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

近藤 稔^{*1}

Machine diagnosis for railway vehicle equipment using anomaly detection method with octave band vibration spectra

Minoru KONDO^{*1}^{*1} Railway Technical Research Institute
2-8-38 Hikari-cho, Kokubunji-shi, Tokyo 185-8540, Japan

Received: 27 December 2017; Revised: 28 March 2018; Accepted: 10 May 2018

Abstract

Railway vehicles are equipped with many kinds of machines such as traction diesel engines and their failures sometimes lead to service disruptions and accidents. Vibration monitoring systems are expected to prevent their failures by detecting their abnormalities at an early stage. In order to make an effectual action after abnormal vibration detection, it is necessary to make a root cause diagnosis. To address this issue, a simple diagnosis method is proposed in this paper. In the method, a measured vibration octave spectrum is divided into three frequency bands and abnormality detections are conducted for the spectra to narrow down the root cause of the vibration. A one class classification method, which is an anomaly detection method in machine learning, is used in the abnormal vibration detection to make a general purpose vibration monitoring system. In addition, the ratios of abnormal vibration are calculated for the three frequency bands to show the progress of the fault. The effectiveness of the method is verified using vibration data acquired on simulated abnormality tests of traction diesel engines, i.e., auxiliary drive shaft failure test and engine abrasion test. The test results show that the proposed method is effective in detecting the abnormality and diagnosing the cause and the degree of the failure.

Keywords : Machine diagnosis, Octave band analysis, Machine learning, Abnormality detection, Traction machines

1. 緒 言

鉄道車両では、電車の主電動機や減速機、気動車のエンジン、変速機、減速機、補機駆動装置といった回転機械が用いられている。これらの車両機器の異常を早期に検知して故障や破損を未然に防止できれば、鉄道の信頼性・安全性を高められる。一般に回転機械の状態監視には振動による方法が効果的であるため、著者らは振動を用いた車両機器の状態監視法の研究開発を行っている。

振動を用いた機器の状態監視はプラントの機器等を対象にして広く行われており、振動速度の実効値等を測定し簡易診断を行う場合が多い(牧, 1983)(豊田, 1991)。一方、鉄道車両用機器では、機器の動作状態が車両の運転状態に応じて変化する。走行に伴う振動も機器の振動に重畳するため、単純な振動速度による状態監視は難しい。そのため、空間バンドパスフィルタで電車の駆動用機器の回転速度に対応する成分を取り出して走行区間毎に評価を行う方法(大庭他, 2009)(大庭他, 2010)や、GPSにより同じ場所を走行した際の振動を抽出する方法(Corni et al., 2015)等が提案されている。

一方、振動測定による診断と同じく広く用いられている検査方法として、聴音棒等により異音を調べる官能検査があり、鉄道車両機器の検査でも用いられている。また、鉄道車両機器の異常は乗客や乗務員が異音を感じて発見される場合が多い。乗客が異音を感じる事からも分かるように、異音の検知には機器に関する専門知識は不

要であり、正常時の音を知っていれば良い。人が異音を検知する際には、単純な音の大きさではなく、周波数成分に関する情報を含む音色も評価するため、走行音が重畳している場合にも異常を検知できるものと考えられる。

もし、人が異音を検知するように異常振動を検知できれば、鉄道車両機器にも適用可能な検知性能が高く汎用性の高い異常検知法が実現できると考えられる。そこで、著者らは振動のオクターブバンド分析と1クラス分類を組み合わせて異常振動を検知する方法を提案し、検証試験によりその効果を確認してきた(近藤他, 2015a) (近藤他, 2015b) (近藤他, 2016) (近藤他, 2017a)。振動と機械学習を組み合わせた機器の異常検知については様々な方法が提案されている(Hayton et al., 2000) (Widodo and Yang, 2007) (Zhou, 2013) (蛭田他, 2015)が、オクターブバンド分析と1クラス分類(Tax, 2001)を使用している点が著者らの方法の特徴である。人間が異音を検知するように異常振動を検知することを目指したため、振動や音の音色をデータ化する方法として、人間の感覚に近い周波数分析法であるオクターブバンド分析を用いた。また、人間が正常時の音を基準にして異音を検知するのと同様の処理を行うために、機械学習の異常検知方法である1クラス分類を用いた。鉄道車両では異常時のデータを事前に取得する事が極めて困難であるため、正常時のデータのみを学習データに用いる1クラス分類が適している。

著者らの方法では図1に示すような状態監視システムを想定している。本システムでは、対象機器に取り付けた振動センサの信号を車載の状態監視装置でオクターブバンド分析し、その結果を地上側に送信してコンピュータ上に蓄積する。そして、コンピュータ上において機械学習を用いた診断プログラムで異常の有無を診断する。本システムにより異常を早期に検知できるようになれば、車両の運用や検査の計画変更により機器故障による輸送サービスへの悪影響を減少できると期待される。

Fig. 1 Schematic diagram of the condition monitoring system. Vibration sensors are attached on the target equipment and octave band analysis is conducted on measured vibration in the on-board condition monitor. Then the analysis result is transmitted to the computers on the ground side. The vibration data are stored in the computer and analyzed with the diagnostic program which using machine learning to detect abnormality and diagnose the root cause of the abnormality.

