

特徴選択と2段の外れ値検出手法による 微小欠陥を含む転がり軸受の欠陥検出法

北井 正嗣^{1,a)} 赤松 良信¹ 福井 健一²

受付日 2018年8月24日, 再受付日 2018年10月17日,
採録日 2018年11月8日

概要: 転がり軸受の欠陥検出は機械メンテナンスにおいて重要な課題である。本研究では、はじめに各種サイズの人工欠陥を設けた転がり軸受に対して、欠陥検出に適した外れ値検出手法を選定した。次に各欠陥サイズの検出において重要度の高い特徴量を選択し、各欠陥サイズの欠陥検出に適した特徴ベクトルを作成した。最後に各欠陥サイズに対してそれぞれ特徴選択後の特徴ベクトルを基に計算した異常度を新たな入力ベクトルとし、再度外れ値検出を行うことにより欠陥検出精度の向上を試みた。

キーワード: 転がり軸受, 欠陥検出, Local Outlier Factor, Random Forest

Defect Detection Method for Rolling Bearing Including Micro Defect by Feature Selection and Two Step Outlier Detection Method

MASASHI KITAI^{1,a)} YOSHINOBU AKAMATSU¹ KEN-ICHI FUKUI²

Received: August 24, 2018, Revised: October 17, 2018,
Accepted: November 8, 2018

Abstract: Detecting the damage of rolling bearings correctly is the important task in machine maintenance. In this paper, firstly, the anomaly detection accuracy using some kind of outlier detection methods for vibration acceleration of rolling bearings with artificial defects is evaluated and compared. Secondly, feature vectors whose features are high importance to each defect sizes are used to evaluate anomaly detection accuracy and anomaly score. Finally, anomaly score for each feature vectors after feature selection are used as anomaly vectors and anomaly detection ratio is evaluated by outlier detection method again.

Keywords: rolling element bearing, defect detection, Local Outlier Factor, Random Forest

1. はじめに

転がり軸受は多くの回転機械において欠かせない重要な要素の1つであり、自動車やプラント、航空機など使用される分野は非常に多岐にわたる。転がり軸受に損傷が発生した場合、回転機械の精度や運転効率に影響を与えるだけでなく、損傷が拡大していくと、機械自体に致命的なダメージを与えかねない。そのため、転がり軸受の損傷を正

確に検知することは重要といえる。

転がり軸受の診断方法としては、運転中の振動加速度または Acoustic Emission (AE) の振動データを対象とした分析方法を多く用いる。これはデータの測定が簡易であり、運転を継続したまま測定が可能なのが理由である。振動データを用いた転がり軸受の損傷検出に関する研究として、たとえば振動加速度から実効値、尖度などの各種統計量を算出し、そのトレンドの変化により状態監視を行う方法 [1]、FFT 処理後の特性周波数ピークの変化により状態監視を行う方法 [2]、また、AE を利用して初期のクラックの発生を検出する方法 [3] がある。しかし、これらの手法は転がり軸受の損傷にともなう振動特性の変化、および分析のための信号処理に関する知見が必要であり、より簡

¹ 大阪大学 NTN 次世代協働研究所
NTN Next Generation Research Alliance Laboratories,
Osaka University, Suita, Osaka 565-0871, Japan

² 大阪大学産業科学研究所
The Institute of Scientific and Industrial Research, Osaka
University, Ibaraki, Osaka 567-0047, Japan

a) masashi_kitai@ntn.co.jp

易的な診断方法が望まれている。

一方で近年、分析や信号処理に関する知見を必要とせず、回転機械の損傷状態を評価する方法として機械学習を利用した手法が目まはしている。たとえば One Class Support Vector Machine (OC SVM) [4] を用いた水力発電所の異常予兆検出 [5] や、Nearest Neighbor Data Description [6] を用いた駆動用機器の異常振動検知 [7]、Deep Neural Network/Gaussian Mixture Model タンデム接続アプローチ [8] を利用した風車の異常検知 [9] などがある。

また著者は、外輪に各種サイズの人工欠陥を設けた転がり軸受に対し、OC SVM による欠陥検出を試みたが、主軸回転速度によっては微小な欠陥を検出できない課題がある [10]。領域、周波数フィルタ、振動加速度の測定方向を考慮した各種特徴量について検証した結果、欠陥サイズの変化により、欠陥検出に有用な特徴量は変化することを確認した [11]。そのため欠陥検出精度の向上には、異なる欠陥サイズに対して特徴選択を行う必要がある。

本研究では、各人工欠陥サイズに応じた特徴選択と 2 段の外れ値検出手法を組み合わせた新規欠陥検出手法を提案する。予備実験として、各種外れ値検出手法の欠陥検出精度を比較し、最も高い欠陥検出精度を得る手法として Local Outlier Factor (LOF) [12] を選定した。また、Random Forest (RF) [13] による正常軸受と微小な欠陥を有する軸受の分類精度を調査した結果、高い分類精度が得られることから欠陥による振動の特徴をとらえるのに適していると判断し、RF を各サイズの人工欠陥を有する軸受と正常軸受を対象とした特徴選択に採用し、特徴選択が LOF による欠陥検出精度に与える効果について考察した。

最後に予備実験結果を考慮した提案手法と従来手法の欠陥検出精度を比較し、提案手法の欠陥検出性能を評価した。欠陥サイズに応じた特徴選択と 2 段階の外れ値検出を行うことにより、既存の研究 [10], [11] よりも欠陥検出精度が向上したことを示す。

以後、2 章において機械学習を利用した転がり軸受の異常検知に関する関連研究、3 章では本研究で用いる外れ値検出手法、特徴選択手法について述べる。4 章では本提案手法の評価実験と結果を記載し、最後に結論を示す。

2. 関連研究

近年、転がり軸受や転がり軸受を内包する回転機械の診断方法として、機械学習、および機械学習と振動分析手法を併用した診断手法が目まはしている。

たとえば Li らは内輪、外輪および転動体にそれぞれ欠陥を設けた転がり軸受を対象とし、Local Mean Decomposition [14] および Multiscale Permutation Entropy [15] による特徴抽出および、Laplacian Score (LS) [16] による特徴選択を行った後、Support Vector Machine based of Binary Tree (SVM-BT) [17] を独自に改良した Improved

SVM-BT による分類を行うことで、従来に比べ高い精度で転がり軸受の欠陥部位を特定することに成功した [18]。また Bugarbee らは正常な軸受の振動データから、Singular Spectrum Analysis [19] を利用した主成分分析と、マハラノビス距離に基づく欠陥検出しきい値の作成により、異なる回転速度条件下での軸受の外輪、内輪、および転動体の欠陥の検出精度を向上した [20]。Shao らは外輪、内輪、転動体にそれぞれ異なる大きさの欠陥を設けた転がり軸受を対象とし、粒子群最適化手法 [21] により各隠れ層のニューロン数を最適化した Deep Belief Network [22] による欠陥の分類を行い、SVM やベイズ推定などの他の分類手法に対する分類精度の優位性を示した [23]。

しかし、文献 [20] では外輪、内輪、転動体の各部位にそれぞれ 1 種類の欠陥を有する軸受を診断対象としており、欠陥のサイズが検出精度に与える影響は述べられていない。また文献 [18], [23] では欠陥検出のための手法として教師あり学習による分類を行っており、教師なし学習での欠陥検出精度については述べられていない。

