

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

近藤 稔* 真鍋 慎一* 高重 達郎* 菅野 普*

Abnormality Detection of Traction Diesel Engines Using Vibration Analysis in Octave Bands

Minoru KONDO Shinichi MANABE Tatsuro TAKASHIGE Hiroshi KANNO

A railway traction system consists of rotating machines such as electric motors, gears, diesel engines, and Cardan shafts. These machines are essential parts for a train to run. Therefore, we are developing a condition monitoring system (CMS) that detects failures of the machines in the early stage to prevent transport disorders. The CMS monitors the vibrations of a machine and detects abnormal vibrations with a machine learning algorithm that is based on nearest-neighbor analysis. In the CMS, octave-band analysis is performed to extract feature vectors from vibration data. We conducted a running test to verify the performance of the CMS. The test results show that the CMS can distinguish the simulated abnormal vibrations from the normal ones without false detections.

キーワード：振動，オクターブバンド分析，状態監視，機械学習

1. はじめに

鉄道車両の駆動用機器には、電車の場合は主電動機と減速機，気動車の場合はディーゼル機関（エンジン），変速機，減速機といった回転機械が用いられている。これらの駆動用機器は故障を起こすと列車の安全で正常な運行を妨げることになるため，そ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。

そこで，著者らはセンサ等により駆動用機器の状態を常時監視する状態監視システムの研究開発を行っている。機器の状態監視方法には様々なものがあるが，回転機械の状態監視方法としては振動による方法が広く用いられている。しかし，駆動用機器は運転状態により複雑に振動が変化し，走行に伴う振動も発生する。そのため，単純に振動の大きさを測定してしきい値により異常を判別することは困難であり，振動の周波数分析を行って判定する方法¹⁾や振動の測定結果を統計的に分析して異常を判別する方法等が提案されている^{2) 3)}。

一方，異常検知は機械の故障のみでは無く，様々な分野でニーズがあるため，情報工学の機械学習分野では一般的問題として異常検知が研究されており，様々な問題に適用できるアルゴリズムが提案されている。このアルゴリズムを回転機械の振動に適用することで，様々な機器に応用可能な一般性のある異常検知システムの実現が期待できる。機械学習ではコンピュータに過去のデータを学習させて，未知の事象について予測させる。近年では，情報通信技術の進歩により大量のデータを扱うこと

* 車両制御技術研究部 動力システム研究室

が可能となったため，機械学習の利用が様々な分野で進んでおり，今後の発展が期待できる。

そこで，著者らは，振動測定と機械学習の異常検知アルゴリズムを組み合わせた状態監視システムを実現することを目指している。本報告では，その状態監視システムについて概説するとともに，機械学習を応用した異常検知方法を提案する。そして，気動車のエンジンを状態監視の対象として走行試験を行い，その方法の有効性を検証した結果について報告する。

2. 振動による駆動用機器の状態監視システム

2.1 提案する状態監視システム

振動による状態監視を行う場合，振動センサにより測定した信号（振動データ）を処理し，それを分析して異常検知等を行うシステム構成となる。このとき，機械学習を用いるためには，振動データを変換して，振動の特徴を表すことができる数値のセット（特徴ベクトル）を生成する必要がある。

特徴ベクトルを得る方法には様々な方法が考えられるが，今回は振動データのオクターブバンド分析結果を特徴ベクトルの元になるデータとして用いることとした。その理由を以下に述べる。

一般に，エンジンのような機械では，部品点数が多く様々な故障の可能性があり，事前に全ての故障とそれにより発生する振動を予測することは困難である。

一方，機械の異常は異音として発見されることが多い。異音とは正常時とは異なる音ということであり，どのような故障が発生しているかまでは分からなくても，何ら

特集：車両技術

かの故障が発生していることが分かる。つまり、異常検知の観点からは全ての故障とそれによる振動を事前にかけておく必要は無く、正常時の振動だけ分かればよい。

多くの場合、異音と認識される音は、ある程度の時間継続する、通常とは異なる音色の音である。そこで、特徴ベクトルとしては定常的な音色を表現できるものとした。振動・音響分野で用いられているオクターブバンド分析の結果はこの要求を満たすものであるため、今回のシステムでは振動のオクターブバンド分析結果を特徴ベクトルの元になるデータとして用いることとした。