この異常振動検知法は正常時の振動データのみに基づくため、様々な機器に適用できる汎用性の高い方法となっている。その反面、この方法ではどのような故障でも同じように異常検知するため、具体的な故障の内容が分からず異常検知後の対処を決めかねるという問題があり、実用上の大きな課題となる。

一方、振動のオクターブバンド分析結果には振動の周波数に関する情報が含まれているため、これを用いて発生している異常の種類をある程度特定できる可能性がある。そこで、著者は振動のオクターブバンド分析結果のデータを周波数帯毎に分割し、分割されたデータに対してそれぞれ異常検知を実施して、異常振動の発生している周波数帯を特定する方法を提案している(近藤, 2017b)。異常の発生に伴う振動の周波数は、その異常の原因によって異なるため、異常振動の周波数帯から異常の原因を絞り込める。

また、著者らの方法では、1秒毎にオクターブバンド分析を実施するため、1秒毎に異常度が算出される。しかしながら車両の運用や検査の計画を立てる担当者が、全ての車両の全ての機器について、1秒毎の異常度を確認するのは現実的ではない。そのため、例えば1日毎に異常度の算出結果を集約して、異常の有無や程度を端的に表現する指標が求められる。その際には、運用や検査の計画を立てる参考とするために異常の進行度合いが分かる指標が望ましい。

そこで、本論文では周波数帯毎に異常振動検知を行って得られる異常度を集約する指標として、異常振動の割合を示す異常振動率を提案する。異常度は異常の程度を表しているが、最大値が不明であるため、その値から異常の進行度合いを判断し難い。これに対し、異常振動率は上限値が 100% であるため、異常の進行度合いを判断し易い。この指標を周波数帯毎の異常振動検知と組み合わせれば、異常の種類と進行度合いを簡易に診断できると考えられる。本論文では、過去に行った異常模擬試験結果に対して周波数帯毎に異常振動率を算出した結果を示し、提案方法の有効性を検証する。以下では、オクターブバンド分析と 1 クラス分類を用いた異常振動検知、周波数帯毎の異常検知による診断、異常模擬試験について紹介し、最後に異常振動率の提案と異常模擬試験結果への提案方法の適用結果を示す。

2. オクターブバンド分析と 1 クラス分類を用いた異常振動検知

2・1 オクターブバンド分析と 1 クラス分類を用いた異常振動検知の概要

これまで開発してきたオクターブバンド分析と 1 クラス分類を用いた異常振動検知(近藤他, 2015a)(近藤他, 2016)では、正常時の振動データ(オクターブバンド分析結果)を学習データ(Training data)として与え、診断対象となる振動データであるテストデータ(Test data)が正常な振動に該当するかどうかを機械学習の 1 クラス分類を用いて判別する。1 クラス分類にはいくつかの方法(Tax, 2001)があるが、本論文では近傍法(Nearest Neighbour Method)に基づく方法を用いる。

具体的な処理としては、車載の状態監視装置内で、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 1/12 オクターブバンド分析を行う。次に、診断プログラムで、その分析結果に対して主成分分析(Principal Component Analysis, PCA)と白色化(Whitening)の処理を前処理として行う。そして、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てプロットする。もし、二つの振動が類似であればそれに対応する二点の座標はお互いに近い位置にプロットされると考えられる。そのため、正常時の振動が安定してお互いに類似していれば、それに対応する正常データを多次元空間上にプロットした際には、図 2 のように多次元空間中に密集した点の集合が得られる。

そこで、異常検知を行うためには、まず、正常時の振動から上記の処理により算出された正常データを学習データとして与え、多次元空間上にプロットする。そして、評価対象となる振動についても同じ処理を行い、得られたテストデータを同じ多次元空間上にプロットする。さらに、そのテストデータ(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)との距離が大きい場合には異常であると判断する。

なお、診断プログラムでは主成分分析や近傍法を用いているが、これらを実行するためのプログラムが機械学習のライブラリである scikit-learn (Pedregosa et al., 2011)で提供されており、本論文ではそれらを利用している。

Fig. 2 Schematic diagram of the abnormal vibration detection method. Octave band analysis is conducted on each one second waveform. Then the analysis results are transformed to feature vectors using principal component analysis. Finally, the feature vectors are used for the abnormality detection using a one class classification method which is based on a nearest neighbor method.

