

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

近藤 稔* 高重 達郎* 真鍋 慎一** 菅野 普*

Abnormality Detection in a Contaminated Diesel Engine by a Vibration Monitoring Method

Minoru KONDO Tatsuro TAKASHIGE Shinichi MANABE Hiroshi KANNO

Railway traction machines are essential parts for a train to run. Therefore, we are developing a condition monitoring system (CMS) that detects the failures of the machines in the early stage to prevent transport disorders. The CMS observes the vibrations of a machine and detects abnormal vibrations with a machine learning algorithm that is based on nearest-neighbor analysis. In this paper, we present an improvement of the algorithm and the result of a contamination test with a traction diesel engine, which was conducted to verify the performance of the CMS. The test result shows that the abnormal vibrations due to the contamination are clearly detected with the CMS.

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

ディーゼル機関（エンジン）を動力源に持つ気動車は、非電化区間を走行する鉄道車両として広く用いられている。エンジン等の駆動用機器が故障すると多くの場合には気動車の継続運行ができなくなるため、エンジンの異常を早期に検知して走行中の故障を未然に防ぐことが望ましい。

そこで、著者らはエンジン等の駆動用機器を対象として振動による状態監視方法の研究開発を行っている。これまでに、気動車での現車試験等により提案手法の有効性を確認した¹⁾。しかし、現車試験では機器を実際に故障させる試験は実施が困難であるため、機器故障時の異常振動に対する提案手法の有効性を検証できていなかった。そこで、エンジン単体での定置試験設備を用いて、実際にエンジンを故障させる試験を行った。具体的にはエンジンの潤滑油に異物を混入し、エンジンが異常摩耗した状態を作り出し、その際の振動の異常を提案手法により検知させる試験を行った²⁾。

著者らの提案手法では、振動のオクターブバンド分析結果に対して機械学習の手法を適用して異常検知を行う。その際に用いる機械学習の手法としては、近傍法の一つで比較的単純な手法である NNDD (Nearest Neighbor Data Description)^{1) 3)} と、機械学習分野における標準的な異常検知手法である OCSVM (One Class Support Vector Machine)^{2) 4) 5)} についてこれまでに検討してきた。

このうち、OCSVM については異物混入試験時の異常振動を検知できることを既に報告している²⁾。本論文ではもう一つの方法である NNDD でも同様に異常振動を検知できることを示す。

NNDD の基本的な有効性は現車試験結果を用いて検証できているが、しきい値等のパラメータ設定に課題がある。過去の報告では、異常データのサンプルが得られている前提条件のもとで、適切なしきい値を設定して異常判別が可能であることを示したが、実際には異常データのサンプルが得られるとは限らないため、正常データのみで適切なしきい値を設定して異常判別ができることが望ましい。そこで、今回は、この観点から NNDD の異常検知アルゴリズムの改良を行った上で、異常振動の検知を行う。

以下では、まず、状態監視システムについて簡単に説明し、次に、異常検知部の検証に用いる振動データを得るために行った異物混入試験について説明する。そして、その振動データを用いて通常の NNDD を用いて異常検知を行う場合の問題点を示し、異常検知アルゴリズムの改良案と、その適用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

以下では本論文が前提としてい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い、その結果を記録、送信する。

* 車両制御技術研究部 動力システム研究室

** 車両制御技術研究部 動力システム研究室
(現 西日本旅客鉄道株式会社)

特集：車両技術

そして、そのデータを、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目指しているため、車上で異常を検知して警報を出すことはせず、地上で分析を行う構成としている。

車上でオクターブバンド分析を行うことで、データ量の圧縮により通信や記録を容易にしながら全ての周波数帯を異常検知の対象とすることができる。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。




図1 状態監視システムの構成¹⁾

本研究開発のために試作した状態監視装置では、振動のオクターブバンド分析の結果を地上に送信する代わりに、取り外し可能な記録媒体に記録する仕様となっている。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おり、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様子は表1の通りである。