3. 提案手法

3.1 概要

提案する手法は転がり軸受の振動加速度の測定データ X から算出される特徴ベクトルを入力データ v とし、分類手法による特徴選択と 2 段の外れ値検出手法により異常度 a を算出する。提案手法の欠陥検出フローの概略図を図 1 に示す。検出したい欠陥をその状態に応じて 3 つの段階に分け、各欠陥状態の分類において分類手法による各特徴量の重要度の算出と特徴選択を行う (図 1 中 Feature Selection)。なお、分類手法による重要度の算出は学習時のみ行い、評

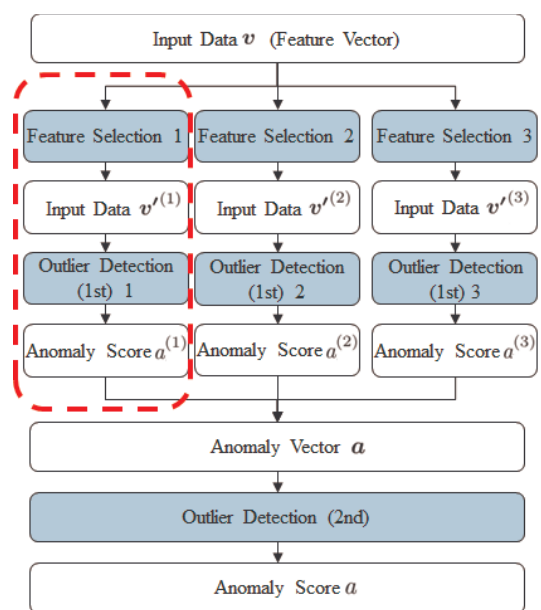


図 1 欠陥検出フロー

Fig. 1 Flow of defect detection.

価時には学習時に算出した重要度を用いて直接特徴選択を行う。次に特徴選択後の各入力データ $\mathbf{v}'^{(M)}$, $M \in \{1, 2, 3\}$ に対し、個別に外れ値検出手法の学習、評価を行い、それぞれの異常度 $a^{(M)}$ を算出する (図 1 中 Outlier Detection (1st) 1 から Outlier Detection (1st) 3)。このとき特徴選択後の入力データ $\mathbf{v}'^{(M)}$ はそれぞれ異なる欠陥状態を対象としているため、対象以外の欠陥状態は検出できない場合がある。そこで、特徴選択後の入力データ $\mathbf{v}'^{(M)}$ に対して求められる複数の異常度 $a^{(M)}$ を対応する測定データに対し 1 つのベクトル (異常度ベクトル, 図 1 中 Anomaly Vector \mathbf{a}) として取り扱い、この異常度ベクトルに対して再度外れ値検出による異常度 a を算出する (図 1 中 Outlier Detection (2nd))。本研究では評価対象の測定データから得られるすべての入力データについて提案手法による異常度を算出した後、異常度が事前に決めた欠陥検出しきい値を超える入力データの割合を異常率として評価し、異常率の大小によって対象データの欠陥の有無を判別する。

3.2 入出力データ

振動加速度の測定データを一定の時間間隔でセグメントに分割後、領域 (時間, 周波数, ケフレンシ), バンドパスフィルタ (BPF), センサ測定方向を考慮した統計量を特徴量としてベクトル化したものを入力データ \mathbf{v} とする。また 2 段目の外れ値検知手法によって得られる異常度 a を出力データとする。

3.3 評価指標

提案手法で得られる異常度 a から欠陥検出精度を評価する指標として異常率 Anomaly Ratio (AR), Area Under Curve Score (AUC Score) [24] を用いる。AR, AUC Score の算出方法について以下に示す。

3.3.1 異常率 Anomaly Ratio

評価したい測定データにおいて、連続する複数のセグメントから得られる入力データ \mathbf{v} に対し、提案手法で算出される異常度 a を基に異常率 AR を次式で算出する。 $a_{\text{threshold}}$ は事前に決定する欠陥検出しきい値であり、正常データに対する異常度の平均 $+ 5 \times$ 正常データに対する異常度の標準偏差とした。また N_{DS} は評価の対象とする測定データに含まれるセグメントの数を示す。

$$U_i = \begin{cases} 1(a_i \geq a_{\text{threshold}}) \\ 0(a_i \leq a_{\text{threshold}}) \end{cases} \quad (1)$$

$$AR = \frac{1}{|N_{DS}|} \sum_{i \in N_{DS}} U_i \quad (2)$$

3.3.2 Area Under Curve Score

識別性能の評価指標として正例を正しく正例と識別した例を True Positive (TP), 負例を正しく負例と識別した例を True Negative (TN), 負例を誤って正例と識別した例




図 2 ROC Curve と AUC Score
Fig. 2 ROC Curve and AUC Score.

を False Positive (FP), 正例を誤って負例と識別した例を False Negative (FN) としたとき, False Positive Rate (FPR), True Positive Rate (TPR) はそれぞれ次式で与えられる。

$$FPR = \frac{FP}{FP + TN} \quad (3)$$

$$TPR = \frac{TP}{TP + FN} \quad (4)$$

ある欠陥検出しきい値での FPR を横軸に, TPR を縦軸にとり, 欠陥検出しきい値を変化させたときの FPR と TPR の関係をプロットすることで Receiver Operating Characteristic Curve (ROC Curve) が得られる。ROC Curve の例を図 2 に示す。AUC Score は ROC Curve の下側面積で定義される。正常データと異常データが完全に分離可能な場合, AUC Score は 1.0 となる。一方でランダムな識別の場合, AUC Score は 0.5 となる。したがって AUC Score が 1.0 に近い値をとれば, 作成した機械学習モデルは高い識別性能を得られている。

3.4 機械学習手法

外れ値検出手法として OC SVM, LOF, Isolation Forest (IF) [25], 特徴選択手法として RF, LS を用いた。以下に各手法について記載する。機械学習手法の実装には Python 2.7 と Scikit-learn 0.19.0 を用いた。

3.4.1 One Class Support Vector Machine

OC SVM は正常データがある特徴空間に写像し, 特徴空間上において正常データをなるべく含む超球の半径と中心を求めることで, 正常データと異常データを分類する識別境界を決定する手法である。未知のデータが得られた場合, 特徴空間上に写像した際に, 超球の半径よりも外側に写像された場合に対象データを異常とみなす。特徴空間への写像に用いるカーネル関数の選択により, 非線形な問題を取り扱えるようになる。本研究ではカーネル関数にはガウシアンカーネルを用いた。

3.4.2 Local Outlier Factor

LOF は特徴空間上の密度に基づく外れ値検出手法である。外れ値は特徴空間上において密度の低い領域に分布す

るといふ仮定に基づく。特徴空間上の各点に対し、周辺密度を計算し評価に用いる。対象の点とその近傍点の周辺密度がほぼ同じ場合には対象の点を正常とみなす。逆に対象の点の周辺密度が近傍点の周辺密度に対して低い場合には対象の点を異常とみなす。

