

機器の振動データの非負値行列因子分解による特徴抽出と異常検知

Feature Extraction and Anomaly Detection by
Non-negative Matrix Factorization of Vibration Data of Machine

関根 理敏 *1 小林 一樹 *1 伊加田 恵志 *1
Masatoshi Sekine Kazuki Kobayashi Satoshi Ikada

*1 沖電気工業株式会社 経営基盤本部 研究開発センター
Corporate Research and Development Center, Oki Electric Industry Co., Ltd.

In recent years, in the field of manufacturing industry, there is an increasing need for anomaly detection by collection and analysis of sensor data for predictive maintenance of factory equipment and industrial product. In the conventional method, for example, attention is focused on the power of a specific frequency band related to the anomaly of the equipment, and anomaly detection is performed by comparing the magnitude of the power. However, when there are many or wide frequency bands involved in anomaly, they may not be clearly specified. Therefore, we propose a method for anomaly detection using non-negative matrix factorization which is an unsupervised learning algorithm. Even if the frequency band of the vibration data is not clearly specified, our proposed method can automatically extract the features of vibration data and detect anomaly of machines accurately.

1. はじめに

近年、主に製造業の分野において、工場設備や工業製品の機器の予防保全に向けたセンサデータの収集・分析による異常検知のニーズが高まっている [METI 17]. そこでは機器の状態監視において、ネットワーク化された振動センサ、音響センサ等を配置し、それらのセンサデータをリアルタイムに収集・分析し、観測対象の故障の兆候を自動的に把握する。これによりメンテナンスのタイミング等を最適化でき、機器のダウンタイム発生による稼働率低下を抑制することが可能となる。

機器の異常検知において、従来手法では一例として、機器の正常・異常に関連する特定の周波数帯のパワーに着目し、そのパワーの大小を比較することによって異常検知を行っている。しかしながら、正常・異常に関与する周波数帯が複数ある場合や、広域にまたがる場合、また検知対象に個体差がある場合等では、周波数帯を明確に特定し、パワーの大小から異常検知を行うのが困難な場合がある。

そこで本稿では、教師なし学習アルゴリズムである非負値行列因子分解 (Non-negative Matrix Factorization (以下, NMF))[Lee 99] を利用し、学習段階と判別段階で NMF の基底行列を共通化することで、係数行列を特徴量とした異常検知手法を提案する。機器を利用した異常検知の性能評価を行った結果、振動データの自動特徴抽出によって、異常部位の動作区間における異常検知が可能であることが分かった。

2. 異常検知手法

2.1 学習段階におけるパワースペクトルからの NMF による特徴抽出と学習モデルの構築

図 1 に本手法における学習段階の動作を示す。学習データとして、正常状態のみ利用する場合と、正常・異常の両方の状態を利用する場合があるが、以下は前者の場合について説明する。まず正常状態における振動データからそれぞれ平均値を引き、高速フーリエ変換 (Fast Fourier Transform (FFT)) を行うことにより、パワースペクトルを求める。以下の式 (1) で

連絡先: 関根理敏、沖電気工業株式会社 経営基盤本部 研究開発センター、埼玉県蕨市中央 1-16-8, sekine566@oki.com

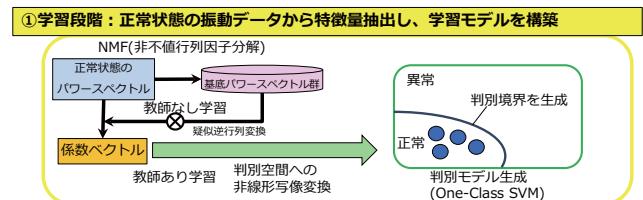


図 1: 学習段階

示すように、正常状態のパワースペクトル \mathbf{Y}_l に NMF を適用し、係数行列 \mathbf{W}_l と基底行列 \mathbf{H}_l に分解する。