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

また、試作した診断プログラムは前処理部と異常検知部からなる¹⁾。前処理部では定常状態の抽出と主成分分析を行い、異常検知部では機械学習分野で用いられている方法を用いて異常検知を行う。前述の通り、異常検知の方法としては、これまでに最近傍法を応用した

NNDD と標準的な手法である OCSVM のそれぞれについて検討している。本報告では、このうち NNDD を適用した場合について報告する。

3. 異物混入試験

3.1 試験方法

異常検知法の検証を行うためには、実際に故障による異常振動が発生している実機で振動を測定し、その異常が検知できるかを確認するのが良い。そこで、実際の鉄道車両用エンジン（コマツ製、SA6D125-H-1A）を用いて、潤滑油に異物（SiC：炭化ケイ素）を混入した状態で運転することで異常摩耗を発生させ、その際の振動を測定する試験を行った。

試験はエンジン単体での定置試験とした。文献1)で報告した走行試験結果から、状態監視の観点からはアイドリング運転時の振動を用いることが良いことが分かっている。そのため、試験時の運転は全てアイドリングとした。振動の測定位置は図2に示すように走行試験の際と同じエンジンマウント部とし、上下方向の振動を圧電式の加速度センサで測定した。

SiC は運転時間の増加とともに追加し、表2に示すように徐々に濃度を増加させた。




図2 振動測定部位

表2 混入量から算出した SiC 濃度の変化

SiC 濃度 [%]	運転時間 [分]	累積運転時間 [分]
0.05	40	40
0.1	80	120
0.15	70	190
0.2	70	260
0.25	80	340
0.3	90	430
0.35	60	490
0.4	60	550
0.5	60	610

SiCを追加する際は、一旦エンジンを停止させて、SiCを潤滑油に混入した。また、潤滑油のサンプリングのため、10～30分間隔でエンジンを停止させてサンプリングを行った。なお、学習データとして用いる正常データを取得するため、SiC混入に先立ち、未混入時のエンジンをアイドリング運転させ、振動測定を行っている。

振動測定の結果については、5.3で詳述するように、時間の経過およびSiC混入量の増加とともに異常の度合いが大きくなる結果となった。しかし、エンジンが運転不能になることはなく、表2の通り運転が行われた。また、試験の際には通常の気動車で常時監視されている潤滑油温度、潤滑油圧力、冷却水温度の測定を行ったが、これらの測定結果からは異常は確認できなかった。


3.2 異物混入によるエンジンの損傷状況

異物混入により実際にどの程度エンジンが損傷したかを確認するため、試験終了後に分解調査を行った。その結果、図3に示す例のように、潤滑油により潤滑が行われているエンジン内部の各部で損傷が確認された。

図3左側はエンジンのクランク軸を支える主軸受（メインメタル）である。メインメタルは3層構造になっているが、表面層の摩耗が進み銅色の中間層が表れかけていることが確認できる。図3右側はコンロッドとクランク軸を結合するコンロッドの大端部のメタルである。このメタルもメインメタルと同様の3層構造となっているが、表面層が摩耗した結果、銅色の中間層が表れていることが確認できる。

これら以外にも、カム軸の摺動部やシリンダライナーでも摩耗が確認された。また、排気マニホールドに潤滑油が入り込む等、オイル上がりの痕跡が確認された。

これらの損傷状況はエンジンの継続使用が許容されないレベルであり、状態監視装置により異常が検知されることが望まれる損傷状況であった。



左：主軸受（メインメタル）（下側）
右：コンロッド大端部メタル（ロッド側）

図3 エンジン内部の損傷状況

4. NNDDによる異常検知の課題

4.1 NNDDの概要¹⁾

NNDDを用いた異常検知の課題について説明する前に、文献1)で用いたNNDDによる異常度計算法について簡単に説明する。NNDDでは、図4のように振動を表わすデータを多次元空間上の点の座標と考える。本状態監視システムにおいては、振動のオクターブバンド分析した結果に主成分分析等の前処理を施したものが異常検知に用いる振動を表わすデータとなる。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間の距離で割った比を異常検出に用いる。テストデータXが異常状態に対応するものであれば、A～B間の距離に比べてX～A間の距離が大きくなると考えることができるため、この距離の比が異常の度合いを表わすと考えることができる。