3.4.3 Isolation Forest

IFはランダムに特徴量と分岐点の選択を行い、あるデータがほかから孤立されるまでの平均分岐回数をもとに異常度を算出する手法である。正常データは他の正常データと似た性質を持つため、各正常データが孤立されるまでの平均分岐回数は多くなる。それに対し、異常データは正常データとは異なる性質を持つため、異常データが孤立されるまでの平均分岐回数は少なくなる。この特性を生かし、特定のデータに対し孤立されるまでの平均分岐回数が他のデータよりも少なくなる場合に対象のデータを異常とみなす。

3.4.4 Random Forest

RFは決定木を利用したアンサンブル学習による分類手法である。入力データから復元抽出により複数の訓練集合を作成し、各訓練集合に対し、決定木による分類を行う。またRFの学習時に得られる情報利得を基に特徴量の重要度を算出する。本研究では、RFで算出される重要度を欠陥状態に応じた有効な特徴選択に用いた。

3.4.5 Laplacian Score

LSは各入力データをノードとした近傍グラフを作成し、グラフ上の近傍のノードにおける特徴量ごとのグラフラプリアンに基づいて特徴選択を行う手法である。本研究では、特徴量ごとに算出されるラプリアンスコアの値を用いて欠陥状態に応じた有効な特徴選択を行い、RFと比較した。

4. 評価実験

4.1 実験装置

欠陥検出精度の評価に用いた実験装置の概略図を図3に、試験軸受に設けた人工欠陥の形状とサイズを表1に示す。試験軸受は転がり軸受（アンギュラ玉軸受、型番：7216）を用い、外輪軌道面に直径の異なる円筒穴（表1中2bから8b）および円筒穴より十分大きい矩形溝（表1中RG）を設けた。荷重負荷時に玉と外輪軌道面に生じる楕円状の弾性接触部の短軸半径を**b**とし、その2倍から8倍の直径の円筒穴とした。たとえば、2bは円筒穴の直径が**b**の2倍であることを意味する。これらの人工欠陥は転動疲労によって生じるはく離（フレーキング）を想定したものであり、円筒穴ははく離の初期の段階、矩形溝ははく離が拡大した状態を想定している。

実験は、人工欠陥のない正常軸受（表1中ND）および上記の各サイズの人工欠陥を有する軸受を実験装置に取り付けた状態で、主軸回転速度1,000, 1,500, 2,000 min⁻¹の各




図3 実験装置

Fig. 3 Test Equipment.

表1 人工欠陥の形状およびサイズ

Table 1 Shape and Size of Artificial Defect.

Symbol	Shape of Defect	Size mm
ND	None	-
2b	Hole	φ 0.32
4b	Hole	φ 0.64
6b	Hole	φ 1.02
8b	Hole	φ 1.36
RG	Rectangular Grove	Width 2, Height 10, Depth 1

表2 各測定データXから得られるセグメントデータy_iの数

Table 2 Number of Segment Data y_i in each Measurement Data X.

Rotation Speed	Number of Segment Data
1,000 min ⁻¹	66
1,500 min ⁻¹	100
2,000 min ⁻¹	133

条件で運転し、得られた鉛直（Radial）、水平（Horizontal）、軸（Axial）方向の振動加速度の測定データを評価に用いた。また評価は主軸回転速度ごとに個別に行った。ある1方向の振動加速度の1回の測定データ $\mathbf{X}^{(D)} = [x_1 \ x_2 \ \dots \ x_i \ \dots \ x_N]$, $D \in \{\text{Axial, Radial, Horizontal}\}$ はサンプリング周波数50 kHz, サンプリング時間20 sで測定し、各人工欠陥サイズでそれぞれ33回測定した。ここでインデックス*i*は時系列の順序を、 x_i はインデックス*i*における振動加速度振幅の瞬時値を示す。また軸受の組換えが振動に与える影響を考慮するため、3回測定するごとに軸受を組み換えた。

4.2 入力データv_jの算出

振動加速度の測定データ $\mathbf{X}^{(D)}$ は主軸5回転の周期でセグメントに分割し、セグメントごとに1つのセグメントデータ $\mathbf{y}_j^{(D)} = [x_{(j-1)n+1} \ x_{(j-1)n+2} \ \dots \ x_{(j-1)n+k} \ \dots \ x_{(j-1)n+n}]$ として取り扱った。ここでnはセグメントデータに含まれるデータ点数、 $j = 1, 2, 3, \dots, \lfloor N/n \rfloor$ はセグメント番号、インデックスkは時系列の順序を示す。したがって、1つの測定データ $\mathbf{X}^{(D)}$ から得られるセグメントデータ $\mathbf{y}_j^{(D)}$ の総数は表2のようになる。各セグメントデータ $\mathbf{y}_j^{(D)}$ に対して表3に示す各周波数帯域でBPF処理を行った振幅

表 3 バンドパスフィルタの種類
Table 3 Kind of Band-Pass Filter.

Filter	Frequency Range (Hz)
Raw	None
Low1	20-200
Low2	20-1,000
Mid1	200-2,000
Mid2	1,000-5,000
High1	2,000-20,000
High2	5,000-20,000

表 4 各入力データ v_j に含まれる特徴量数

Table 4 Number of Parameters included in each Input Data v_j .

	Regions	BPFs	Statistics	Sensors	Features
Number of Parameters	3	7	6	3	378

データを時間領域データ $y_j^{(D, TIME)}$ とした。また時間領域データ $y_j^{(D, TIME)}$ に対し、エンベロープ処理 [26] と FFT 処理を行い得られる周波数領域の振幅データを周波数領域データ $y_j^{(D, SPEC)}$ 、周波数領域データ $y_j^{(D, SPEC)}$ に再度 FFT 処理を行い得られる振幅データをケプレンシ領域データ $y_j^{(D, CEPS)}$ とした。特徴量は $y_j^{(D, R)}$ 、 $R \in \{TIME, SPEC, CEPS\}$ に対し、転がり軸受の診断に一般に用いられることの多い実効値 (OA)・最大値 (MAX)・波高率 (CF)・尖度 (KS)・歪度 (SKN) に加え変調値 (MOF) の統計量を使用した。実効値、最大値、波高率、尖度、歪度の算出方法を以下に示す。

$$OA_j^{(D, R)} = \sqrt{\frac{1}{n} \sum_{k=1}^n (y_{j,k}^{(D, R)})^2} \quad (5)$$

$$MAX_j^{(D, R)} = \max_{1 \leq k \leq n} y_{j,k}^{(D, R)} \quad (6)$$

$$CF_j^{(D, R)} = MAX_j^{(D, R)} / OA_j^{(D, R)} \quad (7)$$

$$KS_j^{(D, R)} = \frac{1}{n} \sum_{k=1}^n \frac{(y_{j,k}^{(D, R)} - \bar{y}_j^{(D, R)})^4}{(\sigma_j^{(D, R)})^4} \quad (8)$$

$$SKN_j^{(D, R)} = \frac{1}{n} \sum_{k=1}^n \frac{(y_{j,k}^{(D, R)} - \bar{y}_j^{(D, R)})^3}{(\sigma_j^{(D, R)})^3} \quad (9)$$