$$\mathbf{Y}_l \simeq \mathbf{W}_l \mathbf{H}_l \quad (1)$$

ここで係数行列 \mathbf{W}_l の各成分は、対応する基底行列 \mathbf{H}_l の各ベクトル成分の、正常状態のパワースペクトル \mathbf{Y}_l における含有情報を示し、パワースペクトルの特徴を表す。本稿では、このように係数行列を特徴量として学習モデルを構築する。この場合、構築した学習モデルにより判別を行うには、学習段階における基底行列 \mathbf{H}_l を共通の基底行列として判別段階でも利用する必要がある。そこで正常状態のパワースペクトル \mathbf{Y}_l に基底行列 \mathbf{H}_l の逆行列をかけて係数行列を求める。しかしながら、基底行列 \mathbf{H}_l は一般に逆行列を持たない。そこで、ムーア・ペンローズの擬似逆行列 \mathbf{H}_l^+ を求め、学習段階においても判別段階においてもこの擬似逆行列 \mathbf{H}_l^+ により係数行列を抽出する。よって、学習時においては以下の式 (2) を用いて係数行列 \mathbf{W}_{lf} を求め、この係数行列を One-Class SVM に入力しモデルを構築する。

$$\mathbf{W}_{lf} = \mathbf{Y}_l \mathbf{H}_l^+ \quad (2)$$

ここで係数行列 \mathbf{W}_{lf} は $\|\mathbf{Y}_l - \mathbf{W}_{lf} \mathbf{H}_l\|^2$ を最小にする最小二乗解となる。

2.2 判別段階における分類スコアの算出と正常・異常判別

図 2 に本手法における判別段階の動作を示す。判別対象のパワースペクトル \mathbf{Y}_t に対して学習段階と同様に、以下の式 (3)

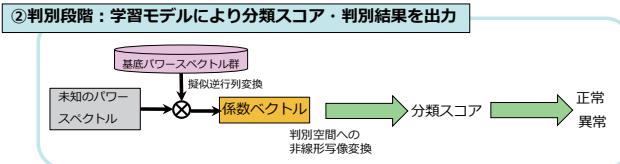


図 2: 判別段階

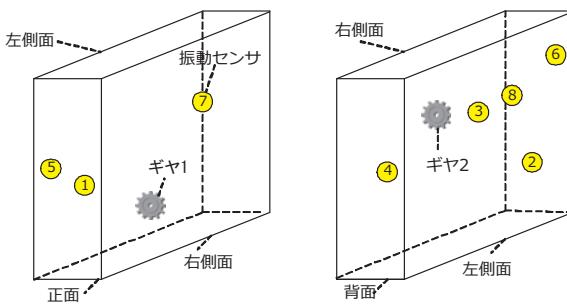


図 3: 振動センサ 8箇所とギヤ 2箇所の設置位置

で示すように基底行列の擬似逆行列 \mathbf{H}_l^+ をかけることで係数行列 \mathbf{W}_{tf} を求める。

$$\mathbf{W}_{tf} = \mathbf{Y}_t \mathbf{H}_l^+ \quad (3)$$

学習モデルは係数行列 \mathbf{W}_{tf} の各ベクトルごとに分類スコアを算出し、異常度の推定及び判別を行う。なお、分類スコアは判定境界までの符号付き距離であり、異常度が高いほど値が小さくなる。

3. 性能評価

本手法の評価を行うため、複数のモータ及び機械式の可動部を有する機器の正常・異常時の異常度推定による判別を行った。機器はシーケンス動作 30 秒間を 1 サンプルとして正常・異常各 10 サンプル分の振動データを取得した。機器の異常を、歯の欠け（ギヤ 1）、回転の偏心（ギヤ 2）があるギヤにそれぞれ交換することにより発生させた。また検知周波数範囲が 10Hz から 15kHz までの同機種の振動センサを図 3 のように 8 箇所配置した。サンプリング周波数は 100kHz とした。

図 4 に 1 シーケンス動作 30 秒間の、図 3 における振動センサ 1 で取得した信号及びスペクトログラムを示す。スペクトログラムはウインドウ幅 0.1 秒、シフト幅 0.05 秒とした。また図 5 に 1 シーケンス動作におけるギヤ 1, 2 の動作期間を示す。動作期間はシーケンス動作全期間における NMF の係数の時系列の振幅の立ち上がり時点、立ち下がり時点から求めた。