図4 NNDDを用いた異常検出

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ず、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、3番目、… k_{NN} 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化させる。このとき用いるデータの数 k_{NN} を近傍データ数と呼ぶ。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している。

4.2 NNDDによる異常検知境界の課題

異物混入試験結果の正常データに対してNNDDを適用して、異常検知境界を作成した結果を図5に示す。異常検知境界は異常度0に対応する等値線を描くことで作成できる。また、参考のため、OCSVMによる異常検知境界²⁾を作成した結果を図6に示す。パラメータは以前の検討結果^{1) 2)}を参考にして、近傍データ数を4、前処理の定常状態抽出のしきい値を0.2とし、主成分の数は可視化のため2としている。

特集：車両技術

図5によると黒線により示した作成された異常検知境界により囲まれている領域は非常に小さく、大半の正常データが異常と判定される結果になっている。異常検知境界はOCSVMにより算出した図6のように大半の正常データを無駄なく囲むことが望ましいが、図5ではそのようになっていない。

ただし、異常データの異常度は正常データの異常度よりも大きくなる傾向があること自体は変わらないため、ゼロよりも大きい適切な値をしきい値として設定することで異常検知が可能である。図5中に赤線で示した異常検知境界は異常度2に対応する等値線であり、異常判定のしきい値を2とした場合に相当する。この場合には大半の正常データを囲む境界が得られている。

しかし、異常データが得られている場合には、文献1)で示されているように、実際に異常データの異常度を算出することで適切な異常判定のしきい値を設定することができるものの、正常データしか無い場合には適切なし

きい値の設定が困難である。鉄道車両の状態監視システムでは、事前に十分な異常データが得られない可能性が高い。また、今回のように徐々に状態が変化していく場合には、異常データが得られていても適切なしきい値を設定することが難しい。よって、正常データのみでも適切な異常検知境界を作成できるようにNNDDを改良することが望ましい。

ここで、改めて従来のNNDDで計算される異常度について考える。Xが正常データの場合、X～A間の距離はA～B間の距離と同程度になり異常度は0となることが期待される。ただし、実際には統計的なばらつきがあるため、正常データに対する異常度はゼロを中心として分布することになり、異常と判定される正常データも多くなる。また、2番目、3番目に近いデータを使う場合にはX～A間の距離が大きくなるにも関わらずA～B間の距離は1番近いデータまでの距離であるため、異常度が正になる可能性がさらに高くなる。その結果、正常データの大半が異常度検知境界の外側に位置する結果になったものと考えられる。

そこで、大半の正常データの異常度が負になるように、次章で述べるように異常度の算出方法を改良する。

5. NNDDの改良および異常度計算結果

5.1 異常度計算法の改良

まず、近傍法の基礎となるデータ間距離の特徴を把握するため、その頻度分布を調査する。学習データの各データについて最近傍データとの距離を算出し、そのヒストグラムを作成した結果を図7に示す。

図7によると、作成されたヒストグラムはピークが左側に寄った対数正規分布等に似た分布になっている。データ間の距離は最小値がゼロで制限されているため、左右対称の分布にはならず、このような分布になっていると考えられる。




