

振動のオクターブバンド分析を用いた駆動用機器の状態監視手法

車両制御技術研究部 動力システム研究室
主任研究員 近藤 稔

1. はじめに

鉄道車両の駆動用機器は、走行状態に応じて運転状態が複雑に変化することに加え、走行に伴う振動も発生するため、単純に振動の大きさ等で異常検知を行うことが難しい。そこで、鉄道総研では振動のオクターブバンド分析と機械学習を組み合わせることで、複雑な振動の変化にも対応できる状態監視手法を考案し、その有効性について現車試験で検証を行った。本発表ではその結果について発表する。

2. 振動による状態監視システムの概要

駆動用機器の動作や振動は複雑であるが、そ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る。つまり、異常振動を検知するには、正常時の振動の音色を記憶しておき、監視している振動の音色がそれと比較して異なるものであるかどうかを判定すれば良い。そこで、音色をデータとして表現するのに適しているオクターブバンド分析結果を異常検知の基になるデータとして用いることとした。また、事前に記憶した正常時のデータと比較するという考え方に基づく異常検知方法は、機械学習分野において様々な方法が提案されている。そこで、それらの方法とオクターブバンド分析を組み合わせることで異常な振動を検知する状態監視システムを開発することとした。

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(図1)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。

なお、状態監視用にオクターブバンド分析を行う装置は一般に市販されてはいないため、今回新たに試作して試験に用いた。また、実際に異常検知を行う診断プログラムも試作した。本発表では、その診断プログラムを現車試験結果に適用した結果を示しながら、診断プログラムの各処理とその有効性について説明していく。

3. 走行試験による振動データの取得

診断プログラムの検証に用いる振動データを取得するため、気動車の走行試験においてディーゼルエンジンの振動測定を行った。振動測定では学習データとして用いる正常状態での振動




図1 状態監視システムの構成

と、異常データとして用いるための異常模擬時の振動を測定する。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、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）の二つの動作条件について走行試験を行った。

走行試験では、各条件において、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た車両を停止させる走行を 5 往復ずつ行った。そのうち、②の測定データの 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エンジン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. ROC 曲線を用いた異常検知性能の評価方法

異常検知性能を評価するためには、異常データを異常と判別できた割合（検知率）を評価するのが良い。しかし、異常度がしきい値を超えた場合に異常と判別する場合、しきい値を小さくしていくと、検知率は高まるものの正常データも異常と判別（誤検知）してしまうようになる。そのため、異常検知性能の評価においては、検知率と誤検知率を同時に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)を用いた方法がある。具体的には、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する異常度を診断プログラムで計算する。そして、誤検知率を横軸にとり、検知率を縦軸にとって、しきい値を変化させていったときの誤検知率と検知率の変化を平面上にプロットする。すると図 2 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 2 ROC 曲線による検知性能評価

5. 診断プログラム

5. 1 定常状態の抽出

診断プログラムでは異常検知の前処理として、振動のオクターブバンド分析結果に対して定常状態の抽出と主成分分析を行っている。異常検知は前処理後のデータ（特徴ベクトルと呼ぶ）に対して行う。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音色による判別を目指しており、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運転状態の変化が多く発生するため、その際に生じる過渡的な振動のデータは排除することが望ましい。そこで、データを多次元空間上の点の座標であると考え、前後のデータとの距離と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することとした。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、図 3 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、後述する主成分分析については主成分の数を 2 とし、同じく後述する異常検知方法である NNDD (Nearest Neighbor Data Description) で使用する近傍データ数は 1 とした。

図 3 によるとしきい値を 0.2 とすることで ROC 曲線は理想的な形になり、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 と低い値となっており、しきい値は 0.2 とすることが適当であることが分かった。




図 3 定常状態抽出のしきい値変更時の ROC 曲線

5. 2 主成分分析

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、後述する異常検知方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。まず、学習データに対して主成分分析を実行して変換行列を求める。そして診断時には、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、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、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 4 に示す。




図 4 主成分の数変更時の ROC 曲線

前述の通り、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 の値が低下する。しかし、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。この結果、主成分の数は 6 が適当であることが分かった。

5. 3 異常検知方法 (NNDD)

正常データと比較して異常なデータを検出する機械学習の方法の一つに NNDD がある。NNDD では図 5 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 の最近傍にある学習データ A と、その学習データ A の最近傍の学習データ 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基に異常度を算出して異常検出に用いる方法である。この方法は非常に単純な考え方に基づいた実用的な方法であるため、今回の診断プログラムでは、この方法を用いる。




図 5 NNDD を用いた異常検出

単純に最近傍の点のみを用いると、学習データに異常データが混入した場合には、そのみ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。そのため、最近傍データ以外にも、2番目、3番目に近いデータ等に対して同様の処理を行い、その平均値から1を引いた値を最終的な異常度として用いる。その際、何番目に近いデータまで用いるか（近傍データ数）が問題となるため、近傍データ数を変化させたときのROC曲線を図6に示す。しきい値は最適値である0.2とすると常に理想的なROC曲線となって差が出ないため0.4とし、主成分の数は6としている。

図6では、近傍データ数を増やすとAUCが向上しており、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。

5. 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、テストデータの異常度を算出した結果を図7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7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。

6. 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と機械学習を組み合わせた異常検知方法を提案し、気動車のディーゼルエンジン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、提案方法を適切なパラメータの値とともに用いることにより、期待した通り異常検知を行うことができることが確認できた。今後も引き続き研究開発を行い、高性能で汎用性の高い状態監視システムの実現を目指していきたい。

文 献

- (1) 近藤，真鍋，高重，菅野：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，第29巻9号，2015




図6 近傍データ数変更時のROC曲線




図7 異常度の算出結果