2・2 主成分分析と白色化

ここで、前処理として行っている主成分分析と白色化について説明する。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。

主成分分析では多次元空間において直交座標軸を回転させ、データの第一軸方向の成分（第一主成分）の分散が最大となる方向に、第一軸の方向を定める。そして、第二軸については、第一軸に直交する方向の中でデータの第二軸方向の成分（第二主成分）の分散が最大となる方向に第二軸の方向を定める。第三軸以下についても同様の手続きにより方向を定める。主成分分析を行う過程では、全データの平均値や各座標軸方向の分散が算出されるため、それらを用いて白色化処理を実施できる。

主成分分析ではデータの分布を表現する際に寄与度の高い成分から抽出するため、はじめに抽出されたいくつかの成分のみを用いる事でデータの次元を削減できる。次元を削減できれば、必要なメモリや計算時間を削減できる。また、白色化により各主成分の方向の分散が1になり、データの分布は原点を中心にした球状の分布に近づくため、変動が大きい成分のみが支配的になる事を防げる。これらの利点があるため、本論文でもこれらを前処理として行う。その際、いくつかの主成分を選ぶかで異常検知の性能が変化するが、本論文では過去に行った検討(近藤他, 2015a)の結果を参考にして主成分の数は6としている。

主成分分析は学習データに対して実行し、各学習データの主成分を求めるとともに座標変換を行うための変換行列を求める。そして、異常検知の際にはその変換行列を用いてテストデータの主成分分析と白色化を行う。

2・3 近傍法による異常度計算

次に、異常度計算について具体的に説明する。前述の通り、異常度計算においてはテストデータ（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 ）との距離を用いる。その距離が大きい場合にはそのテストデータはどの学習データとも大きく異なる事を意味しているため、異常であると判断できる。その際に異常判定をするための閾値を基準距離と呼ぶ。本論文においては、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基準距離を定めている。さらに、点 X と点 A 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定義すると、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。

ただし、この方法では点 A が学習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、平均した値を異常度とするのが良い。この k_{NN} を近傍データ数と呼ぶ。この場合には、次式によりテストデータ x の異常度を算出する関数 f を定義し、各テストデータについて k ($1 \leq k \leq k_{NN}$) 番目に近いデータとの距離を算出して異常度を計算する。

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

ただし、 $NN_k(x)$ はテストデータ x に k 番目に近い学習データであり、 d_k は k 番目に近いデータに対する基準距離である。主成分の数と同様に近傍データ数も異常検知性能に影響を及ぼすが、これについても過去の検討結果(近藤他, 2015a)を参考にして、本論文では近傍データ数を4としている。

このような方法を用いれば、観測された振動が正常時のどの振動とも異なる場合にのみ異常度が大きくなるため、正常時の振動が複雑に変化する場合であっても適切な異常検知が可能となる。また、この方法では正常時の振動データのみを必要とするため、事前に異常時の振動を把握しておく必要もなく、機器の設計情報を用いて機器ごとにパラメータを設定したりする必要も無い。そのため、機器や故障の種類を問わずに適用できる汎用性の高い方法である。その反面、どのような故障であっても異常振動が発生した場合には同様に異常度が大きくなるため、異常の原因が分からないという課題がある。

3. 異常振動の発生周波数帯による簡易診断

3・1 異常振動の発生周波数帯と原因の関係

前述の通り、単に異常を検知するだけでは異常の原因が分からないという問題がある。一方、振動の周波数分析を用いた機器の異常原因の診断は広く行われており、オクターブバンド分析結果を用いて原因を診断できる可能性がある。

振動による機器の故障診断については、多くの知見が蓄積されており、ある異常に対してどのような周波数帯の振動が発生するかが明らかにされている(牧, 1983)(小林他, 2000)(豊田, 1991). まず、アンバランスやミスアライメントによる異常振動は機器の回転周波数やその整数倍の比較的低い周波数の振動を引き起こす. 各部のゆるみや回転軸の変形もアンバランスやミスアライメントにつながり、異常振動の原因となる. また、ゆるみの場合には、部品同士が衝突する際に発生する振動も加わり、比較的高い周波数の振動も発生する.

一方、機械の部品であるころがり軸受や歯車についても振動による診断の有効性が知られている. 例えはころがり軸受において傷が成長すると衝突や擦過音により数 10 kHz 付近の振動が発生する. さらに摩耗が進むと軸が振動して回転数依存による成分の振動が表れる. そのため、異常振動の発生周波数から欠陥の成長が分かる(牧, 1983). 歯車についても、初期の割れや傷の成長に伴う振動については類似の現象が起きるものと考えられる.

これらの知見を利用すると、鉄道車両用機器では例えば表 1 のように異常振動の周波数帯を分類して、異常振動が発生した際に行うべき検査を定められる.

Table 1 Criteria for diagnosing abnormal vibration by frequency bands.

Frequency band	Abnormality	Frequency	Inspection
Low frequency	<ul style="list-style-type: none"> ● Unbalance ● Misalignment ● Deformation ● Looseness 	Under 100 Hz	<ul style="list-style-type: none"> ● Appearance check ● Dimension measurement ● Looseness check (hammering test)
Middle frequency	<ul style="list-style-type: none"> ● Looseness ● Wear in bearings or gears 	100 Hz ~ 1 kHz	<ul style="list-style-type: none"> ● Looseness check (hammering test) ● Lubricant analysis ● Wear inspection (overhaul)
High frequency	<ul style="list-style-type: none"> ● Wear in bearings or gears ● Crack in bearings or gears 	Over 1 kHz	<ul style="list-style-type: none"> ● Lubricant analysis ● Wear inspection (overhaul)

まず、回転体のアンバランスに起因する振動の周波数は機器の回転周波数からその範囲が分かる. 電車用主電動機は最高回転速度が 6000 /min 以下に設計されるため、回転周波数は 100 Hz 以下となる. 気動車のエンジンは概ね 2100 /min 以下で利用されるため回転周波数は 35 Hz 以下となる. 気動車ではエンジンの動力をユニバーサルジョイントとカルダンシャフトを介して伝達するが、ミスアライメントがあると回転周波数の 2 倍の周波数(70 Hz 以下)の振動が生じる. そのため、鉄道車両では 100 Hz 以下を低周波として扱い、この領域の異常振動についてはアンバランスやミスアライメントを推定原因とする.

