

評価実験

開発手法の有効性を評価するため、OKIで生産している複数のモーター及び機械式の稼働部をもち、それらが順次動作する機器(以下、評価機とする)を対象に実験を行った。振動データは検知周波数が10Hzから15kHzまでの4ヶ月間動作させることで取得した。本実験ではある複数の動作を含む、30秒間の一連動作を1サンプルとみなして

異常度の推移を評価した。図6に1サンプル分の振動波形とそのスペクトログラムを示す。

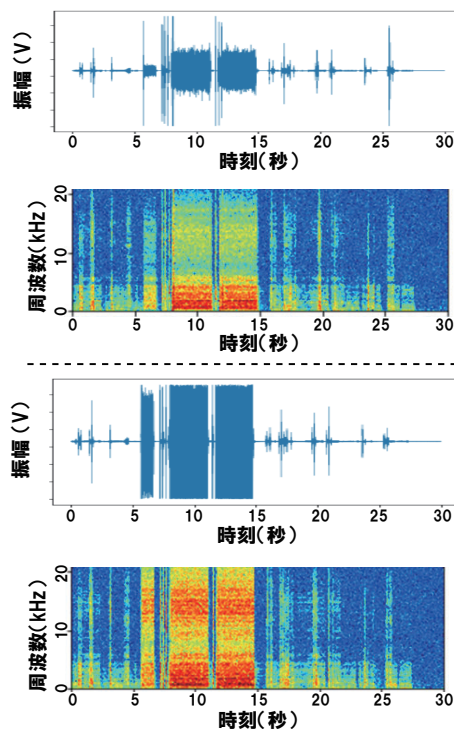


図6 30秒間の一連動作時の振動波形とスペクトログラム (上:実験初日、下:実験開始約4ヶ月後)

(1) モデルの学習方法

本評価実験でのモデルの学習方法を補足する。モデルの学習は、正常データとして実験初日の振動データ550サンプル(約4.5時間分)を用い、このうち500サンプルを特徴量抽出モデルの学習、残り50サンプルを異常度推定モデルの学習に利用した。スペクトログラムはウィンドウ幅を0.1秒、シフト幅を0.05秒として算出した。

(2) 実験結果と考察

実験開始から1~4週間までの1週間ごと、及び実験開始から1~4ヶ月の1か月ごとに取得した振動データ各5サンプルで、開発手法を用いて異常度を推定した。それら5サンプル分の異常度の平均値を求めた結果を図7に示す。この結果から、実験開始より1週間後以降、評価機の動作開始6~15秒後(図7中の※印の区間)で異常度が大きくなるのが分かる。また、このタイミングでの1~3週間後の異常度は大きな差がみられなかったが、4週間後以降では異常度がより大きくなるのが分かる。

次に、評価機の状態を調査し、以上の結果が得られた理由を考察する。まず、図6の波形及びスペクトログラムから

分かるように、評価機は動作開始6～15秒後のタイミングで動作しているが、このとき生じる振動の大きさは実験初日と実験開始4ヶ月後で明らかに異なる。このタイミングで動作する部材を調査したところ、ギヤの一つに摩耗が見つかった。

これらのことから、摩耗したギヤの動作タイミングで異常度が上昇し、更に実験開始4週間後以降で異常度の上昇が大きくなったと推測される。この結果から、機器の各動作箇所の動作タイミングと異常度が大きくなるタイミングを突き合わせることで機器の異常箇所を特定可能であると考えられる。ただし、今回の実験ではギヤの摩耗の程度と振動の大きさの関係及びギヤの摩耗の程度と異常度の大きさの関係を確認できなかった。今後、実験により異常度推定結果とギヤの摩耗の程度の関係に対応づける必要がある。

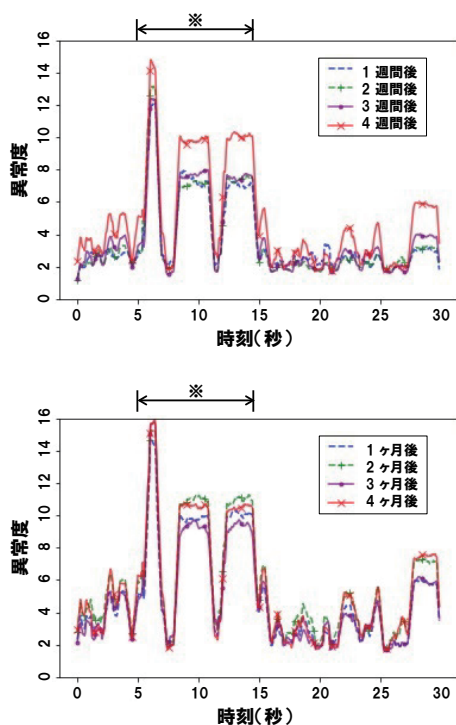


図7 実験結果
(上：1週間ごとの異常度変化、下：1ヶ月ごとの異常度変化)

おわりに

多様な動作パターンをもつ機器を対象とする新たな異常検知技術を解説し、評価機を用いた開発手法の評価実験結果を報告した。開発手法の評価実験では、あるギヤの摩耗に伴う振動変化を捉えたと推測可能な結果が得られた。

今後も引き続き、ほかの機器を対象に開発手法の追加

評価を重ねつつ、多様な動作パターンをもつ機器の高効率で高精度な異常検知や異常原因特定に有効な手法の開発に取り組みたい。

参考文献

- 1) 経済産業省:2017年版ものづくり白書
<http://www.meti.go.jp/report/whitepaper/mono/2017/index.html>
- 2) 高橋佑輔:製造業IoT向け振動による異常検知、OKIテクニカルレビュー230号、Vol.84、No.2、pp30-33、2017年12月
- 3) Francois Chollet:Python とKeras によるディープラーニング、初版、pp312-321、2018、マイナビ出版

筆者紹介

小林一樹:Kazuki Kobayashi. 情報通信事業本部 IoTプラットフォーム事業部 IoTソリューション推進部
関根理敏:Masatoshi Sekine. 経営基盤本部 研究開発センター AI技術研究開発部

TIPs 【基本用語解説】

スペクトログラム

振動パワーの周波数分布の時間変化を表したもの。