

機械学習を用いた異常振動検知のための One-Class 分類手法の比較

○横内 俊秀 (鉄道総研) 兎内 達也 (鉄道総研)

山本 真 (鉄道総研) [電] 近藤 稔 (鉄道総研)

Comparative study of One-Class Classification Methods for Anormal Vibration Detection
using Machine Learning

○Toshihide Yokouchi, (RTRI) Tatsuya Tonai, (RTRI)

Shin Yamamoto, (RTRI) Minoru Kondo, (RTRI)

There are many kinds of One-Class classification methods for anomaly vibration detection using machine learning. It is assumed that a proper method depends on a target. In this paper, One-Class Support Vector Machine, Local Outlier Factor, Isolation Forest, Nearest Neighbor Classifier are compared as One-Class classification methods. Evaluation data is given in 1/12-octave band analysis of vibration acceleration measured in simulated tests of abnormal auxiliary drive shaft for diesel car. We present that One-Class Support Vector Machine and Nearest Neighbor are proper methods for anomaly detection for auxiliary drive shaft for diesel car.

キーワード : 状態監視, 異常検知, 機械学習, 振動, 気動車, 補機駆動軸

Key Words : Condition Monitoring, Anomaly Detection, Machine Learning, Vibration, Diesel Car, Auxiliary Drive Shaft

1. はじめに

物理的な動作を伴う機器には, 様々な振動や力がかかることによる破損が生じる場合がある. このような不具合は周辺に対して危険を及ぼすだけでなく, 動作を止めることでダウンタイムを生じさせることになる. そこで早期に異常を検知し不具合の発生を予防できれば, 機器やシステムの安全性・安定性を高めることができる.

一般にこのような機器の状態監視には, 機器に機械的な不具合が発生すると通常とは異なる振動が発生することに着目し, 振動に基づく方法が採用される場合が多い. これまで筆者らは, 鉄道車両機器の不具合に対して, 振動のオクターブバンド分析と機械学習を用いた分類手法を組み合わせた異常検知手法を提案してきた. そして, 手法の有効性を異常模擬試験や営業車両で測定されたデータを用いて確認してきた^{1)・5)}.

異常検知に用いられる分類手法のうち, 学習データのラベルが 1 つだけの分類手法を One-Class 分類手法と呼ぶ. One-Class 分類手法では, 正常データのみを学習データとし, 新たなデータに対して学習データの特徴から外れたものを異常データとみなす. したがって, 故障が発生しにく

い機器など, 異常データを取得する機会が少ない機器に対して効果的である. 一方で, One-Class 分類手法には様々な種類が存在し, その異常検知性能は手法や対象に依存すると考えられる. そこで本稿では, 異常振動検知に適した機械学習手法を評価することを目的として, 代表的な One-Class 分類手法である OCSVM (One-Class Support Vector Machine), LOF (Local Outlier Factor), IF (Isolation Forest), 近傍法⁵⁾を用いた場合の異常検知性能の比較を行う.

2. 機械学習を用いた異常振動検知の評価

2.1 異常振動検知手法の評価方法

異常振動検知手法の評価方法は図 1 のように, 3 ステップに大別される. まず, データ前処理で振動データを One-Class 分類手法に適した形 (特徴ベクトル) に変換する. 次に, One-Class 分類手法を用いて変換されたデータを学習することで分類器を作成する. そして, テストデータの各サンプルの異常度を計算する. 最後に, 計算された異常度とテストデータのラベルに基づき, 分類器の性能評価を行う.




図1 異常振動検知手法の性能評価

2.2 データ前処理

データ前処理では、振動データを特徴ベクトルに変換する。本稿では振動データに対してオクターブバンド分析を行い、その結果に対して主成分分析と白色化の処理を行う。オクターブバンド分析を行うことで、振動の特徴を周波数帯ごとの振動の大きさとして表現することができる。さらに、主成分分析を行うことで、振動の特徴を極力損なうことなくデータの次元を削減し、データ量を低減することができる。そして、各次元に対して白色化を行うことで、主成分間の分散を一致させ、検知性能を向上させる。

異常を検知した際には異常の原因特定が求められる。一般的に、機器や異常の内容ごとに異常振動の周波数帯が異なることが知られている。そこで本稿では、異常を示す周波数帯を特定することで異常原因を特定する。周波数帯は、過去の検討に基づき、低周波(100Hz以下)、中周波(100Hz～1kHz)、高周波(1kHz以上)と定義する²⁾。

2.3 One-Class 分類手法

(1) OCSVM (One-Class Support Vector Machine)