次に、軸受や歯車の異常では、前述の通り数 10 kHz までの振動が発生するが、軸受異常の事例(牧, 1983)では 1.7 kHz 付近に発生振動数のピークが生じている. また、軸受診断の事例では 4 kHz 以上の周波数で軸受不良に伴う振動が観測されており、歯車診断の例ではピッチング(歯面のはく離)による振動の増加が 4~5 kHz 付近に見られる(小林他, 2000). このため、軸受や歯車の異常では、数 kHz の振動までを対象とするのが良く、1 kHz を高周波振動の下限として設定する. 歯車や軸受に異常が生じた場合には異常摩耗が進行するため、潤滑油やグリースの分析により、摩耗粉の量や成分から損傷の状況を推定できる. そのため、高周波で異常振動が検知された場合には、潤滑油やグリースの検査や分解検査により異常摩耗の発生を確認するのが良い.

最後に、高周波と低周波の間の領域が中周波となる. 中周波領域の振動は前述の摩耗が進んだ場合に発生する. そのため、対処法としては高周波の場合と同様である. また、ゆるみやガタが生じた場合にも回転周波数の 1/2 倍、1/3 倍の分数調成分や 2 倍、3 倍の高調波成分が観測される(豊田, 1991). そのため、低周波や中周波の異常振動が観測された場合にはゆるみについても検査を行う必要がある.

以上のように、異常振動が起きている周波数帯を把握できれば、異常の発生原因を絞り込んで適切な対処ができるようになると思われる.

3・2 周波数帯毎の異常振動検知

次に、異常振動が発生している周波数帯を検知する方法について述べる。

2章で説明した異常振動検知法では、オクターブバンド分析結果の全周波数帯を使用して異常振動を検出しているため、どの周波数帯で異常振動が発生しているかは分からない。そこで、オクターブバンド分析結果を図3のように「低周波データ」「中周波データ」「高周波データ」の3つに分けて、それぞれについて異常振動検知を行えば、異常振動が発生している周波数帯を明らかにできる。各周波数帯に対して異常度計算を行う際には2章で述べた方法をそのまま使用できる。この場合、主成分分析の変換行列、学習データ、基準距離は周波数帯毎に管理する。異常振動の発生周波数帯が明らかになった後には、表1を参考にして異常の発生原因を推定し、必要な検査や修理を実施できる。

Fig. 3 Division of an octave band spectrum. The octave band spectrum is divided into three spectra, i.e., low frequency spectrum, middle frequency spectrum, and high frequency spectrum. Then the abnormal vibration detection is conducted for each spectrum.

4. エンジンの異常模擬試験

ここで、異常振動検知の検証のために過去に実施したエンジンの異常模擬試験について紹介する。気動車ではエンジン等の機器が用いられているが、それらの振動は複雑であり、振動の大きさによる異常検知が難しい。その一方で、一両編成で運用されて機器の冗長性が確保できない場合も多く、状態監視のニーズも高い。そのため、気動車の機器を対象として異常模擬試験を行った。異常模擬試験は補機駆動軸の異常模擬試験(近藤他, 2017a)とエンジン潤滑油への異物混入による異常摩耗試験(近藤他, 2016)の二つがあり、いずれもエンジンベンチにおいて同種のエンジンにより行われた。

補機駆動軸の異常模擬試験ではエンジンの動力を発電機に伝える補機駆動軸で異常模擬を行った(図4)。

Fig. 4 Test equipment for auxiliary drive shaft failure test. The shaft is composed of a cardan joint, a spline shaft, and a rubber coupling. The vibration is measured on the generator.

異常模擬は、図4右に示したゴム継手のゴムの経年劣化による硬化を模擬した「ゴム劣化 (Degraded rubber)」と、図4右に示したフランジ継手部のキーの幅を図5に示すように1mm狭くして周方向に隙間を設けた「隙間あり (Loose key)」の二種類を行った。「ゴム劣化」では硬度の高いゴムを用いたゴム継手に交換し、正常品に対

してねじりバネ定数を約 1.3 倍とした。試験時にはエンジンをアイドリングさせて図 4 に示す発電機上で振動測定を行った。測定された振動に対して 2 章の方法で異常度を計算した結果、図 6 に示す通り二種類の異常模擬とも大半のデータの異常度が正の値であり、異常模擬に伴う状態変化が検知できている(近藤他, 2017a)。

Fig. 5 Loose key. A gap is provided in the rotational direction by exchanging the key for a one having a width smaller than that of the normal key.