図5 NNDDによる異常検知境界

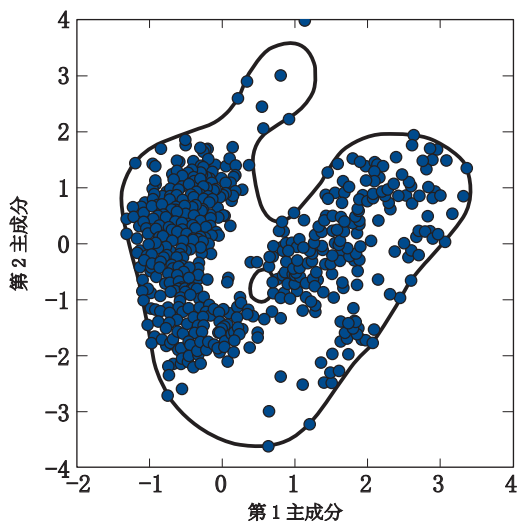


図6 OCSVMによる異常検知境界²⁾




図7 データ間距離のヒストグラム

この分布の大半（例えば 99%）のデータが正常と判定されるようにするためには、このデータ間距離の大半の値よりも大きな値を基準距離として設定し、図 4 の A ~ B 間距離の代わりに用いれば良いと考えられる。そこで、学習データのデータ間距離を値が小さい順に並べ、データ数の 99% の順位に位置するデータのデータ間距離を基準距離 d_1 とする。

同様に、最近傍のデータのみでなく、 k 番目に近いデータも利用する場合には、学習データの各データについて、 k 番目に近いデータとの距離を算出し、それを小さい順に並べて 99% の順位に位置するデータのデータ間距離を求めて k 番目に近いデータに対する基準距離 d_k とすれば良い。

k_{NN} 番目に近いデータまで用いる場合、これらの量を用いて、式 (1) のようにデータ \mathbf{x} の異常度を算出する関数 f を定義できる。

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

ただし、 $\text{NN}_k(\mathbf{x})$ はデータ \mathbf{x} に k 番目に近い学習データを表わしている。

このようにすることで、大半の正常データに対して異常度の値が負になることが期待できる。

5.2 改良 NNDD による異常検知境界の作成結果

改良 NNDD により適切な異常検知境界が作成できることを確認するために、式 (1) により計算される異常度により異常検知境界を作成する。作成のために設定したパラメータの値は 4.2 節と統一し、定常状態抽出のしきい値を 0.2、主成分の数を 2、近傍データ数 k_{NN} を 4 とした。作成した異常検知境界を図 8 に示す。

図 8 によると、作成された異常検知境界は、図 6 の OCSVM による異常検知境界と同じように大半の正常




図 8 改良 NNDD による異常検知境界

データを囲む滑らかな境界となっている。また、外れ値と見られる一部の学習データが決定境界の外側になる結果となっており、学習データに異常データが混入していた場合でも、その影響を低減して適切な決定境界を作成できることが確認できる。

OCSVM では学習データのいくつかを通る境界が作成されるため、そのテストデータがその学習データの近傍である場合、ほとんど学習データと同じデータであっても境界の外側であれば異常と判定される。これに対して、改良 NNDD では境界線が学習データから少し離れた位置にあるため、学習データの密集した場所の近傍にあるテストデータは正常と判定される。信頼される状態監視システムを実現するためには、敏感すぎる異常検知は望ましく無いため、改良 NNDD のこの性質は望ましい。また、改良 NNDD は OCSVM と比較して、異常検知境界の作成根拠が分かり易い。改良 NNDD はこのような優れた面がある。その一方で、学習データ数が増加した場合には NNDD は異常度計算にかかる時間が飛躍的に増大するおそれがあり、その点では OCSVM が優れていると予想される。そのため、最終的にどのアルゴリズムを異常検知に採用するかは、実際に営業車両等で大量のデータを取得して各アルゴリズムを適用して判断していきたいと考えている。

5.3 改良 NNDD による異常度計算結果

次に、改良 NNDD により異物混入時の異常度を計算した結果を図 9、図 10 に示す。図 9 は改良 NNDD により異常度を算出した結果を、累積運転時間を横軸にしてプロットしたものである。また、図 10 は図 9 における累積運転時間が 5 時間から 6 時間の部分を拡大したものである。図では異常度と併せて、参考のために混入量から算出した SiC 濃度も示している。