従来の異常検知方法では、事前に検知すべき振動の周波数を把握し、その周波数帯の振動をフィルタで取り出す処理を行うのが一般的である。しかし、この方法では想定していない故障による振動を異常検知の対象外にしてしまう可能性がある。これに対し、オクターブバンド分析結果を用いる方法では、測定された全ての周波数帯を対象とするため、事前に検知すべき振動の周波数を特定する必要が無い。そのため、エンジンのような複雑な機器を対象とした場合にも容易に適用できる、汎用性の高い状態監視システムの実現が期待できる。

このような状態監視システムを構成するためには、振動を測定してオクターブバンド分析を行う処理と、その結果を分析して異常検知を行う処理が必要となる。今回開発するシステムでは、前者の処理を「状態監視装置」で、後者の処理を「診断プログラム」で実現することを想定している。今回想定しているシステムの構成を図1に示す。

図1のシステムでは状態監視装置で得られたオクターブバンド分析結果が、速度等のデータとともに地上に送信されて、地上側のパソコンで診断プログラムにより分析する構成となっている。このシステムでは、部品の劣化や故障の予兆を早期に検出して、実際に大きな故障が起きる前に必要な修繕を行うことを想定しているため、車上で異常を検知して警報を出すのではなく、地上で分析を行う構成としている。




図1 状態監視システムの構成

2.2 状態監視装置

状態監視装置は車上で振動測定とオクターブバンド分析を行う装置である。車上でオクターブバンド分析を行うことにより、データ量を大幅に圧縮することができ、データの記録や外部への通信が容易になる。

しかし、状態監視用にオクターブバンド分析を行って記録・通信する装置は一般に市販されてはいないため、今回、そのような機能を持つ装置を状態監視装置として試作した。ただし、データ送信機能は実際にシステムを構築する際に付加することとし、今回の試作装置では送信機能は設けていない。

測定分析結果をUSBメモリ等の外部記憶装置に記録できるように、状態監視装置はUSBポートを介して測定分析結果を外部記録装置に出力する仕様とした。測定された振動データに対してはオクターブバンド分析がなされ、その結果が記録される。また、状態監視装置には列車速度等の情報も記録するため電圧測定機能も設けている。電圧測定結果についてはデータ記録周期1周期分のデータについて平均値処理を行った結果が記録される。これらの信号処理の仕様は表1の通りである。なお、表1に示した仕様は暫定的な値であり、今後最適な仕様を検討していく予定である。

表1 状態監視装置の信号処理機能の仕様

項目		仕様
オクターブバンド分析	バンド幅	1/12
	周波数範囲	10Hz～5kHz
電圧測定サンプリング周期		100ms
データ記録周期		1s
出力ファイル形式		CSVテキスト

3. 診断プログラムの異常検知アルゴリズム

3.1 前処理

3.1.1 定常状態の抽出

状態監視装置で得られたオクターブバンド分析結果は、診断プログラムで分析される。診断プログラムでは異常検知を行う前に、与えられた振動データを異常検知に用いる特徴ベクトルに変換する前処理を行う。今回作成した診断プログラムの前処理では、まず、定常状態の抽出を行い、抽出されたデータに対して主成分分析を行っている。以下では、まず、定常状態の抽出について説明する。

今回の異常検知ではある程度定常的な振動を想定している。しかし、実際に車両が走行する際には過渡的な振動の変化が多く発生する。そのため、過渡的な振動に対するデータは排除することが望ましい。

表1に示した通り、状態監視装置ではオクターブバ

ンド分析結果を1秒毎に保存する。そこで、対象とするオクターブバンド分析結果を前後の時刻のものと比較して、その違いがほとんど無ければ定常状態であると判定することができると考えられる。