Fig. 6 The histogram of the calculated abnormality. In the case of “Loose key” and “Degraded rubber”, the abnormality was successfully detected.

異常摩耗試験では表 2 に示すようにエンジンの潤滑油にセラミック粉末 (SiC) を段階的に混入して異常摩耗を発生させた。試験では図 7 に示す位置で振動測定を行った。測定された振動に対して 2 章で紹介した方法により異常度を計算した結果、図 8 に示す通り時間の経過と SiC 粉末の濃度増大に伴い異常度が増加する結果が得られた。試験後にエンジンを分解調査した結果、図 9 に示すようにエンジンの摺動部品で磨耗が進展しており、エンジンの継続使用が許容されない状態であった(近藤他, 2016)。

Table 2 Test process of SiC powder addition

SiC powder concentration [%]	Operational time [min]	Cumulative operational time [min]
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

Fig. 7 Test equipment for engine abrasion test. The vibration of the engine was measured at the mount part of the engine. The engine was idled during the test.

Fig. 8 Calculated abnormality in engine abrasion test. Abnormality rises as SiC powder concentration increases and as time advances.

Fig. 9 Worn parts in the engine after the test. The left is a main bearing and the right is the end part of a connecting rod. The brown areas are the copper layers.

5. 異常振動率の提案と異常模擬試験への適用結果

5・1 異常度平均値と異常振動率

前章の図 8 でも確認できるように、2 章で説明した異常振動検知法では 1 秒毎に異常度が算出されるため、常時監視を行った場合には多数の異常度が算出される。エンジンのような機器では振動が複雑に変化するため、異常度のばらつきが大きい。そのため、機器の状態を端的に評価するためには、図 8 中に示したように異常度の平均値を算出するのが良い。

しかし、異常度は異常の程度を表現しているものの、その上限値が不明であるため異常の進行度合いが不明である。例えば、図 8 で 10 時間経過した後の異常度は 2~3 程度であるが、その値からは異常磨耗の初期段階なのか末期段階なのかは不明である。実際には 10 時間経過後の時点で図 9 に示した通り大きく磨耗した状態になっているため、末期段階であるとの診断が望ましい。しかし、異常度の値は学習データの分布から設定された基準距離に対する比であり、学習データに依存して大きく変わる可能性があるため、異常の程度や進行度合いを評価する尺度としては使用しにくい。

そこで、診断結果の提示法として、異常度の平均値でなく、異常振動率（異常と判定されたテストデータの割合）で診断結果を示す方法を提案する。異常振動率の場合には上限値が 100% であるので異常の進行度合いを判断しやすい。よって、異常振動率は異常の程度を端的に表す指標として、より有用であると期待できる。

以下では、4 章の異常模擬試験結果に対して 2 章および 3 章で説明した周波数帯毎の異常振動検知法を適用し、異常度平均値と異常振動率を算出した結果について説明する。

5・2 周波数帯毎の異常振動検知の適用結果（異常度平均値）

異常模擬試験の各条件における異常度平均値の算出結果を図 10 に示す。今回の異常度計算ではアイドリング時のみを抽出するため、振動と同時に測定しているエンジンの回転速度を用いて、エンジン回転が 600~800/min のデータのみを対象とするようにフィルタリングを行っている。

Fig. 10 Calculation results of average abnormalities. The left chart show the result of the auxiliary drive shaft failure test. Large abnormality values are calculated in low and middle frequency band for “Loose key”, which assumed to be the results of looseness and unbalance. The right chart shows the result of engine abrasion test. In the test, the middle frequency and high frequency abnormality are observed. These results are consistent with the criteria shown in Table.1.

まず、補機駆動軸の異常模擬試験の「隙間あり」について見ると、低周波・中周波で大きな異常が出ている。「隙間あり」は隙間を設けているのでゆるみが発生していると考えられ、フランジ部にゆるみがあるとアンバランスが発生している可能性が高い。よって、「隙間あり」では、アンバランス・ゆるみが同時に発生していると考えられ、第 3 章の表 1 による、診断結果は適切であるといえる。

「ゴム劣化」については中周波で小さな異常がみられる。ゴム劣化は経年劣化の状態であって故障ではないため、「隙間あり」のように大きな異常度とならないのは適切な診断である。表 1 にはそもそも「ゴム劣化」の項目が無いが、振動特性が変化するという意味ではゆるみに似ている。そのため、もし表 1 に「ゴム劣化」を加えるのであれば、この試験結果も考慮して「ゆるみ」の列に併記するのが良いと考えられる。

次に、異常磨耗試験について見ると、試験開始から「SiC0.35%」まで中周波と高周波で異常度平均値が増大している。これを表 1 に従って判断すると「異常磨耗」の診断となり、適切な診断結果であると言える。その後、SiC 濃度 0.4%~0.5%では低周波でも異常が検知されている。末期になって低周波でも異常が検知されるように変化していく様子は 3 章での説明と一致しており、概ね想定通りに診断できている。