この異常度計算では、前処理は以前の検討結果を参考にして、定常状態の抽出をしきい値 0.2 で行い、主成分の数は 6、近傍データ数を 4 とした。

図 9 によると、累積運転時間および SiC 混入量の増大とともに異常度が増加していることが確認できる。これは、累積運転時間の増大とともに摩耗が進行して状態変化が起きて振動が変化しており、提案する異常検知手法によりその振動の変化を適切にとらえることができていたため、異常度が増大しているものと考えられる。

なお、図の中央付近を見ると、累積運転時間が 5 時間を過ぎた時点で一旦異常度が下がり、負の値になっていることが分かる。この部分を拡大したものが図 10 である。試験は 2 日間に渡り行われたため、累積運転時間が 5 時間 40 分の時点で初日の試験が終わり、一晩経った二日目の朝から試験が再開されている。運転を止めた状態で長時間経過することで、潤滑油中の SiC や摩耗粉が

特集：車両技術

沈殿するため、再開時には異物や摩耗粉が少ない潤滑油がエンジンに供給されると考えられる。そのため、試験を再開した直後は異常度が負になり、正常データなみに異常度が小さくなっているものと推定できる。そう考えると、少なくとも試験の前半については、観測された異常振動は、摩耗によるエンジン部品の寸法変化に起因するものではなく、異物と摩耗粉により潤滑状態が変化したことに起因していると推定できる。

なお、累積運転時間が5時間40分の点以外にも、異常度が下がっている点がいくつかあるが、これらは潤滑油の調査のためにエンジンを停止した時間に対応するものであり、二日目の朝と類似の状況が発生していると考えられる。

6. おわりに

振動による駆動用機器の状態監視方法について、その有効性の検証と改良を行う目的でディーゼル機関の潤滑油に異物を混入する試験を行った。また、状態監視の異常検知方法について、従来の方法を改良して、データ間距離の分布に着目した新しい異常検知方法を提案した。

試験結果に対して提案手法を適用したところ、異常検知境界が適切に作成されることが確認できた。また、累積運転時間およびSiC混入量の増大とともに異常度が増加している結果となり、提案手法により適切に異常度が評価できることが確認できた。

今後、より実用的な状態監視方法の確立を目指し、引き続き研究開発を進めていく予定である。

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, 真鍋慎一, 高重達郎, 菅野普, 振動による駆動用機器の状態監視法, 講演番号 1201, 第 22 回鉄道技術連合シンポジウム (J-RAIL2015), 2015
- 3) David M.J. Tax : One-class classification, TU Delft, Delft University of Technology, 2001.
- 4) B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson, Estimating the Support of a High-Dimensional Distribution, *Neural Computation*, Vol. 13, No. 7, pp. 1443-1471, 2001.
- 5) F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, Scikit-learn: Machine learning in Python, *The Journal of Machine Learning Research*, Vol. 12, pp.2825-2830, 2011.




図9 異常度の計算結果

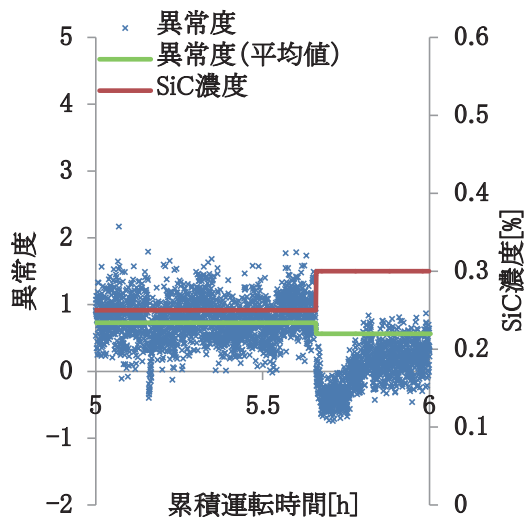


図10 異常度の計算結果 (拡大図)