オクターブバンド分析結果同士の違いを評価する際には、それらを多次元空間上の点の座標を表わすデータであると考え、その点間の距離を用いて評価することができる。本プログラムでは、その距離とその点の原点からの距離の比に対してしきい値を設けて、過渡的なデータは排除している。ただし、その際、そのしきい値をいくつに設定するかが問題となるため、試験データを用いて最適な値を明らかにする。

3.1.2 主成分分析⁴⁾

主成分分析はベクトルの次元を削減する方法であり、主成分分析を行うことで扱うデータ量を大幅に削減できる。また、多次元データを2次元化すれば、平面上の点として特徴ベクトルを示すことができるため、人間が直感的にデータの傾向を把握することができる。さらに、後述する最近傍法は次元が高いと性能が悪くなることが知られており、適度に次元を削減することが望ましい。よって、前処理として主成分分析を行う。

機械学習を用いた異常検知方法では、事前に測定された正常データを学習データとして診断プログラムに与える。そして、学習データから得られる情報を基に、テストデータの診断を行う。そこで、まず、学習データに対して主成分分析を実行し、学習データの主成分を求めるとともに各成分の分散が1になるように標準化する変換行列を求めておく。診断時には、その変換行列を用いてテストデータの主成分を求める。そして、寄与率の大きい方から選んだ複数個の主成分からなるベクトルを特徴ベクトルとして、異常検知に用いる。その際、いくつの主成分を選ぶかで異常検知の性能が変化するため、最適な主成分の数を明らかにする必要があり、これについても試験データを用いて明らかにしていく。

3.2 異常検知方法

3.2.1 機械学習を用いた異常検知方法

機械学習を用いた異常検知では、学習データとして正常データのみが与えられる場合と、異常データが正常データとともに与えられる場合がある。駆動用機器の場合、あらかじめ検出すべき故障を列挙し、それらの故障に対応する異常データを用意することは困難である。そのため、正常データのみを与えて、それとの比較により異常を検知することが求められる。このような問題は1クラス分類問題と呼ばれる。1クラス分類問題に対する方法として、最も単純な方法である最近傍法(NN)を応用したNNDD(Nearest Neighbor Data Description)⁵⁾があり、本論文ではこの方法を用いることとする。機械

学習分野ではこの方法以外にも様々な方法が提案されているが、本稿ではNNDDのみを扱うこととし、その他の方法の適用については今後取り組んでいきたいと考えている。

3.2.2 NNDD

最近傍法は、テストデータを全ての学習データと比較し、最も近い学習データと同じクラスに分類する方法であり、分類問題に用いられる最も単純な方法である。これを異常検知に応用した方法がNNDDである。

NNDDでは、図2のように各特徴ベクトルが多次元空間上の点の座標と考える。そして、テストデータXと最も近い学習データAと、その学習データAに最も近い学習データBを探し出し、X～A間の距離をA～B間の距離で割った値を異常検出に用いる方法である。学習データ間の距離に比べてテストデータと学習データの距離が大きければ、そのテストデータは異常状態に対応するものであると考えることができるため、この値を異常の度合い(異常度)を計算するために用いる。

しかし、この方法では、学習データに異常データが混入している場合には、その異常データが異常判定に用いられてしまい、適切に異常判定ができなくなることが想定される。そのため、最も近い学習データ以外にも、2番目に近いデータ、3番目に近いデータ等に対して同様の処理を行い、その距離の比の平均値を最終的な異常度の算出に用いることにより、異常度の算出を安定的に行うことができるようになると考えられる。その際、異常度算出に用いるテストデータに最も近い学習データの数(近傍データ数)をいくつにするかが本方法のパラメータとなるため、その最適な数値を設定することが課題となる。そこで、このパラメータについても試験データを用いて最適な数値を明らかにする。

