

車両機器のリアルタイム異常振動検知を目的とした 異常度計算の高速化

近藤 稔* 堺谷 洋*

Fast Calculation Method of Abnormality Degree for Real Time Abnormality Detection of Vehicle Equipment

Minoru KONDO Yo SAKAIDANI

Vibration monitoring is effective in early detection of equipment failure. In the vibration monitoring system we have proposed, abnormality detection is performed by applying the nearest neighbor method (NN) to the octave band analysis results of vibration. However, the NN requires a long calculation time and is not suitable for detecting an abnormality in real time. Therefore, we decided to consider applying the One Class Support Vector Machine (OCSVM) to abnormality detection. In this paper, the OCSVM is applied to actual vibration data, and calculation time are compared with the NN. As a result, we verified that the calculation time can be significantly reduced compared to the NN.

キーワード：状態監視，振動，オクターブバンド分析，機械学習

1. はじめに

電車では主電動機と減速機，気動車ではディーゼルエンジン，変速機，減速機，推進軸などの回転機械が駆動用に用いられている。これらの車両機器の異常を早期に検知して故障を未然に防ぐことができれば，鉄道の信頼性・安全性を高めることができる。一般に機器の状態監視には振動による方法が効果的であることが知られているため，鉄道総研では車両機器を対象とした振動監視システムの開発を行っている^{1)~6)}。

その開発では，車両機器の複雑な振動に対応するため，振動のオクターブバンド分析結果に機械学習を適用して異常検知を行うシステムを提案し，その有効性を異常模擬試験等により確認している。上記システムは，車上で振動の測定とオクターブバンド分析を行い，その結果を無線通信等で地上に送信し，地上のコンピュータで分析して異常検知を行うことを想定しており，異常検知方法として近傍法に基づく方法を用いている。

しかし，異常検知結果をなるべく早く通知したい場合や地上への無線通信量の削減のためには，車上でリアルタイムの異常検知を行う必要がある。近傍法に基づく方法は，学習データの増大とともに異常検知にかかる計算時間が長くなる性質があるため，車上での異常検知に適していない。そこで，車上での異常検知方法としてOCSVM(One Class Support Vector Machine)⁷⁾を適用することを検討した。

OCSVMは機械学習による異常検知手法として広く知られた方法であり，様々な問題に対して有効であることが知られている。OCSVMでは，サポートベクターと呼ばれる学習データのごく一部のデータのみを用いて異常検知境界を作成するため，異常検知計算の高速化が期待できる。本論文では，実際の振動データに対してOCSVMを適用し，異常度の計算結果や計算時間を従来方法と比較して，その有効性について検証した結果について報告する。

2. 振動を用いた状態監視システムの構成

2.1 システムの構成と動作

まず，対象とする状態監視システムの概要について説明する。図1に状態監視システムの構成例を示す。状態監視システムの主な構成要素は，車上に搭載された「状態監視装置」と地上のパソコンに組み込まれた「診断プログラム」である。このシステムでは，状態監視装置により機器の振動を常時測定すると同時にオクターブバンド分析を行う。

これまで提案してきたシステムでは，オクターブバンド分析結果(振動データ)を地上に送信し，その振動データを，診断プログラムにより分析することで異常検知を行うことを想定してきた。オクターブバンド分析を行うことでデータ量は大幅に削減されるものの，例えば10Hzから10kHzまでの振動について1秒毎に1/12オクターブバンド分析を行う場合には，振動測定一箇所の測定あたり毎秒100個以上の数値データが生成される。

* 車両制御技術研究部 動力システム研究室

特集：車両技術

そのため編成内の機器の数が多い電車の場合にはデータ量が膨大となる。

もし編成内の各車両に設置された状態監視装置内においてリアルタイムで異常検知を実施し、その結果のみを送信することができれば、通信データ量を大幅に削減できるためシステムの実装が容易になる。