ここで D は測定方向、 R は領域、 j はセグメント番号、 $y_{j,k}^{(D, R)}$ は $y_j^{(D, R)}$ のインデックス k の要素、 $\bar{y}_j^{(D, R)}$ は $y_j^{(D, R)}$ の平均値、 $\sigma_j^{(D, R)}$ は $y_j^{(D, R)}$ の標準偏差を示す。変調値は $y_j^{(D, R)}$ に対し、エンベロープ処理後の実効値として定義した。またセグメントデータ y_j における各測定方向、各領域の特徴量を 1 つのベクトルとしたものを、入力データ v_j とした。表 4 に特徴量算出において考慮する領域、BPF、統計量、センサ測定方向の数をまとめる。各入力データ v_j は領域 (3 種)、BPF (7 種)、統計量 (6 種)、センサ測定方向 (3 種) を考慮した、合計 378 個の特徴量で構成される。

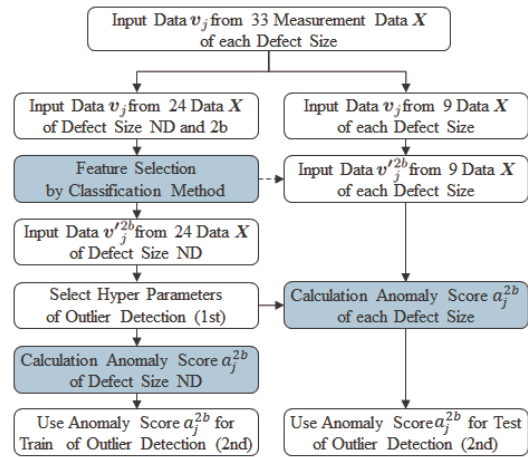


図 4 学習および評価に用いる測定データ X の組合せ

Fig. 4 Selection of measurement data X for train and test.

4.3 変動係数による特徴量の選別

入力データ v_j に含まれる複数の特徴量の中には、人工欠陥サイズの変化による変動より、軸受の組換えの影響によるばらつきの方が大きい特徴量もある。そこで、前処理として学習に使用する正常軸受のセグメントデータ y_j から算出される各特徴量について変動係数 (標準偏差を平均値で除した値) を算出し、変動係数が 0.3 を超える特徴量については学習および評価の対象から除外した。学習に使用する測定データ X の選択により、4.2 節で算出した全特徴量のうち、本処理によっておよそ 20~40% の特徴量が除外される。なお各特徴量は変動係数による選別後、後述する学習に使用する人工欠陥サイズ ND の入力データ v_j を基に特徴量ごとに Z Score を算出し学習、評価に使用した。

4.4 学習データ・評価データの選別

軸受の組換えが欠陥検出精度に与える影響を考慮するため、学習と評価に使用する測定データ X の組合せはランダムに変更して提案手法の学習と評価を行った。図 1 の赤枠部において、人工欠陥サイズ ND と 2b を対象に特徴選択する場合の測定データ X の組合せの詳細を図 4 に示す。

学習時は各人工欠陥サイズ 33 個の測定データ X のうち、人工欠陥サイズ ND と 2b の測定データ X をそれぞれ 24 個選択し、それぞれの入力データ v_j を基に分類手法による各特徴量の重要度の算出と特徴選択を行った。このとき得られる特徴選択後の入力データを v_j^{2b} とした。上付きの 2b は特徴選択後の入力データ v_j が人工欠陥サイズ 2b を対象として構成した特徴量の集合を用いていることを示している。次に人工欠陥サイズ ND の入力データ v_j^{2b} を外れ値検出手法の学習に用い、10 分割交差検証により特異度が最も高くなるハイパーパラメータの選定と異常度 a_j^{2b} の算出を行った。

評価時は各人工欠陥サイズそれぞれ 9 個の測定データ X から得られる入力データ v_j^{2b} に対し、外れ値検出手法によ

る異常度 a_j^{2b} を算出した。

人工欠陥サイズ ND と 4b, ND と 6b の組合せに対しても同様に特徴選択を行い, 特徴選択後の入力データ \mathbf{v}'_j^{4b} , \mathbf{v}'_j^{6b} から異常度 a_j^{4b} , a_j^{6b} を算出した. また本処理により得られる特徴選択後の入力データ $\mathbf{v}'_j^{(S)}$, $S \in \{2b, 4b, 6b\}$ に対する異常度 $a_j^{(S)}$ は, 対応するセグメントごとに1つの異常度ベクトル $\mathbf{a}_j = (a_j^{2b}, a_j^{4b}, a_j^{6b})$ とした. 学習・評価の入力データ $\mathbf{v}'_j^{(S)}$ に対する異常度ベクトル \mathbf{a}_j をそれぞれ2段目の外れ値検出手法の学習・評価に用いた. なお, 学習と評価に用いる測定データ \mathbf{X} は重複しないようにした.

4.5 欠陥検出精度の評価

欠陥検出精度は評価対象の測定データ \mathbf{X} に対し, 外れ値検出手法で得られる異常度から式 (1) により欠陥サイズごとの異常率を算出して評価した. 回転速度 $1,500 \text{ min}^{-1}$ を対象とした場合, 欠陥サイズごとの評価対象の測定データ \mathbf{X} は9個, 各測定データから得られるセグメントデータ \mathbf{y}_j は100個であり, 欠陥サイズごとの評価対象のセグメントデータ \mathbf{y}_j の総数は900個となる. 人工欠陥サイズごとの異常率は各セグメントデータ \mathbf{y}_j から得られる入力データ \mathbf{v}_j , $\mathbf{v}'_j^{(S)}$ または異常度ベクトル \mathbf{a}_j に対し, 外れ値検出手法で算出される異常度を用いて算出した. 学習に用いる測定データ \mathbf{X} は50回ランダムに変更し, 学習データの違いに対する異常率の平均とばらつきで欠陥検出精度を評価した.

4.6 予備実験

4.6.1 外れ値検出手法の比較

各外れ値検出手法について特徴選択しない場合の回転速度 $1,000, 1,500, 2,000 \text{ min}^{-1}$ における人工欠陥サイズと異常率の関係を図5に示す. また, 人工欠陥サイズ ND と 4b を対象として各外れ値検出手法の AUC Score を算出した結果を図6に, 学習データの違いに対する, 交差検証で求まるハイパーパラメータの平均値, 最大値, 最小値, および標準偏差を表5に示す. 表中 ν は OC SVM におけるサポートベクトルの割合の下限, γ はガウシアンカーネルのハイパーパラメータ, n-neighbors は LOF の周辺密度計算にける近傍数, n-estimators は IF のアンサンブル学習における予測器の数を示す.

図5より人工欠陥サイズ 2b~6b の異常率の平均はいずれも LOF が最も高い. また図6より AUC Score についても LOF が高い欠陥検出精度を得た. ただしいずれの手法でも人工欠陥サイズ 2b の異常率の平均は 0.3 以下であり, 人工欠陥サイズ 4b 以上に比べ低い. 表5より, ハイパーパラメータの値は学習データの違いに対するばらつきが大きく, これにともない異常率にばらつきが生じたと推察する. そこで, 欠陥検出精度を向上させるために RF による特徴選択を行った.