最終的な異常度は、異常と判定される場合に異常度が正の値、正常と判定される場合には異常度が負の値となるようにするため、距離の比の平均値から1を引いた値を最終的な異常度として用いることとする。




図2 NNDDを用いた異常検出

3.3 ROC曲線を用いた異常検知性能の評価方法

異常検知性能を検証するためには、まず異常データを異常と判別できるかどうかを検証する必要がある。しか

特集：車両技術

し、診断プログラムで計算される異常度があるしきい値を超えた場合に異常と判別する場合には、そのしきい値を小さくしていくと、多くの異常データを異常と判別し易くなる代わりに、正常な状態も異常と判別してしまうようになる。そのため、異常検知性能の評価を行うためには、異常データを異常と判別するだけでなく、正常データを異常と判別しないことを評価する必要がある。

このような評価を行う方法としてROC曲線(Receiver Operating Characteristic Curve)⁴⁾を用いた方法がある。ROC曲線を異常検知性能評価に用いる場合には、横軸を誤検知率(正常データを異常と判定した割合)、縦軸を検知率(異常データを異常と判定した割合)としてROC曲線を作成する。まず、正常データと異常データからなるテストデータに対して診断プログラムで異常度を計算する。そして、しきい値を変化させていった際の誤検知率と検知率を平面上にプロットしていくと図3のようなROC曲線が得られる。

ROC曲線が得られれば、異常検知性能を端的に表わすことができる評価指標として、ROC曲線のAUC(Area Under the Curve)を用いることができる。AUCはROC曲線より下の領域の面積である。理想的な異常検知が可能な場合には、ROC曲線は原点と左上の点(誤検知率0%、検知率100%)と右上の点を結ぶ折れ線になるが、このときのAUCの値は1となる。よってAUCが1に近いほど異常検知性能が高いと評価することができる。

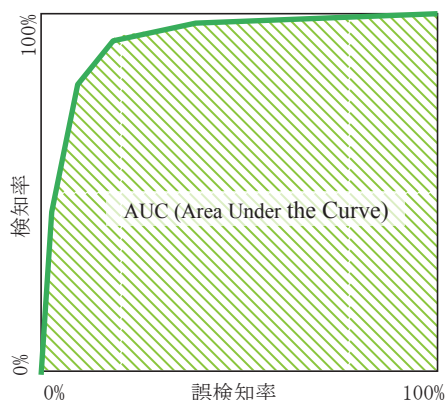


図3 ROC曲線による異常検知性能の評価

4. 走行試験による検証

4.1 走行試験

状態監視装置と診断プログラムの検証を行うため、気動車の走行試験において振動測定を行った。振動測定では学習データに用いる正常状態での振動と、異常データに用いるための異常模擬時の振動を測定する。異常検知性能を検証するためには、故障状態で走行するのが良いが、その実施は安全上の理由等から困難である。そのた

め、エンジンに取り付けられているコンプレッサの動作で異常模擬を行うこととし、以下の二つの走行条件について走行試験を行った。

- ①コンプレッサ動作有り(異常模擬)
- ②コンプレッサ動作無し(正常状態)

走行試験では、上記の2つの異なる走行条件において、停止状態から速度45km/hまで加速し、その後ブレーキをかけ車両を停止させる走行を行い、その際のエンジン振動を測定した。走行は各条件についてそれぞれ5往復行った。そのうち、②の測定データのうち3往復分を学習データとして用い、残りの2往復分を正常データのテストデータ、①の測定データを異常データのテストデータとして用いることとした。エンジン振動は、エンジンと変速機の合わせ面近くにあるマウント用プレートに圧電式の振動加速度センサを仮設して、前述の状態監視装置を用いて測定した。また、車両信号からは力行ノッチや列車速度等を測定した。

4.2 診断プログラムの検証

4.2.1 定常状態の抽出

以下では、診断プログラムによる各処理の効果を確認していく。まずは、前処理として行われる定常状態の抽出について示す。定常状態の抽出では、前後のデータとの差についてしきい値を設けており、このしきい値により、最終的な結果がどのように変化するかを確認する。図4にしきい値を変化させた場合のROC曲線を示す。