OCSVM は識別や回帰に用いられる SVM (Support Vector Machine) を One-Class 分類に適用した手法である(図2)。OCSVM では、学習データの一番外側にあるデータのいくつかをサポートベクターとして選ばれる。そして、それらを通りながら学習データの大半を囲むことができる判別境界が作成され、その判別境界で異常と正常の判定が行われる。





図2 OCSVM

OCSVM はカーネル法と組み合わせて使用することが多い。カーネル法ではベクトルの内積を計算する際に、通常の内積ではなくカーネル関数の値を内積として用いられるため、より非線形な形状の境界を作成できる。本稿でもカーネル法を採用し、カーネル関数には最も標準的なガウシアンカーネルを使用した。ハイパーパラメータは、学習データに含まれる異常データ割合の上限と同時に学習データ数に対するサポートベクター数の割合の下限を決める ν

($0 < \nu \leq 1$) と、学習データに対する判別境界の決定の重みづけに関する γ である。


(2) LOF (Local Outlier Factor)

LOF は密度ベースの異常検知手法である(図3)。LOF では、テストデータに対して k 番目に近い学習データを参照し、それぞれの k 近傍学習データに対してさらに k 近傍における局所近傍密度を計算する。そして、テストデータの局所近傍密度が k 近傍の平均局所近傍密度に比べて小さければ、異常データと判断する。単にデータ間の距離で判断しないため、正常データの分布密度が特徴ベクトル空間上の場所によって大きく変化する場合に有効な手法である。ハイパーパラメータは近傍数である。

図3 LOF ($k=3$ の場合)

(3) IF (Isolation Forest)

IF は決定木ベースの異常検知法である(図4)。特徴空間をランダムに分割して対象のデータを孤立させるための分割数は、正常データの場合には多く、異常データの場合には少ない。そこで、特徴空間のランダムな分割を複数回繰り返し、対象のデータが孤立するまでの分割回数に基づき異常度を計算する。1 回のみでは乱数による結果の依存性があるため、一連の分割を複数回繰り返して決定木のアンサンブルを行う。ハイパーパラメータはアンサンブル数である。



(a) 正常データの場合 (b) 異常データの場合

図4 IF

(4) 近傍法⁵⁾

テストデータ X と、 X に k 番目に近い学習データ A_k ($k=1, \dots, k_{NN}$) との距離をそれぞれ計算する。そして、各 k について計算された基準距離 d_k と比較して異常度を計算する(図5)。基準距離とは、 $X \cdot A_k$ 間の距離と比較して異常判定するための閾値である。その値は、学習時点で学習

データ自身に対して異常度を計算した際に、学習データの99%が正常判定されるように決められる。異常度 $f(x)$ は、 $X-A_k$ 間の距離を d_k で割った値を最近傍から k_{NN} 近傍にかけて平均して 1 を引いた値とし、正の値をとれば異常とする（式 1）。

$$f(x) = \frac{1}{k_{NN}} \sum_{k=1}^{k_{NN}} \frac{|x - A_k(x)|}{d_k} - 1 \quad (1)$$

最近傍だけでなく k_{NN} 近傍までを異常度の計算に使う理由は、最近傍のデータが学習データに混入した異常データであった場合（異常度が過大になる）でも、周囲の正常データを参照することで異常度を適切に算出するためである。ハイパーパラメータは参照する近傍数 k_{NN} である。




図5 近傍法（ $k_{NN}=4$ の場合）

2.4 性能評価

算出したテストデータの異常度をもとに、分類器の性能評価を行う。異常検知では、図6に示すROC（Receiver Operating Characteristic）曲線と、その下部面積 AUC（Area Under Curve）によって分類器を評価するのが一般的である⁶⁾。縦軸の TPR（True Positive Rate）は異常データを正しく異常と検出した割合（検知率）、横軸の FPR（False Positive Rate）は正常データを誤って異常と検出した割合（誤検知率）を表す。正常・異常の判定を行う異常度のしきい値を定めることで TPR と FPR が定まる。このしきい値を変化させたときの TPR と FPR の変化により ROC 曲線を描くことができる。理想的な分類器では、検知率が 100%、誤検知率が 0%となるしきい値が存在し、そのとき AUC は 1 となる。また、真逆の分類をしてしまう分類器では、検知率が 0%、誤検知率が 100%となるしきい値が存在し、そのとき AUC は 0 となる。そして、確率的に正常・異常の判定がランダムである分類器では、AUC は 0.5 となる。