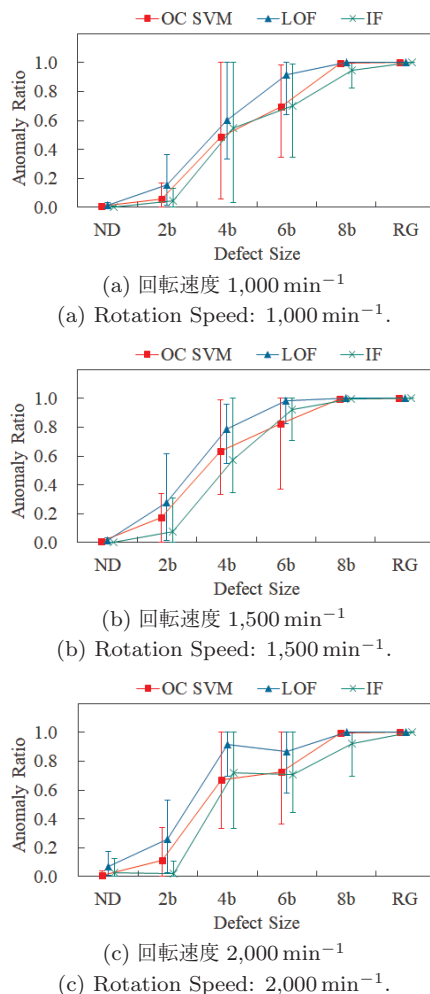


図5 外れ値検出手法の比較

Fig. 5 Comparison of outlier detection methods.




図6 各手法の AUC Score

Fig. 6 AUC score for each method.

4.6.2 Random Forest による特徴量重要度算出

前節の外れ値検出手法では検出が困難な人工欠陥サイズ 2b について RF による分類精度を評価した. はじめに RF のハイパーパラメータの影響を確認するため, 回転速度 $1,500 \text{ min}^{-1}$ において RF の決定木の数を 100, 1,000, 10,000, 決定木の最大深さを 10, 100, 1,000 の範囲で変更し人工欠陥サイズ ND と 2b の分類精度への影響を確認したが, 分類精度に有意な差は見られなかった. そのため以降は決定木の数を 1,000, 決定木の最大深さを 100 とし, 各回転速度における分類精度評価と特徴選択を行った.

表 5 学習データの違いに対するハイパーパラメータのばらつき

Table 5 Variation of hyper parameters for difference of train data.

Method	Hyper Parameter	Rotation Speed	Average	Max	Min	Standard Deviation
OC SVM	ν	1,000 min ⁻¹	2.0×10^{-3}	5.6×10^{-3}	1.8×10^{-4}	2.0×10^{-3}
		1,500 min ⁻¹	1.1×10^{-3}	2.0×10^{-3}	4.5×10^{-4}	6.7×10^{-4}
		2,000 min ⁻¹	1.6×10^{-3}	5.6×10^{-3}	1.8×10^{-4}	1.5×10^{-3}
	γ	1,000 min ⁻¹	2.8×10^{-4}	1.0×10^{-3}	1.0×10^{-4}	2.8×10^{-4}
		1,500 min ⁻¹	2.7×10^{-4}	1.0×10^{-3}	7.9×10^{-5}	2.8×10^{-4}
		2,000 min ⁻¹	1.6×10^{-4}	3.1×10^{-4}	7.9×10^{-5}	1.1×10^{-4}
LOF	n-neighbors	1,000 min ⁻¹	13.3	24	2	8.0
		1,500 min ⁻¹	9.8	25	2	8.6
		2,000 min ⁻¹	8.4	29	2	8.3
IF	n-estimators	1,000 min ⁻¹	33.0	60	17	15.1
		1,500 min ⁻¹	32.7	59	23	11.1
		2,000 min ⁻¹	71.7	96	35	20.0

表 6 各欠陥サイズに重要度の高い特徴量 (回転速度 1,500 min⁻¹)

Table 6 Features with high importance to defect size (rotation speed 1,500 min⁻¹).

	Comparison ND and 2b	Comparison ND and 4b	Comparison ND and 6b
1	OA-TIME-LOW1(Radial)	OA-TIME-LOW1(Radial)	OA-TIME-LOW2(Radial)
2	OA-TIME-LOW1(Horizontal)	OA-CEPS-LOW1(Radial)	MOF-TIME-LOW2(Radial)
3	MAX-TIME-LOW1(Horizontal)	OA-CEPS-MID1(Radial)	OA-SPEC-LOW2(Radial)
4	OA-TIME-LOW1(Horizontal)	MAX-CEPS-MID2(Radial)	MOF-SPEC-LOW2(Radial)
5	OA-CEPS-LOW1(Horizontal)	OA-TIME-LOW1(Axial)	OA-CEPS-LOW2(Radial)
6	CF-CEPS-LOW1(Horizontal)	MAX-TIME-LOW1(Axial)	MOF-TIME-MID1(Radial)
7	MOF-TIME-LOW1(Axial)	MAX-SPEC-LOW1(Axial)	OA-SPEC-MID1(Radial)
8	OA-SPEC-LOW1(Axial)	SKN-SPEC-LOW1(Axial)	MOF-SPEC-MID1(Radial)
9	MAX-SPEC-LOW1(Axial)	OA-CEPS-LOW1(Axial)	OA-CEPS-MID1(Radial)
10	MOF-SPEC-LOW1(Axial)	KS-CEPS-LOW1(Axial)	MAX-CEPS-MID1(Radial)




図 7 Random Forest による分類精度

Fig. 7 Classification accuracy by Random Forest.

回転速度 1,000, 1,500, 2,000 min⁻¹ における人工欠陥サイズ ND と 2b の分類精度を図 7 に示す。また回転速度 1,500 min⁻¹ において、人工欠陥サイズ ND と 2b の分類に加え、人工欠陥サイズ ND と 4b, 人工欠陥サイズ ND と 6b を対象としてそれぞれ RF による特徴選択を行い、学習データの違いに対して選択される回数の多い特徴量を 10 個抽出した例を表 6 に示す。人工欠陥サイズ ND, 2b の分類と人工欠陥サイズ ND, 4b の分類に共通して重要度の高い特徴量を太字、人工欠陥サイズ ND, 4b の分類と人工欠陥サイズ ND, 6b の分類に共通して重要度の高い特徴量を

太字 (下線) で表記する。また、表内の特徴量は統計量-領域-BPF (測定方向) で表記する。

図 7 より RF による分類では回転速度にかかわらず、人工欠陥サイズ 2b について非常に高い精度で分類ができる。また、表 6 より人工欠陥サイズ ND と 2b, ND と 4b の分類で共通する特徴量は 2 個、および人工欠陥サイズ ND と 4b, ND と 6b の分類で共通する特徴量は 1 個のみであり、人工欠陥サイズ ND と 2b, ND と 6b の分類に共通する特徴量はない。そのため、すべての欠陥サイズを同じ特徴量で評価することはできない。

4.6.3 特徴選択後の入力データ $v_j^{(S)}$ による欠陥検出精度

各人工欠陥サイズにおいて重要度の高い 10 個の特徴量を選択した特徴ベクトルを入力データ $v_j^{(S)}$ とし、LOF による欠陥検出精度を評価した。特徴選択後の入力データ $v_j^{(S)}$ に対する人工欠陥サイズと異常率の関係を図 8 に示す。人工欠陥サイズ ND と 2b, ND と 4b, ND と 6b の分類にそれぞれ重要度の高い特徴量を選択した入力データ $v_j^{2b}, v_j^{4b}, v_j^{6b}$ により算出される異常率を Feature (2b), Feature (4b), Feature (6b) として図に示す。同図に、特徴選択前の入力データ v_j から LOF を用いて直接欠陥サイ