ROC曲線を描くためにはその後の処理も全て行う必要があるため、それらの処理のパラメータも値を仮決めした。まず、主成分分析についてはデータの分布を可視化するために主成分の数を2として実施している。異常検知は最も単純な方法としてNNDDで使用する近傍データ数は1とした。

図4によるとしきい値を0.2とするとROC曲線は理




図4 定常状態抽出のしきい値変更時のROC曲線

想的な形になり、AUC の値もほぼ 1.0 になるが、それ以外の場合には AUC の値は 0.7 ~ 0.8 と低い値となっている。

このときのデータ分布の様子を確認するため、しきい値 1.0 と 0.2 の場合について、定常状態の抽出と主成分分析を行った後のデータをプロットした結果を図 5 に示す。

図 5 から確認できるように、しきい値 1.0 の場合（定常データの抽出をほとんど行わない場合）には、正常データと異常データの分布が重なりあっており、明らかに両者を判別することは困難である。その一方で、しきい値 0.2 の場合には、異常データと正常データは重ならず分布しており、学習データと正常データがほぼ同じ位置に分布している。この結果、異常データは明確に判別することができ、図 4 に示されたような理想的な ROC 曲線が実現できることがわかる。

なお、定常状態の抽出により抽出されたデータに対応する運転状態を確認すると、それらはいずれもアイドリ

ング状態であった。つまり、今回の振動測定結果では、容易に異常模擬状態を区別できるのはアイドリング時で振動の状態が安定している場合のみであるといえる。

4.2.2 主成分分析

次に、主成分分析に関して、使用する主成分の数をパラメータとしたときの異常検知性能の変化について調べる。まず、定常状態抽出のしきい値を 0.2、近傍データ数を 1 として主成分の数を変化させたときの ROC 曲線を図 6 に示す。

前章で確認した通り、主成分の数が 2 の場合にはほぼ理想的な ROC 曲線となる。これに対し、主成分の数を増加させていくと、3 から 5 までは AUC の値が低下していくが、主成分の数を 6 以上にした場合には AUC の値はほぼ 1.0 になっている。これは、第 3 主成分から第 5 主成分までは今回の異常判別に寄与しない成分であるが、第 6 主成分は異常判別に寄与する成分であったためである。





図 5 データの分布
(上：しきい値 1.0, 下：しきい値 0.2)

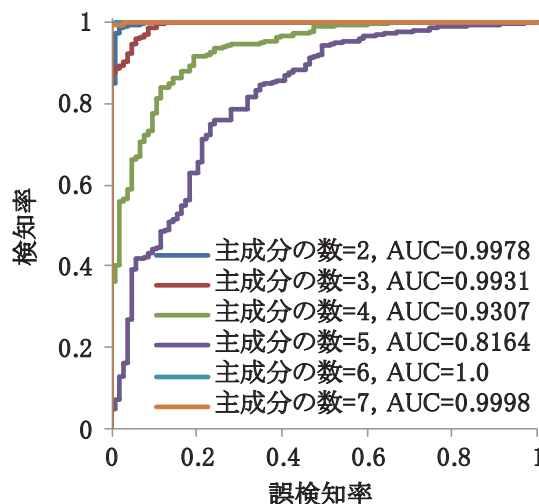


図 6 主成分の数変更時の ROC 曲線

4.2.3 NNDD

次に NNDD のパラメータである近傍データ数が ROC 曲線に与える影響について確認する。定常状態抽出のしきい値が 0.2 の場合には近傍データ数に関わらず AUC が 1 となる結果となった。そこで、しきい値を 0.4 として、学習データやテストデータに異常判別が困難なデータを混入させて作成した ROC 曲線を図 7 に示す。このときの主成分の数は 6 としている。