そこで、本論文では状態監視装置内においてリアルタイムの異常検知を実施するシステムの実現を目指す。

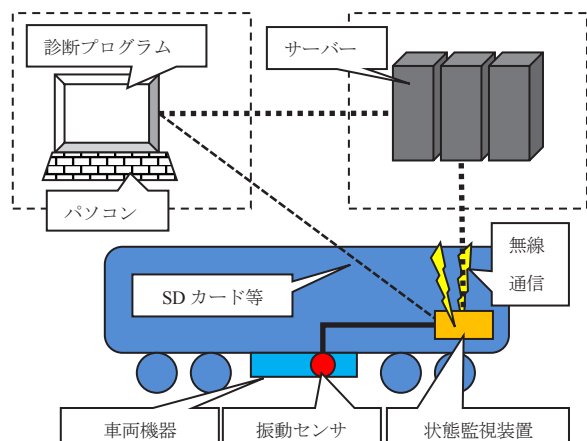


図1 状態監視システムの構成例

2.2 正常データの学習

本システムで用いる異常検知手法では、正常時の振動データ（学習データ）と比較を行うことで異常検知を行う。そのため、状態監視装置内で異常検知を行うためには、少なくとも過去に取得した振動データから学習データを抽出して状態監視装置内の記憶媒体に移す作業が必要となる。また、OCSVMを使用する場合には学習データからサポートベクター等を求めて状態監視装置に移す作業が必要となる。

そこで、本システムでは図1に示したように、状態監視装置でSDカード等の記憶媒体に振動データを記録しておき、定期検査の際等に記憶媒体を取り外して振動データを地上のパソコンに移す。そして、振動データを診断プログラムに入力してサポートベクター等を算出し、その結果を記憶媒体に記録して車上的状態監視装置に戻す。そして、そのサポートベクター等を用いてリアルタイムの異常検知を行う。

このようにすることで、大量の振動データを通信することなく、正常データとの比較による異常検知を行うことができる。

3. 異常検知手法

3.1 1クラス分類による異常検知

本論文の異常検知手法では、正常時の振動データを学

習データとして与え、機械学習の1クラス分類の手法を用いて診断対象となる振動データ（テストデータ）が正常な振動に該当するかどうかを判別する。「クラス」とはデータを分類するときのカテゴリーを意味する。

一般的な分類問題では、あらかじめ定めた複数のクラスのどれかにデータを分類するが、その方法で異常検知を行うためには、事前に「正常」と「異常」の両方のクラスについて、クラスを定義するための学習データを準備する必要がある。車両機器の故障が起きる頻度は低く、事前に故障した状態の振動データを取得することが困難であると考えられ、「異常」の学習データを準備することは難しい。

一方、1クラス分類では、1つのクラスについてのみ学習データを与え、そのクラスとそれ以外のどちらかにデータを分類する。この方法であれば「正常」データのみを準備すれば異常検知ができるため、車両機器の異常検知に適していると考えられる。

1クラス分類の手法はいくつかあるが、これまでの開発では近傍法に基づく方法を用いてきた。しかし、近傍法では学習データの増大に伴い、異常検知に必要なメモリや計算時間が増大する問題がある。車上でリアルタイムの異常検知を行うためには異常検知時の計算負荷が少ないOCSVMが適していると考えられる。そこで、本論文ではこの両者の比較を行う。

3.2 近傍法

まず、近傍法を用いた異常検知手法について説明する。

本システムでは図2に示すように振動の測定結果を1秒毎のデータに分割し、それぞれについてオクターブバンド分析を行う。次に、その分析結果に対して、前処理として主成分分析及び白色化の処理を行う。