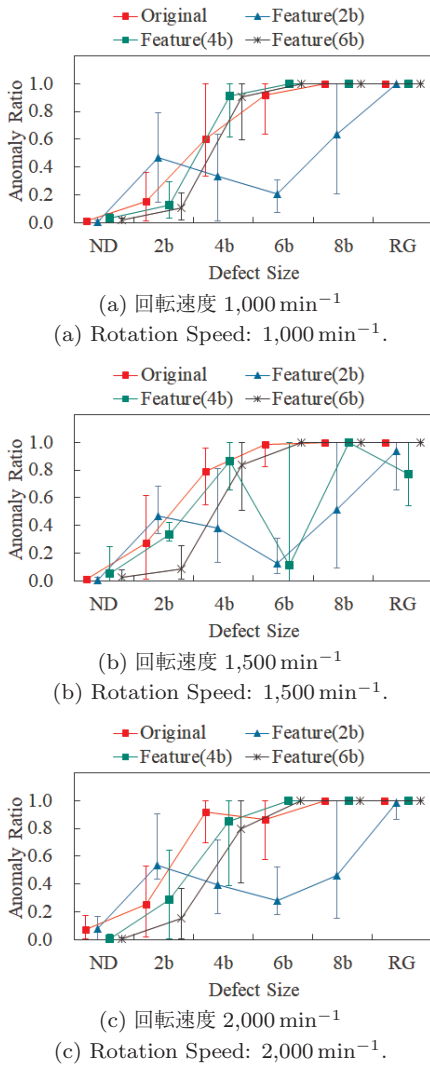


図 8 入力データ $v_j^{(S)}$ と異常率の関係

Fig. 8 Anomaly ratio for each input data $v_j^{(S)}$.

ズごとの異常率を算出した結果を従来手法 (Original) として示す. 特徴選択前の入力データ v_j に対する結果は図 5 と同じである. また特徴選択後の入力データ $v_j^{(S)}$ に対し, 交差検証により求まる LOF の周辺密度計算における近傍数の平均, 最大, 最小, 標準偏差を表 7 に示す.

図 8 より, 人工欠陥サイズ 2b への重要度の高い特徴量を選択した場合, 人工欠陥サイズ 4b または 6b への重要度の高い特徴量を選択した場合に比べ, 人工欠陥サイズ 2b の異常率は向上する. 一方で上記特徴量を選択した場合, 人工欠陥サイズ 4b, 6b に対する異常率は人工欠陥サイズ 2b に対する異常率よりも低い値となり, 対象とした人工欠陥サイズ以外において検出精度は低下する. また表 7 より学習データの違いに対して近傍数のばらつきは変化しない. そのため特徴選択後の各入力データ $v_j^{(S)}$ に対する欠陥検出精度を総合して評価する必要がある.

4.6.4 2 段の LOF による外れ値検出精度と特徴選択に用いる特徴量数の影響

特徴選択後の入力データ $v_j^{(S)}$ を用いた場合に, 特徴選

表 7 学習データの違いに対する Local Outlier Factor 近傍数のばらつき

Table 7 Variation of of the neighborhood numbers of Local Outlier Factor for the difference of train data.

Feature Vector	Rotation Speed	Average	Max	Min	Standard Deviation
Original	1,000 min ⁻¹	13.3	24	2	8.0
	1,500 min ⁻¹	9.8	25	2	8.6
	2,000 min ⁻¹	8.4	29	2	8.3
Feature(2b)	1,000 min ⁻¹	16.0	28	3	7.5
	1,500 min ⁻¹	14.0	28	5	6.4
	2,000 min ⁻¹	24.4	29	16	4.0
Feature(4b)	1,000 min ⁻¹	23.1	28	14	4.9
	1,500 min ⁻¹	14.4	28	2	8.9
	2,000 min ⁻¹	18.1	27	2	7.2
Feature(6b)	1,000 min ⁻¹	15.2	28	2	7.8
	1,500 min ⁻¹	17.2	27	5	7.0
	2,000 min ⁻¹	24.4	29	15	4.6




図 9 特徴選択に用いる特徴量数の影響

Fig. 9 Influence of number of features on feature selection.

択の対象とした人工欠陥サイズ以外の異常率が低下する問題を解決するため, 提案手法では特徴選択後の入力データ $v_j^{(S)}$ に対する異常度を元の測定データの対応するセグメントごとに 1 つのベクトル (異常度ベクトル a_j) として 2

表 8 特徴量数に対する Local Outlier Factor 近傍数の比較


Table 8 Comparison of the neighborhood numbers of Local Outlier Factor for the number of features.

Number of Features	Rotation Speed	Average	Max	Min	Standard Deviation
1	1,000 min ⁻¹	11.2	24	3	7.4
	1,500 min ⁻¹	14.9	24	6	7.0
	2,000 min ⁻¹	16.9	29	8	7.8
2	1,000 min ⁻¹	21.5	29	4	8.3
	1,500 min ⁻¹	21.3	27	11	5.8
	2,000 min ⁻¹	16.2	24	8	7.0
5	1,000 min ⁻¹	16.0	25	5	6.5
	1,500 min ⁻¹	17.8	29	2	7.9
	2,000 min ⁻¹	17.7	29	9	6.7
10	1,000 min ⁻¹	16.3	29	6	8.5
	1,500 min ⁻¹	18.0	25	3	6.6
	2,000 min ⁻¹	22.0	29	16	4.2
30	1,000 min ⁻¹	16.9	28	3	10.5
	1,500 min ⁻¹	18.1	28	6	6.7
	2,000 min ⁻¹	21.8	29	13	5.9
50	1,000 min ⁻¹	20.7	29	8	7.4
	1,500 min ⁻¹	21.5	29	2	9.4
	2,000 min ⁻¹	16.6	28	2	8.5
100	1,000 min ⁻¹	15.6	23	8	5.5
	1,500 min ⁻¹	16.1	29	2	9.4
	2,000 min ⁻¹	21.3	29	2	8.1
150	1,000 min ⁻¹	16.6	29	5	7.2
	1,500 min ⁻¹	15.6	26	9	5.1
	2,000 min ⁻¹	17.7	29	8	7.1


段目の LOF の入力データに用い、再度欠陥検出精度を比較する。そのため、提案手法の欠陥検出精度は入力データ $v_j^{(S)}$ の特徴選択における特徴量の数により変化する。そこで回転速度 1,000, 1,500, 2,000 min⁻¹ において、入力データ $v_j^{(S)}$ の特徴選択における特徴量の数と、提案手法における人工欠陥サイズ ND, 2b, 4b, 6b の異常率の平均およびばらつきとの関係を図 9 に示す。また特徴選択における特徴量の数と LOF の近傍数の平均, 最大, 最小, 標準偏差の関係を表 8 に示す。

図 9 より、回転速度によって欠陥検出精度が向上する特徴量の数は異なる。いずれの回転速度においても特徴量数 5 以下では人工欠陥サイズ 2b および 4b の異常率が低下する。また、特徴量数 30 以上では回転速度 1,500 min⁻¹ では人工欠陥サイズ 2b の異常率が上昇するが、回転速度 2,000 min⁻¹ では人工欠陥サイズ 2b および 6b の異常率が低下し、人工欠陥サイズ ND の異常率の平均が 0.2 まで上昇する。表 8 より特徴量の数に対する近傍数の違いは見られない。


欠陥検出手法の運用においては、正常な軸受を異常と誤判別することは避けるべきである。また正常な軸受と微小な欠陥を有する軸受の異常率の差が大きいほど欠陥検出は



(a) 回転速度 1,000 min⁻¹ (特徴量数 30)
(a) Rotation Speed: 1,000 min⁻¹ (30 Features).