以上から、過去に実施した二つの異常模擬試験については、周波数帯毎に異常振動検知により異常度平均値を算出して、簡易に異常の種類を評価できている。ただし、エンジンの異常磨耗試験では異常度平均値が 2 以下であるのに対し、補機駆動軸の「隙間あり」では異常度が 10 程度であり大きな開きがあり、異常度平均値から異常の程度を判断し難い。また、異常磨耗試験では異常度の平均値の上昇傾向が「SiC0.50%」まで続いており、「SiC0.50%」が異常の初期段階なのか末期段階なのかは判断できない。

5・3 周波数帯毎の異常振動検知の適用結果（異常振動率）

次に、同じデータを用いて異常振動率を算出した結果を図 11 に示す。異常振動率は、各条件について、異常度が正の値であったデータの数と全データ数で割った値である。

Fig. 11 Calculation results of the ratio of abnormal vibration. Owing to the limited range of the index, the ratio of abnormal vibration, one can clearly see the existence of the abnormality in “Degraded rubber” and the progress of the failure in the engine abrasion test in the right chart.

まず、「隙間あり」について見ると、低周波と中周波で異常が検知されている点は異常度平均値の場合と同様であるが、異常振動率ではそれらの値がほぼ 100%であり、異常振動の常時発生が確認できる。また、「ゴム劣化」の異常度平均値は「隙間あり」に比べて非常に小さい値であったが、異常振動率では中周波が 100%近い値であり、状態が正常状態と異なる事がより明確に検知されている。

次に、エンジン異常磨耗試験の結果について見ると、まずは中周波の異常振動率が試験開始から「SiC 0.20%」まで直線的に増加して 100%近くまで到達し、その後高周波の異常振動率が「SiC 0.40%」まで直線的に増加して 100%近くまで到達している。低周波の異常振動率も「SiC0.35%」以降急激に増加しており、「SiC0.50%」では全ての周波数帯において異常振動率がほぼ 100%になっている。つまり、「SiC0.50%」では値がそれ以上増加し得ない状態にあり、末期段階であると判断できる。各周波数帯で異常が発生して増大していく順序は異常度平均値と同じであるが、異常振動率では上限値が 100%と定まっているため、異常進展の段階が判断し易い。

1 章で説明したような状態監視システムを実際に運用する場合には、一瞬でも異常が検知されたら即座に当該車両の保守を行うとの判断は合理的ではなく、異常進展の段階を評価して保守も含めた運用の計画を立てていく

必要がある。その際には、異常振動が収まらなくなる段階を末期段階と考え、そこに到達するまでにどの程度余裕があるかを異常振動率から推定して異常進展の段階を評価できると考えられる。機器が正常に機能しなくなる状態と異常振動率が 100%の状態が必ずしも対応している訳では無いが、異常振動率が 100%の時には機器が常に正常時と異なる状態で動作しているため、機器が故障しているかどうかの良い目安になると考えられる。

6. 考 察

6・1 想定される提案方法の使用方法

前章で示した通り、周波数帯毎に異常振動率を評価することにより、異常発生の原因を絞り込むとともに異常進展の段階を評価できる可能性がある。ただし、実際に診断を行うためには機器の構造や異常に伴い発生する現象を把握した上で、異常振動率の示す内容を解釈する必要がある。

例えば、機器内部で異常摩耗が発生した場合、はじめは摩耗に伴う振動のため高周波や中周波で異常振動率が増加していく。次に、摩耗が進展した結果、ガタや隙間が生じて中周波の異常振動率が増加する。そして、最終的にアンバランスが生じて低周波の異常振動率が増加するといった現象が考えられる。

そのため、高周波や中周波での異常振動率上昇後に低周波での異常振動率上昇がみられた場合には、摩耗によるアンバランスが発生していると推定することができる。この場合には、異常振動率のみでなく、異常が検知された周波数帯の順序も含めて異常の進展を推定することができる。ただし、周波数帯別の異常振動率評価では原因を絞り込むだけで具体的な異常発生原因を特定できる訳ではない。例えば、中周波の異常振動率が上昇した場合、それがゆるみによるものか摩耗によるものかは判別できない。そのため、提案方法は異常発生を発見してその後の原因調査の方向性を示すためのツールと位置付けられ、異常振動率の上昇が認められた場合には、潤滑油検査、打音検査、外観寸法検査等を実施して総合的な診断を行う必要がある。また、提案方法では異常の進展段階を評価できるため、異常振動率の 1 日毎の変化を外挿して異常振動率が 100%に到達する日を予測し、それまでに機器を運用から外して原因調査を行うように計画を立てるといった使用方法も想定される。

6・2 提案方法の適用範囲

本論文では気動車のエンジン周辺を対象とした試験結果を示したが、機器の異常発生に伴い異常振動が定常的に発生する場合には適用可能であり、表 1 に示したような異常が全て検知対象である。