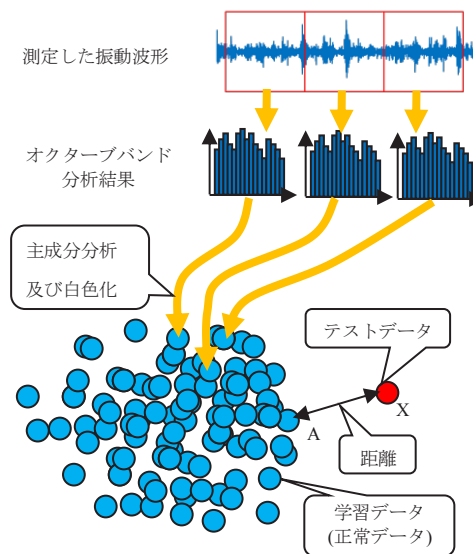


図2 振動のオクターブバンド分析と近傍法による異常検知手法

主成分分析はデータが広く分布している方向の成分を主な成分として抽出する方法であり、白色化は各データの各主成分について、全学習データの平均値を引いて標準偏差で割る処理である。本論文では過去の研究¹⁾を参考にして第1～第6主成分までを用いる。

著者らが提案する近傍法²⁾により異常検知を行う際には、前処理後の各データを多次元空間上の一点の座標に対応させ、テストデータ(点X)と各学習データとの距離を計算し、最も距離の近い学習データ(点A)との距離を基準距離で割った値から1を引いたものを異常度とする。このようにすると算出した距離が基準距離を超えた場合に異常度が正の値になるため、異常度の正負で異常判定ができる。基準距離は、学習データ自身に対して評価を行った際にその99%が正常判定されるように定めている。ただし、この方法では点Aが正常データに紛れ込んだ異常なデータであった場合に大きな影響を受けてしまうため、 k_{NN} 番目に近い学習データまでについても同様の計算をして、平均した値を異常度とする。この k_{NN} を近傍データ数と呼び、本論文では $k_{NN}=4$ として計算する。以上の考え方に従い定義した異常度は式(1)の関数 $f(\bar{x})$ で表される。

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

ただし、 \bar{x} はテストデータ(ベクトル)、 $NN_k(\bar{x})$ は \bar{x} に k 番目に近い学習データ(ベクトル)、 d_k は k 番目に近いデータに対する基準距離である。なお、これらの処理を行うプログラムの作成にあたってはオープンソースの機械学習ライブラリ⁸⁾を使用している。

3.3 OCSVMの概要

次にOCSVMを用いた異常検知手法について説明する。

サポートベクターマシン(Support Vector Machine)は、元々2クラスの分類問題のために考えられた方法であり、この方法を1クラス分類問題に適用したのがOCSVMである。OCSVMによる異常検知では前述の主成分分析と白色化を行った後のデータに対してOCSVMを適用する。OCSVMでは図3に示すように特徴ベクトルで構成される特徴空間上の学習データの集合の一番外側にあるデータの幾つかを選び、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を作成し、




図3 OCSVMによる異常判定のイメージ

その判別境界で異常と正常の判定を行う。その判別境界を作成するために選ばれたデータがサポートベクターと呼ばれる。サポートベクターは判別境界上かその外側に位置する。

判別境界はサポートベクターをパラメータとし、特徴空間上の点の座標を変数とした判別関数の等値線として表される。そのため、その関数の値を異常度の算出に用いることができる。

OCSVMはカーネル法と組み合わせて使用することが多く、本プログラムでもカーネル法を使用する。カーネル法ではベクトル同士の内積を計算する際に、通常の内積では無くカーネル関数の値を内積として用いる。カーネル関数は最も標準的なガウシアンカーネルを使用する。ガウシアンカーネルは式(2)で表される。

$$k(\bar{x}, \bar{y}) = e^{-\gamma \|\bar{x} - \bar{y}\|^2} \quad (2)$$

$k(\bar{x}, \bar{y})$ はカーネル関数、 \bar{x} と \bar{y} はテストデータ等のベクトルである。 γ はパラメータであり、適当な値に調整する必要があるため、事前に外部で求めた値を用いる。

異常度の計算を行う関数 $f(\bar{x})$ は、カーネル関数を用いて式(3)で与えられる。

$$f(\bar{x}) = -\frac{\sum_i \alpha_i k(\bar{x}_i, \bar{x}) - \rho}{\rho} \quad (3)$$