(b) 回転速度 1,500 min⁻¹ (特徴量数 150)
(b) Rotation Speed: 1,500 min⁻¹ (150 Features).



(c) 回転速度 2,000 min⁻¹ (特徴量数 10)
(c) Rotation Speed: 2,000 min⁻¹ (10 Features).

* : 有意水準 5% (Significance Level 5%).
** : 有意水準 1% (Significance Level 1%).

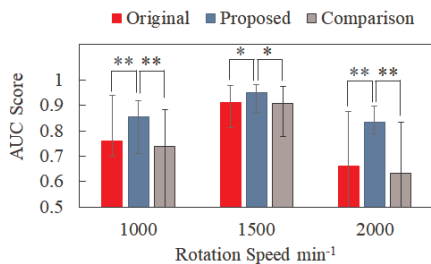
図 10 従来手法, 比較手法と提案手法の異常率の比較

Fig. 10 Comparison of anomaly ratios between original, comparison and proposed method.

行いやすくなる。そこで欠陥検出に適した特徴量数の選定基準を、人工欠陥サイズ ND の異常率が 0.2 以下であること、かつ人工欠陥サイズ ND と 2b 間のマージンが大きくなることとした。また人工欠陥サイズ ND, 2b 間のマージンが同程度の場合には特徴量数の少ないものを選択することとした。上記基準に基づき回転速度 1,000 min⁻¹ では特徴量数 30 個, 回転速度 1,500 min⁻¹ では特徴量数 150 個, 回転速度 2,000 min⁻¹ では特徴量数 10 個を欠陥検出に適した特徴量数とした。

4.7 提案手法による欠陥検出精度

回転速度 1,000, 1,500, 2,000 min⁻¹ の各運転条件において、前節で選定した欠陥検出に適した特徴量数を用いた提案手法による人工欠陥サイズと異常率の関係 (提案手法, Proposed) を図 10 に示す。比較として特徴選択前の入力データ v_j から LOF を用いて直接人工欠陥サイズごとの異常率を算出した結果を従来手法 (Original) として示す。従来手法の結果は図 5 と同じである。また特徴選択手法として Laplacian Score [16] を用いた場合の人工欠陥サ



* : 有意水準 5% (Significance Level 5%).
 ** : 有意水準 1% (Significance Level 1%).

図 11 従来手法, 比較手法と提案手法の AUC Score の比較

Fig. 11 Comparison of AUC Score between original, comparison and proposed method.

表 9 従来手法と提案手法による Local Outlier Factor 近傍数比較
 Table 9 Comparison of the neighborhood numbers of Local Outlier Factor between original and proposed method.

Method	Rotation Speed	Average	Max	Min	Standard Deviation
Original	1,000 min ⁻¹	13.3	24	2	8.0
	1,500 min ⁻¹	9.8	25	2	8.6
	2,000 min ⁻¹	8.4	29	2	8.3
Outlier Detection (2nd) (Proposed)	1,000 min ⁻¹	16.3	29	6	8.5
	1,500 min ⁻¹	18.0	25	3	6.6
	2,000 min ⁻¹	22.0	29	16	4.2

イズごとの異常率を比較手法 (Comparison) として同図に示す。図 11 に人工欠陥サイズ ND, 2b を対象とした提案手法, 従来手法および比較手法による AUC Score の比較結果を示す。図 10 の異常率, 図 11 の AUC Score について, 従来手法と提案手法, 比較手法と提案手法をそれぞれ比較し, 有意水準 5% で差が認められるものには*, 有意水準 1% で差が認められるものには** を付記した。また表 9 に提案手法と従来手法における近傍数の平均, 最大, 最小, 標準偏差を示す。

図 10 より提案手法では, 回転速度にかかわらず人工欠陥サイズ 6b 以上の異常率はほぼ 1 となり, 人工欠陥サイズ 2b についても従来手法, 比較手法に比べ異常率は有意に上昇した。また人工欠陥サイズ 4b についても, 従来手法に対しては回転速度 1,000, 1,500 min⁻¹ において, 比較手法に対しては回転速度にかかわらず, 異常率は有意に上昇した。

図 11 よりいずれの回転速度においても AUC Score は提案手法を用いることで従来手法, 比較手法に比べ改善した。回転速度 1,000 min⁻¹, 1,500 min⁻¹ では人工欠陥サイズ ND の異常率が従来手法と提案手法で有意差がみられるものの, AUC Score も有意に向上していることより, 提案手法を用いることで欠陥検出精度が向上した。

表 9 より, 従来手法と提案手法で LOF の近傍数のばらつきに変化はみられない。

5. 今後の課題

本論文で評価の対象とした実験装置は軸受の組換えによる振動のばらつきが大きく, 軸受の組換えにより多少なりとも実験環境が変化していると考えられる。しかしながら, 提案手法の検証においては, 完全に異なる実験装置での評価が必要であり, 現在, 新規の実験装置でのデータ収集を進めており, 今後提案手法の検証を予定している。

また今回提案する手法では 1 段目の LOF による異常度算出において, RF を用いた教師あり学習による特徴選択を行っており, 教師データとして欠陥を有する軸受の振動データを使用している。しかし, 実際の現場において欠陥を有する軸受の振動データを入手できる事はほとんどない。この解決方法として, たとえば Persistent Homology [27] や動的モード分解法 [28] などの振動分析手法を用い, 回転速度や機器に依存しない特徴を抽出することで, 欠陥検出精度を向上する方法が考えられる。または, RandomForest による特徴選択において, 動力学解析などの理論解析モデル [29] を用いることで, 実機での測定データの代わりに理論解析モデルから得られるデータを教師データとして利用することを考える。もしくは, 転移学習を利用することにより, 実験装置または理論解析モデルのデータを教師データとして別の装置の診断に利用することが考えられる。これらの改善方法については今後検討を進める。

6. まとめ

人工欠陥を設けた転がり軸受の振動加速度データに対し, 各種異常検知手法で欠陥検出精度を比較した。得られた知見を以下に示す。

- One Class Support Vector Machine, Local Outlier Factor, Isolation Forest の 3 種類の外れ値検出手法による欠陥検出精度を比較した結果, Local Outlier Factor が最も高い欠陥検出精度を得た。ただし, いずれの手法においても人工欠陥サイズ 2b の欠陥検出精度は 4b 以上に比べ低い。
- Random Forest による人工欠陥サイズの分類精度の評価の結果, 人工欠陥のサイズによって正常との分類に重要度の高い特徴量は異なることが分かった。また, 微小な人工欠陥サイズに対し Random Forest による特徴選択を行うことで, 対象の欠陥検出精度が向上した。
- 提案した欠陥検出方法により, Random Forest による特徴選択をしない場合に比べ, 大きな欠陥サイズの検出精度を落とすことなく微小な人工欠陥サイズの欠陥検出精度を大幅に向上することに成功した。