ただし、表 1 に記載した異常が常に検知可能な訳ではない。例えば、部品の変形があったとしても、それが固定側の部品であり回転に伴う振動に影響を及ぼさない場合には異常の検知はできない。また、正常状態の振動の変動範囲が大きく、異常振動がその変動範囲に埋もれてしまう場合には、異常振動が発生していても異常が検知できない可能性がある。例えば、車軸軸受の異常振動検知を行うためには軸箱の振動を監視するのが良いと考えられるが、軸箱の振動は軌道や車輪の状態により大きく変動するため、本方法を単純に適用しても異常振動を検知することは難しく、走行区間毎に振動を評価する等の工夫が必要になると考えられる。

また、台車のサスペンション関係部品の異常は台車の運動に影響を及ぼしたり、過渡的な異常振動を発生させたりする可能性があるが、本方法では定常的な異常振動の発生を前提としてオクターブバンド分析を採用しているため、それらの異常は基本的に適用範囲外であると考えている。

6・3 各パラメータの設定方法

本方法は定常的な異常振動を想定しているが、定常とはどの程度の継続時間を指すのかは適用対象によって異なる。気動車のエンジンのように使用時に回転速度が変化していく場合には振動を評価する時間は短い方が良い。その一方で、オクターブバンド分析を実施するためには振動の周期の数倍の時間を必要とする。本論文で示した例では、エンジンのアイドリング時の回転速度は 700/min 程度であり、その回転周波数の振動を評価することを考えると 1 秒程度は確保する必要があると考え、オクターブバンド分析の周期は 1 秒とした。

同様に、異常度算出のための様々なパラメータについても適用対象によって最適な値は異なると考えられる。本論文で参考とした以前の検討(近藤他, 2015a)では、車両の走行時にエンジンの異常模擬を行った試験データについて十分な異常検知性能が得られるように主成分の数と近傍データ数を設定している。その際の異常検知性能

評価指標としては検知率と誤検知率を同時に評価できる ROC 曲線の AUC を使用している。本論文では同種の機器を対象としているため、それらの値を使用した。異なる機器に本方法を適用する場合には、その機器に適したパラメータ値の評価を改めて行う必要があると考えられる。

また、表 1 に示した周波数帯の分類も、対象機器によって変える必要がある。3 章で説明した通り、低周波数帯の上限周波数は機器の最高使用回転速度を参考にして定めているため、同様の方法で機器毎に上限周波数を算出できる。一方、中周波数帯と高周波数帯との境界については明確な算出方法が無いため、機器毎に経験を蓄積して設定方法を検討していく必要がある。

最後に、近傍法における基準距離を設定する際には正常データの 99% が正常判定されることを基準としているが、この 99% という値もパラメータの一つである。これについては、100% に近い数値であれば任意の値を設定できると考えているが、その設定値によって異常振動率の評価が変わることに留意する必要がある。つまり、例えば 99% が正常判定される設定の場合には 1% が異常判定されるように設定しているため、正常状態では異常振動率が 1% 程度になるということを理解して異常振動率を解釈する必要がある。

7. 結 言

鉄道車両機器を対象とした汎用性の高い状態監視システムの開発を目指して提案しているオクターブバンド分析と機械学習の 1 クラス分類を組み合わせた異常振動検知方法において、周波数帯毎に異常振動検知を行った際の異常振動率により、異常の種類を診断するとともに異常進展の段階を評価する方法を提案した。エンジンを対象として行った異常模擬試験に対して提案方法を適用した結果、概ね期待通りの結果が得られた。提案方法の特長をまとめると以下の通りである。

- ・汎用性が高く、定常的な振動が変化する異常であれば機器や故障の種類を問わず適用できる可能性がある。
- ・学習時には正常時の振動データのみを必要とし、異常時の振動データは不要である。
- ・異常振動の周波数帯から異常の種類を絞り込むことができる。
- ・異常振動の発生率から異常進展の段階を推定できる。

一方、異常模擬試験は定置でアイドリング状態のみを対象としているのに対し、実際の鉄道車両では機器の動作状態が複雑に変化する。また、走行線区、運用、気温や天候の変化等、様々な要因により振動が変化する可能性がある。そのような条件下でも提案方法が想定通りに機能するかは長期的な検証が必要であり、今後の課題である。また、長期的に振動データを取得して分析していく際には、データの規模が大きくなるため、計算機のメモリや計算速度の制約が問題になる可能性がある。これらについても今後の課題として取り組んでいきたい。

文 献

- Corni, I., Symonds, N., Wood, R.J.K., Wasenczuk, A. and Vincent, D., Real-time on-board condition monitoring of train axle bearings, The Stephenson Conference, IMechE (2015).
- Hayton, P. M., Schölkopf, B., Tarassenko, L., and Anuzis, P., Support vector novelty detection applied to jet engine vibration spectra, *Advances in neural information processing systems* (2000), pp. 946-952.
- 蛭田智昭, 鈴木英明, 藤原淳輔, 機械学習を使った異常検知技術のための定常状態の抽出条件の自動生成手法, 日本機械学会論文集, Vol.81, No.826 (2015) DOI:10.1299/transjsme.14-00372.
- 小林健二, 鈴木英男, 金井浩, 大橋正尚, 音・振動による診断工学, コロナ社 (2000).
- 近藤稔, 真鍋慎一, 高重達郎, 菅野晋, 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 (2015a), pp. 17-22.
- 近藤稔, 真鍋慎一, 高重達郎, 菅野晋, 振動による駆動用機器の状態監視法, 鉄道技術連合シンポジウム (J-Rail 2015) 講演論文集 (2015b), 1201.
- 近藤稔, 高重達郎, 真鍋慎一, 菅野晋, 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検知, 鉄道総研報告, Vol.30, No.4 (2016), pp. 47-52.
- 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, (2017a), pp. 23-28.
- 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 2017 年度年次大会講演論文集 (2017b), G1000202.