ただし $\rho = \sum_j \alpha_j k(\bar{x}_j, \bar{x}_i)$ であり、 \bar{x} と α_i と ρ は、サポートベクターとそれに対応する係数、切片である。

この関数は、異常度が1から-1の範囲になり、異常と判定される場合に異常度が正の値となるように、OCSVMで通常用いられている決定関数に負号をつけて切片で割ったものである。

これらのパラメータは学習データに基づいて決定した値を用い、式(4)の最小化問題の解として算出される。

$$\begin{aligned} \min_{\alpha} \quad & \frac{1}{2} \sum_{ij} \alpha_i \alpha_j k(\bar{x}_i, \bar{x}_j) \\ & 0 \leq \alpha_i \leq \frac{1}{v|l|}, \quad \sum_i \alpha_i = 1 \end{aligned} \quad (4)$$

v は0から1の間の値を取るパラメータ、 l は学習データのデータ数である。

以上の計算により関数 $f(\bar{x})$ を定義でき、異常度の計算ができる。ただし、計算過程で示されたように、事前に設定する必要があるOCSVMのパラメータとして、 v と γ の2つがあり、これらの値を適切な値にする必要がある。

3.4 OCSVMのパラメータ設定

OCSVMのパラメータである v と γ は異常検知性能に大きな影響を及ぼすため、適切な値に設定する必要がある。

特集：車両技術

る。設定時に異常データを利用できる場合には、異常データを用いて実際に異常検知性能を評価することで、比較的容易にパラメータの最適化を行うことができる。しかし、状態監視システムの場合には、使用を開始する段階で異常データは得られていない場合が多い。そのため、OCSVMのパラメータ最適化も正常データのみを用いて行う必要がある。

v と γ のうち、 v については学習データに含まれる異常データの割合の上限であり(性質1)、サポートベクターの割合の下限である(性質2)という性質がある。そのため、性質1の観点からは、基本的に異常データが含まれていない学習データの場合には、 v の値は十分に小さい値にしておけば良い。ただし、 v の値を固定すると、学習データの数 l が非常に多い場合には性質2によりサポートベクターの数が非常に多くなり、異常度計算にかかる計算時間が増大してしまう。そこで、まず、サポートベクターの数の下限値を定め、それを学習データの数 l で割ったものを v とする。サポートベクターの数の下限値としては、多次元空間上で超平面を指定するのに空間の次元数の点が必要となることから、学習データの次元 n を指定すると v の値は式(5)で定められる。

$$v = \frac{n}{l} \tag{5}$$

なお、 v の値で定められるのはサポートベクターの数の下限値であり、最終的なサポートベクターの数は学習データ等に依存して、必要に応じて増大する。

一方、 γ については、値が大きすぎると学習データへ過剰に適合して、正常データを異常と判定してしまう可能性が高くなる。逆に、 γ の値が小さすぎると学習データへの適合が不十分になり、異常値を正常判定してしまう可能性が高くなる。そこで、 γ の値を適切な値に設定する方法として、学習データから生成される検証用データに対してOCSVMで異常検知を行い、 γ を適切な値に調整する方法(DTL法⁹⁾)が提案されている。DTL法では近傍法と類似の考え方で検証用データを作成するため、結果的に近傍法と類似の結果が得られるように調整が行われる。そこで、本論文ではDTL法により γ を決定する。

3.5 周波数帯毎の異常検知による故障種類の診断

前述の通り、オクターブバンド分析結果に対して1クラス分類を適用することで、様々な機器の様々な故障を検知できる汎用性の高い異常検知手法を実現できると考えられる。しかし、正常以外の状態を全て異常と判定しているため異常の内容を判別できず、異常検知後の対処の判断が困難であるという問題がある。