参考文献

[1] 五十嵐昭男, 野田万寿, 松島栄一: 転がり軸受の異常予知に関する研究 (第 1 報), 潤滑, Vol.24, No.2, pp.122-129

- (1979).
- [2] 五十嵐昭男, 浜田啓好: 欠陥をもつ転がり軸受の振動・音響に関する研究 (第1報), 日本機械学会論文集 (C), Vol.47, No.422, pp.1327-1336 (1981).
 - [3] 間野大樹, 是永 敦: AE および振動観測による転がり軸受の損傷診断, 精密工学会春季大会学術講演会講演論文集, pp.683-684 (2014).
 - [4] Schölkopf, B., Platt, J.C., Taylor, J.S., Smola, A.J., and Williamson, J.: Estimating the Support of a High-Dimensional Distribution, *Neural Computation*, Vol.13, pp.1443-1471 (2001).
 - [5] 小野田崇, 伊藤憲彦, 是枝英明: 水力発電所における異常予兆発見支援ツールの開発, 電気学会論文誌 (D), Vol.131, No.4, pp.448-457 (2011).
 - [6] Tax, D.M.J.: *One Class Classification*, Ph.D thesis, Delft University of Technology (2001).
 - [7] 近藤 捻, 高重達郎, 真鍋真一, 菅野 晋: 振動による状態監視法を用いたディーゼル機関遺物混入時の振動異常検知, 鉄道技術論文集, Vol.30, No.4, pp.47-52 (2016).
 - [8] Hermansky, H., Ellis, D.P. and Sharma, S.: Tandem Connectionist Feature Extraction for Conventional HMM Systems, *Proc. IEEE International Conference on Acoustics, Speech, and Signal Processing*, Vol.3, pp.1635-1638 (2000).
 - [9] 長谷川隆徳, 緒方 淳, 村川正弘, 小川哲司: 正常・損傷の表現学習に基づく風力発電システム異常検知技術の高度化, 第39回風力エネルギー利用シンポジウム (2017).
 - [10] 北井正嗣, 筒井英之: One Class Support Vector Machineを用いたアンギュラ玉軸受の異常診断, トライボロジー会議 2017 秋, C41 (2017).
 - [11] 加藤甲馬, 谷 僚二, 筒井英之: アンギュラ玉軸受における欠陥サイズと各種振動特徴量の関係, トライボロジー会議 2017 春, F33 (2017).
 - [12] Breunig, M.M., Kriegel, H.P., Ng, R.T. and Sander, J.: LOF: Identifying Density-Based Local Outliers, *Management of Data*, Vol.29, pp.93-101 (2000).
 - [13] Breiman, L.: Random Forests, *Machine Learning*, Vol.45, pp.5-32 (2001).
 - [14] Smith, J.S.: The Local Mean Decomposition and Its Application to EEG Perception Data, *J. R. Soc. Interface*, Vol.2, pp.443-445 (2005).
 - [15] Aziz, W. and Arif, M.: Multiscale Permutation Entropy of Physiological Time Series, *9th International Multi-topic Conference*, pp.1-6 (2005).
 - [16] He, X., Cai, D. and Niyogi P.: Laplacian Score for Feature Selection, *Adv. Neural Inform. Process. Syst.*, pp.1-6 (2005).
 - [17] Cheong, S., Sang, H.O. and Lee, S.Y.: Support Vector Machines with Binary Tree Architecture for Multi-class Classification, *Neural Inform. Process. -Lett. Rev.*, Vol.2, pp.47-51 (2004).
 - [18] Li, Y., Xu, M., Wei, Y. and Huang, W.: A New Rolling Bearing Fault Diagnosis Method Base on Multiscale Permutation Entropy and Improved Support Vector Machine Based Binary Tree, *Measurement*, Vol.77, pp.80-94 (2016).
 - [19] Kilundu, B., Chimentin, X. and Dehombreux, P.: Singular Spectrum Analysis for Bearing Defect Detection, *Journal of Vibration and Acoustics*, Vol.133, No.5, 051007 (2011).
 - [20] Bugarbee, H.A. and Trendafilova, I.: A New Methodology for Fault Detection in Rolling Element Bearings using Singular Spectrum Analysis, *The International Journal of Condition Monitoring*, Vol.7, No.2, pp.26-35 (2018).
 - [21] Zhu, H., Wang, Y. and Wang, K.: Particle Swarm Optimization (PSO) for the Constrained Portfolio Optimization Problem, *Expert System*, Vol.38, pp.10161-10169 (2006).
 - [22] Hinton, G.E. and Osindero, S.: A Fast Learning Algorithm for Deep Belief Nets, *Neurocomputing*, Vol.18, pp.1527-1554 (2006).
 - [23] Shao, H., Jiang, H., Zhang, X. and Niu, M.: Rolling Bearing Fault Diagnosis Using an Optimization Deep Belief Network, *Measurement Science and Technology*, Vol.26, pp.1-17 (2015).
 - [24] 井出 剛, 杉山 将: 異常検知と変化検知, 講談社, pp.11-12 (2015).
 - [25] Liu, F.T., Ting, K.M. and Zhou, Z.H.: Isolation Forest, *8th IEEE International Conference on Data Mining*, pp.413-422 (2008).
 - [26] 豊田利夫: 回転機械の異常診断の進め方, 日本プラントメンテナンス協会, pp.94-96 (1991).
 - [27] Umeda Y.: Time Series Classification via Topological Data Analysis, 人工知能学会論文誌, Vol.32, No.3, pp.1-12 (2017).
 - [28] 土肥宏太, 武石直也, 矢入健久, 堀 浩一: 動的モード分解を用いた音響データの異常検知, 第32回人工知能学会全国大会, 1P2-02 (2018).
 - [29] Gupta, P.K.: *Advanced Dynamics of Rolling Elements*, Springer-Veriag (1984).




北井 正嗣

2009年広島大学大学院工学研究科機械システム工学専攻博士前期課程修了。同年 NTN 株式会社入社。2013年より転がり軸受の診断技術開発に従事。



赤松 良信

1993年東京農工大学大学院機械システム工学専攻博士後期課程修了。現在大阪大学大学院工学研究科, NTN 次世代協働研究所所長, 特任教授。博士(工学) トライボロジー。



福井 健一 (正会員)

2003年名古屋大学大学院人間情報学研究科物質・生命情報学専攻博士前期課程修了。2010年博士(情報科学)(大阪大学)取得。2005年大阪大学産業科学研究所新産業創造物質基盤技術研究センター特任助手, 特任助教, 2010年同研究所助教を経て, 2015年より同准教授。データマイニング・機械学習とその応用に興味を持つ。IEEE Computer Society, 人工知能学会, 進化計算学会, 電子情報通信学会各会員。