- 牧修市, 振動法による設備診断の実際, 日本プラントメンテナンス協会 (1983).
- 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, Vol.75, No.757 (2009), pp.93-101.
- 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, Vol.76, No.769 (2010), pp.27-35.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V. and Vanderplas, J., Scikit-learn: Machine learning in Python, Journal of Machine Learning Research, 12(Oct) (2011), pp.2825-2830.
- 豊田利夫, 回転機械診断の進め方, 日本プラントメンテナンス協会 (1991).
- Widodo, A. and Yang, B. S., Support vector machine in machine condition monitoring and fault diagnosis, Mechanical systems and signal processing, Vol.21, No.6 (2007), pp.2560-2574.
- Zhou, J., Intellectual Gear fault detection based on wavelet time-frequency analysis, Applied Mechanics and Materials, Vol.373-375 (2013), pp.762-769.

References

- Corni, I., Symonds, N., Wood, R.J.K., Wasenczuk, A. and Vincent, D., Real-time on-board condition monitoring of train axle bearings, The Stephenson Conference, IMechE (2015).
- Hayton, P. M., Schölkopf, B., Tarassenko, L. and Anuzis, P., Support vector novelty detection applied to jet engine vibration spectra, Advances in neural information processing systems (2000), pp. 946-952.
- Hiruta, T., Suzuki, H. and Fujiwara, J., Automatic creation method of extraction condition of sensor data for anomaly detection based on machine learning, Transactions of the JSME (in Japanese), Vol.81, No.826 (2015) DOI:10.1299/transjsme.14-00372.
- Kobayashi, K., Suzuki, H., Kanai, H. and Oohashi, M., Diagnostic technology by acoustic and mechanical method, Corona publishing (2000) (in Japanese).
- Kondo, M., Manabe, S., Takashige, T. and Kanno, H., Abnormality detection of traction diesel engines using vibration analysis in octave bands, RTRI Report, Vol.29, No.9 (2015a), pp. 17-22 (in Japanese).
- Kondo, M., Manabe, S., Takashige, T. and Kanno, H., Vibration based condition monitoring method for traction machines, Jointed railway technology symposium 2015 (2015b), 1201 (in Japanese).
- Kondo, M., Takashige, T., Manabe, S. and Kanno, H., Abnormality detection in a contaminated diesel engine by a vibration monitoring method, RTRI Report, Vol.30, No.4 (2016) pp. 47-52 (in Japanese).
- Kondo, M. and Takashige, T., Abnormality detection for auxiliary drive shafts on diesel cars using vibration condition monitoring, RTRI Report, Vol.31, No.6 (2017a), pp. 23-28 (in Japanese).
- Kondo, M., Machine diagnosis using anomaly detection method with octave band vibration spectra, Mechanical Engineering Congress, 2017 JAPAN (MECJ-17) (2017b), G1000202 (in Japanese).
- Maki, S., Shindouhou niyoru setsubi shindan no jissai, Japan Institute of Plant Maintenance (1983) (in Japanese).
- Oba, T., Yamada, K., Okada, N., Soma, H. and Tanifuji, K., Condition monitoring for shinkansen bogies based on vibration analysis, Transactions of the Japan Society of Mechanical Engineers, Series C, Vol.75, No.757 (2009), pp.93-101 (in Japanese).
- Oba, T., Yamada, K., Okada, N. and Tanifuji, K., Condition monitoring for shinkansen bogies based on vibration analysis : 2nd report, comparison of vibration states between two bogies in the same cars and examination of continuity of vibration peaks, Transactions of the Japan Society of Mechanical Engineers, Series C, Vol.76, No.769 (2010), pp.27-35 (in Japanese).
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V. and Vanderplas, J., Scikit-learn: Machine learning in Python, Journal of Machine Learning Research, 12(Oct) (2011), pp.2825-2830.
- Toyota, T., Kaitenkikai shindan no susumekata, Japan Institute of Plant Maintenance (1991) (in Japanese).
- Widodo, A. and Yang, B. S., Support vector machine in machine condition monitoring and fault diagnosis, Mechanical systems and signal processing, Vol.21, No.6 (2007), pp.2560-2574.
- Zhou, J., Intellectual Gear fault detection based on wavelet time-frequency analysis, Applied Mechanics and Materials, Vol.373-375 (2013), pp.762-769.