図6 ROC曲線とAUC

3. One-Class 分類手法の性能評価

3.1 補機駆動軸の異常模擬試験

筆者らは過去に補機駆動軸の異常模擬試験を実施し、振動データを測定した³⁾⁴⁾。本稿では、測定した振動データを用いて One-Class 分類手法の性能を評価した。試験装置を図7に示す。試験はエンジンベンチを使用し、エンジンの出力軸は動力計に、反対側は補機駆動軸を介して発電機に接続した。これは、気動車において補機駆動軸を介してエンジンと補機を接続している状況を模擬している。

模擬した異常内容は、補機駆動軸と補機の結合部摩耗、ゴムカップリングの経年劣化の2つである。前者では、スプライン結合である結合部で摩耗が発生し、回転方向に隙間が生じて異常振動が発生する状況を模擬した。後者では、ゴムカップリングを構成するゴムが経年劣化により硬化した状況を模擬した。

試験は「正常 1」⇒「結合部摩耗」⇒「正常 2」⇒「ゴム劣化」の順に実施した。また、全試番において発電機・動力計ともに無負荷での運転とした。




図7 異常模擬試験の様子

3.2 性能評価条件

表1に前処理で用いたパラメータ、表2に性能評価で用いたハイパーパラメータを示す。

表1 前処理のパラメータ

オクターブバンド分析	バンド幅	1/12
	周波数範囲	10Hz~5kHz
	時間幅	1s
主成分分析	主成分数	6

表2 One-Class 分類手法とハイパーパラメータ

手法	ハイパーパラメータ	設定値
OCSVM	カーネル関数	ガウシアンカーネル
	ν	10^{-n} ($n = -6 \sim -0.5, 0.5\text{step}$)
	γ	10^{-n} ($n = -6 \sim 0.5, 0.5\text{step}$)
LOF	近傍データ数	1~10, 1step
IF	アンサンブル数	100~1000, 100step
近傍法	近傍データ数	1~10, 1step

学習データとして「正常 1」、テストデータのうち正常データとして「正常 2」、異常データとして「結合部摩耗」、

「ゴム劣化」を用いた。また、各データについて低周波、中周波、高周波と、周波数で分割しない全周波について評価を行った。データとして各 10 分間分を用いた。

3.3 評価結果

各 One-Class 分類で得られた ROC および AUC を図 8 に示す。いずれの手法においても、中周波、高周波では AUC が 1 に近く、理想的な分類器が得られたことを示している。したがって、補機駆動軸取り付け部の摩耗によるがたつきやゴムカップリングの劣化が発生すると、中周波～高周波の異常振動が発生し、高い異常度が発生すると考えられる。

また、常時監視システムでリアルタイムの異常検知が求められる場合には、異常検知に要する時間も重要な要素である。そこで、ハイパーパラメータを変えた時の中周波、高周波での AUC と異常検知に必要なとした時間を図 9 に示す。OCSVM を用いた場合には、ハイパーパラメータ依存性は認められるもののサブミリ秒オーダーの異常検知時間が期待できる。また、近傍法を用いた場合には、ハイパーパラメータの依存性が比較的少なく、ミリ秒オーダーの異常検知時間を期待できる。

以上の結果から、補機駆動軸を対象とした機械学習を用いた異常振動検知のための One-Class 分類手法の比較では、OCSVM または近傍法の使用が適切であると言える。




図 8 ROC および AUC

4. おわりに

気動車の補機駆動軸を対象として、機械学習を用いた異常振動検知のための One-Class 分類手法の比較を行った。その結果、高周波および中周波の周波数帯のデータを用いることで高性能な分類器を作成できることを示した。また、異常検知に必要なとする計算時間を比較し、One-Class 分類手法として、OCSVM および近傍法を用いたものが適していることを示した。




図 9 AUC および計算時間

参考文献

- 1) 近藤稔, 真鍋慎一, 高重達郎, 菅野普: 振動のオクターブバンド分析を用いた車両用ディーゼル機関の異常検知手法, 鉄道総研報告, Vol.29, No.9, pp.17-22, 2015.
- 2) 近藤稔: 振動のオクターブバンド分析を用いた異常検知法による機器の簡易診断, 日本機械学会年次大会, 2017.
- 3) 近藤稔, 高重達郎: 振動のオクターブバンド分析と機械学習を用いた車両機器の異常検知, 日本機械学会関東支部講演論文集, 2017.
- 4) 近藤稔, 高重達郎: 振動による状態監視手法を用いた気動車補機駆動軸の異常検知, 鉄道総研報告, Vol.31, No.6, pp.23-28, 2017.
- 5) 近藤 稔: 振動のオクターブバンド分析を用いた異常検知法による車両機器の診断, 日本機械学会論文集, Vol.84, No.862, pp.17-00594, 2018.
- 6) 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—, pp.105-113, コロナ社, 2015.