一方、振動による機器の検査では、周波数分析により異常振動の周波数を明らかにし、そこから異常振動の原因を推定することが古くから行われており、故障の種類

表1 異常振動の発生周波数の分類

分類	発生周波数	異常	対処法(例)
低周波	100Hz以下	・アンバランス ・ミスアライメント ・ゆるみ	外観検査 寸法測定 打音検査
中周波	100Hz～1kHz	・ゆるみ ・摩耗や衝突(軸受等)	打音検査 潤滑油検査 分解検査
高周波	1kHz以上	・摩耗や衝突(軸受等) ・傷や割れ(軸受等)	潤滑油検査 分解検査




図4 オクターブバンド分析結果の分割

によって異常振動の発生周波数帯が異なることが知られている。その知見を鉄道車両の駆動用機器に適用すると、異常振動の発生周波数を概ね表1のように高周波・中周波・低周波の三つの周波数帯に分類することができる。

そこで、図4に示すようにオクターブバンド分析結果を3つの周波数帯毎に分割し、各周波数帯のデータの集合について、それぞれ異常検知を行うことで、異常振動が発生している周波数帯を明らかにすることができ、表1に従って簡易診断を行うことができると考えられる³⁾。

3つの周波数帯の境界は前述の通り100Hzと1kHzであるが、後述する異常模擬試験では1/12オクターブバンド分析を使用しており、各周波数帯の範囲を中心周波数で表わすと、低周波データは96Hz以下、中周波データは102Hzから970Hz、高周波データは1030Hz以上となる。次章で示す異常模擬試験による検証でも、この3つの周波数帯毎に異常検知を行った結果について示す。

4. 主電動機の異常模擬試験による検証

4.1 異常模擬試験

近傍法と OCSVM の比較を行うため、新幹線電専用主電動機の軸受異常を対象として実施した異常模擬試験⁵⁾時に取得された振動データを使用する。本異常模擬試験では、定置で主電動機を回転させて振動等の各状態監視量を測定した。供試電動機と供試軸受を図5に示す。

異常模擬試験では、図5に示すように、異常を模擬するために軸受の内輪を加工して平らな部分を作った供試軸受を新幹線電専用主電動機に組み込んだものを使用した。振動測定は駆動側と反駆動側の二箇所それぞれ振動加速度センサを取り付けて行った。振動加速度センサは1軸の振動加速度センサで、回転軸方向の振動を測定するようにセンサが取り付けられている。

試験は異常軸受と正常軸受のそれぞれについて負荷試験と無負荷試験を行った。負荷試験では図6に示す運転点で供試電動機を運転してその際の振動等を測定した。無負荷試験では負荷試験と同じ回転速度で無負荷回転させて振動等を測定した。測定は各運転点について180秒間行った。正常軸受については、学習データとテストデータを取得するため試験を2回実施し、得られた振動データをランダムに学習データとテストデータに分けた。



図5 供試電動機と供試軸受




図6 負荷試験時の運転点

4.2 異常検知結果の比較

OCSVMにより近傍法と同等の異常度計算ができることを確認するため、主電動機軸受の異常模擬試験結果に対してOCSVMを適用し、異常検知を行った。想定する状態監視システムでは主電動機反駆動側の振動を監視するため、反駆動側振動に対して異常検知を行った結果を示す。近傍法とOCSVMによる異常検知結果の比較を図7に示す。

図7では異常検知されたデータの割合を示す異常発生率を各条件について計算した結果を示している。正常軸受であっても様々な振動が発生するため、近傍法でもOCSVMでも誤検知の発生が完全に無くなることは無い。そのため、ある一定時間内の異常発生率が異常検知のための指標となる。

図7によると、正常軸受の場合には両者ともほぼ全てのデータについて正常判定されており、誤検知の発生は少なく、異常発生率は8%以下である。異常軸受については、両者ともほぼ全ての条件において高周波成分で異常が検知され、条件によっては中周波成分でも一部のデータについて異常が検知されている。

高周波成分については近傍法の全負荷50km/hの異常発生率が低く、OCSVMの全負荷200km/hでほとんど異常検知できていない等、条件によっては異なる結果になっている部分もあるが、全体の傾向としては近傍法とOCSVMの結果はほぼ同じであり、同等の異常検知ができることが確認された。