図 7 では、近傍データ数を増やしていくと AUC が向上していく傾向が確認でき、期待する効果が得られていることが確認できる。ただし、近傍データ数 4 以上では ROC 曲線の形状はほぼ同じであるため、近傍データ数は 4 程度で十分であると考えられる。

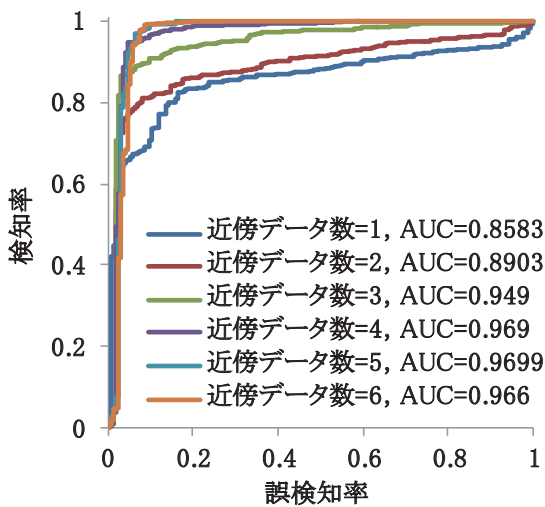


図7 近傍データ数変更時のROC曲線

4.2.4 異常度の算出

最後に、これまでに検討した各パラメータの値を組み合わせて、テストデータの異常度を算出した結果を図8に示す。パラメータの値は、定常状態のしきい値を0.2、主成分の数を6、近傍データ数を4とした。

図8から確認できるように、本診断プログラムで計算される異常度により、正常データと異常データが明白に区別できることが分かる。以上により、提案する方法により車両走行時の振動から機器の状態が判別できることを示すことができた。




図8 異常度の算出結果

5. おわりに

鉄道車両の駆動用機器の状態監視方法として、振動のオクターブバンド分析結果に対して機械学習の方法を適用して異常検知を行う方法を提案し、ディーゼル機関を対象とした現車試験で取得したデータにより、提案方法の有効性を検証した。

その結果、異常検知を行うための前処理として、定常状態の抽出と主成分分析を行い、適切な主成分の数を選択することが、検知性能の向上に有効であることが分かった。今回の検討では、主成分の数を6とすることが良いことが分かった。

また、機械学習の方法であるNNDDにより異常データと正常データを明確に判別できることが確認できた。そして、学習データに異常なデータが混入した場合にも安定して異常検知を行うためには、近傍データ数を4程度まで増やすのが良いことが分かった。

今回の一連の検証により、提案方法により期待した通り異常検知を行えることが確認できた。今後も引き続き研究開発を行い、高性能な状態監視システムの実現を目指していきたい。

謝辞

本論文中の走行試験の実施においては、西日本旅客鉄道株式会社の皆様にご協力を頂きました。ご協力頂きました関係者の皆様に感謝申し上げます。

文献

- 1) P. Pennacchi, S. Bruni, S. Chatterton, P. Borghesani, R. Ricci, D. Marinis, A. Didonato, F. Unger-Weber : A Test Rig for the Condition-Based Maintenance Application on the Traction Chain of Very High Speed Trains, WCRR2011, 2011.
- 2) 大庭拓也, 山田幸一, 岡田信之, 相馬仁, 谷藤克也 : 振動解析に基づく新幹線台車の状態監視, 日本機械学会論文集 (C編) 75巻757号, pp.93-101, 2009
- 3) 大庭拓也, 山田幸一, 岡田信之, 谷藤克也 : 振動解析に基づく新幹線台車の状態監視 (第2報, 前後台車比較及び振動ピーク継続性の検証), 日本機械学会論文集 (C編) 76巻769号, pp.27-35, 2010
- 4) Gavin Hackeling : Mastering Machine Learning with scikit-learn, Packt Publishing, 2014.
- 5) David M.J. Tax : One-class classification, Ph.D. thesis, Delft University of Technology, 2001.