スペクトログラムにおける 0.1 秒間のパワースペクトルごとに正常 5 サンプルで One-Class SVM で学習を行った。残りの正常データ 5 サンプル及び異常データを判別データとして交差検定（分割数 2）を行った。また、ギヤ 1, ギヤ 2 の動作が重複しない動作期間を評価対象とし、ギヤ 1 は 2.8 秒間、ギヤ 2 は 0.75 秒間における 0.05 秒毎の分類スコア値の平均値を閾値判別した。閾値は判別正解率が最も高くなる値に設定した。

表 1、表 2 にそれぞれギヤ 1, ギヤ 2 の判別結果を示す。実験の結果、ギヤ 1 については図 3 における振動センサ 2 または 8、ギヤ 2 については振動センサ 2 のデータをそれぞれ用いることで、最も精度よく正常・異常判別できることが分かった。

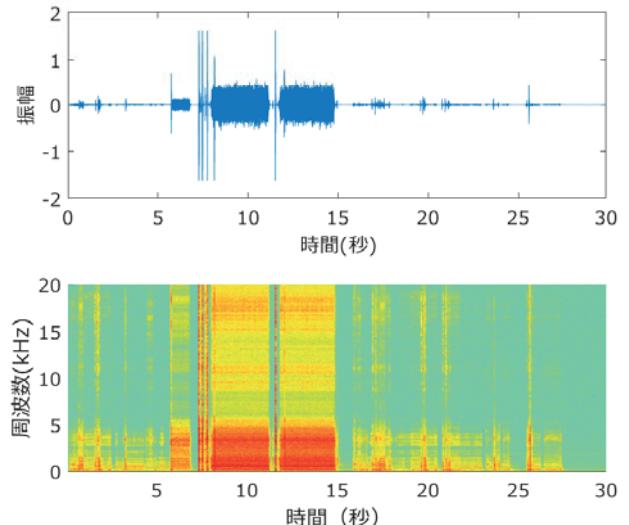


図 4: 1 シーケンス動作における信号 (上) とスペクトログラム (下)

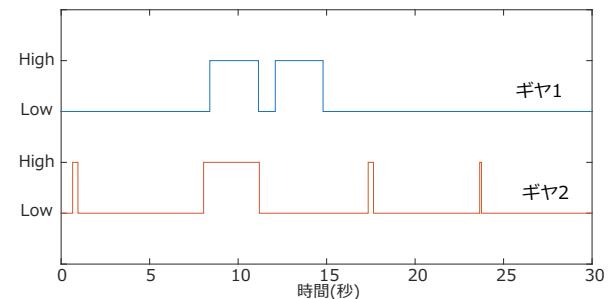


図 5: 1 シーケンス動作におけるギヤの動作区間 (High の区間)

4. おわりに

本稿では機器の異常検知において、NMF で振動データの特徴を抽出し、機械学習により機器の異常検知を行う手法について示した。機器を対象とした正常・異常状態の振動データを利用した評価の結果、ギヤの動作区間において、異常時においては正常時と比べて異常度が増加し、異常検知が可能であることが分かった。今後は機器の劣化経緯を観測した振動データを利用した異常の予兆検知を行う予定である。また正常状態において、複数の動作モードが存在する場合における効率的かつ高精度な異常検知手法の検討を行う予定である。

参考文献

[METI 17] 経済産業省, 2017 年版ものづくり白書.

[Lee 99] D.D. Lee and H.S. Seung, "Learning the part of objects by non-negative matrix factorization," Nature, vol.401,no,pp.788-791,Oct.1999.

表 1: ギヤ 1 の判別正解率 (%) 表 2: ギヤ 2 の判別正解率 (%)

	判別 真	正常	異常
正常	100	0	
異常	0	100	

	判別 真	正常	異常
正常	100	0	
異常	5	95	