図7 異常検知結果の比較
(上：近傍法, 下：OCSVM)

特集：車両技術

4.3 計算時間の比較

OCSVM を適用する目的は異常検知を高速化して、状態監視端末内でのリアルタイムの異常検知を可能にすることである。そこで、OCSVM による異常検知のための計算時間の短縮効果を評価する。

評価の際にはパソコン上で計算を実行し、その際の経過時間を測定する。しかし、パソコン上では複数のプログラムが同時に動作しているため、プログラムの実行時間は他のプログラムの動作状況に影響される。そこで、その影響を極力減らすために、同じ計算を複数回実施して最も実行時間が短い場合が最も他のプログラムの影響を受けなかった場合であると考え、その際の実行時間をプログラムの実行時間として評価した。

評価は近傍法と OCSVM について実施するが、近傍法では計算を高速化するための方法があり、異常検知に利用している機械学習のライブラリ⁸⁾では複数の計算方法が選択できる。通常はその方法の一つである Ball Tree を使用している。しかし、状態監視端末に実装する場合には、単純なアルゴリズムで実装が容易なしらみつぶし (Brute force) による方法が用いられる可能性もある。そこで、近傍法については Brute force と Ball tree の両方について計算を行った。計算時間の評価結果を図 8 に示す。

図 8 によると、近傍法 (Brute force) を基準にすると、近傍法 (Ball tree) は約 40%、OCSVM は約 5% の計算時間となっており、実際に計算時間が大幅に短縮できることを確認できた。また、近傍法では計算時間が条件により変動しているのに対し、OCSVM は計算時間が一定値となっており、状態監視端末内でのリアルタイムの異常検知に適した異常検知方法であることが確認できた。




図 8 計算時間の比較

5. まとめ

車両機器の振動を監視する状態監視システムにおいて、振動データの機械学習による異常検知手法を適用する場合に、リアルタイムでの異常検知を実現するため、異常検知手法として OCSVM を適用する方法について検討し、異常模擬試験で得られた振動データを用いて、異常検知性能と計算速度の評価を行った。

その結果、OCSVM で従来の近傍法と同等の異常検知を行うことができることと、従来の近傍法と比べて大幅に計算時間を短縮できることを確認した。

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, 高重達郎, 真鍋慎一, 菅野普: 振動による状態監視法を用いたディーゼル機関異物混入時の異常振動検知, 鉄道総研報告, Vol.30, No.4, pp.47-52, 2016
- 3) 近藤稔: 異常振動の発生周波数帯による車両機器状態の簡易診断, 鉄道総研報告, Vol.32, No.1, pp.35-40, 2018
- 4) 西谷幸祐, 近藤稔, 高重達郎, 片岡祐太, 野口敬太: 振動による駆動機器用状態監視システムの営業列車への適用, 鉄道総研報告, Vol.32, No.8, pp.23-28, 2018
- 5) 近藤稔, 堺谷洋, 高橋研: 振動のオクターブバンド分析を用いた駆動用電動機軸受の異常検知, D&D2018 講演論文集, 602, 2018
- 6) 近藤稔, 堺谷洋: 車両機器振動監視システムにおけるリアルタイム異常検知, 電気学会産業応用部門大会 2019 講演論文集, 2019
- 7) Schölkopf, B., Williamson, R., Smola, A., Shawe-Taylor, J., & Platt, J., "Support Vector Method for Novelty Detection." Advances in Neural Information Processing Systems 12, 582-588., 1999.
- 8) Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, E., "Scikit-learn: Machine learning in Python," The Journal of Machine Learning Research, vol. 12, pp.2825-2830, 2011.
- 9) Y. Xiao, H. Wang, L. Zhang, and W. Xu, "Two methods of selecting Gaussian kernel parameters for one-class SVM and their application to fault detection, Knowledge-Based Systems," vol. 59, pp. 75-84, 2014.