

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

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用いて特徴ベクトルを再構成した。最後に各欠陥サイズに対してそれぞれ再構成した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

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, reconstructed feature vectors whose features are high importance to each defect sizes are used to evaluate anomaly detection accuracy and anomaly score by Local Outlier Factor(LOF). Finally, anomaly score for each reconstructed feature vectors as anomaly vectors and anomaly detection ratio is evaluated by LOF 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さない重要な要素であり、自動車やプラント、航空機等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、例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や信号処理に関する知見が必要であり、より簡易的な診断方法が望まれている。

一方で近年、回転機械の損傷評価方法として機械学習を利

¹ 大阪大学 NTN 次世代協働研究所
NTN Next Generation Research Alliance Laboratories, Osaka Univ.

² 大阪大学 産業科学研究所
The Institute of Scientific and Industrial Research, Osaka Univ.

a) masashi_kitai@ntn.co.jp

用した手法が注目されている。例えば 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, 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を検証した結果, 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].

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] により各サイズの人工欠陥を有する軸受と正常軸受を個別に分類し, それぞれに重要度の高い特徴量の選択と, 特徴選択が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章では本研究の提案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注目されている。

例えば 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] による特徴抽出と, Improved SVM-BT[16] による分類を併せることで, 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 [17]. また Bugarbee らは正常な軸受の振動データから, Singular Spectrum Analysis[18] を利用した主成分分析により, 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 [19].

しかし, 文献 [19] 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 [17] 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

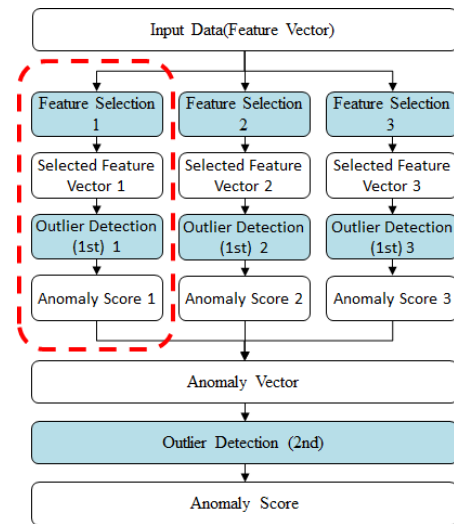


図 1 欠陥検出フロー

Fig. 1 Flow of Defect Detection.

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から算出される特徴ベクトルを入力データとし, 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, 分類手法による重要度の算出と特徴選択を行い, 特徴ベクトルをそれぞれ再構成する(図1中 Feature Selection 1 から3)。なお, 分類手法による重要度の算出は学習時のみ行い, 評価時には学習時に算出した重要度を基に直接入力データを再構成する。次に再構成した各入力データに対し, 個別に外れ値検出手法の学習, 評価を行い, それぞれの異常度を算出する(図1中 Outlier Detection (1st) 1 から3)。各入力データに対して求められる複数の異常度を, 対応する測定データに対しひとつのベクトル(異常度ベクトル, 図1中 Anomaly Vector)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を算出する(図1中 Outlier Detection (2nd))。本研究では測定対象のデータから得られるすべての特徴ベクトル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しきい値を超える特徴ベクトル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の特徴量としてベクトル化したものを入力データとする。また

2 段階目の外れ値検知手法によって得られる異常度 Anomaly Score(AS) 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 AS 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)[20] を用いる。AR 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に対し、提案手法で算出される異常度 AS を基に異常率 AR を次式で算出する。AS_{threshold} は事前に決めた欠陥検出しきい値、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。

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

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

3.4 機械学習手法

外れ値検出手法として OC SVM, LOF, Isolation Forest (IF)[21], 特徴選択のための分類手法として RF を用いた。OC SVM のカーネル関数はガウシアンカーネルを用いた。機械学習手法の実装には Python 2.7 と Scikit-learn 0.19.0 を用いた。

4. 評価実験

4.1 実験装置

実験装置の概略図を図 2 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。例えば、2b は円筒穴の直径が b の 2 倍であることを意味する。

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 1000, 1500, 2000 min⁻¹ の各条件で運転し、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。振動加速度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。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。各振動加速度データは主軸 5 回転の周期でセグメントに分割し、セグメント毎に各センサの測定データから特徴量を算出し入




図 2 実験装置

Fig. 2 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 バンドパスフィルタの種類

Table 2 Kind of Band-Pass Filter.

Filter	Frequency Range(Hz)
Raw	None
Low1	20-200
Low2	20-1000
Mid1	200-2000
Mid2	1000-5000
High1	2000-20000
High2	5000-20000

力データに用いた。

4.2 特徴量の算出

特徴量算出に使用した BPF を表 2 に示す。特徴量は各種 BPF 処理後の時間領域 (TIME)・周波数領域 (SPEC)・ケフレンシ領域 (CEPS) の実効値 (OA)・最大値 (MAX)・波高率 (CF)・変調値 (MOF)・尖度 (KS)・歪度 (SKN) の統計量を使用した。変調値はエンベロープ処理 [22] 後の実効値として定義した。周波数領域の統計量はセグメント分割後の時間領域の波形に対し、BPF 処理後、エンベロープ処理と FFT 処理を行い、得られた周波数領域の波形から算出した。またケフレンシ領域の統計量は上記 FFT 処理後の周波数領域の振幅データを対象とし、同データに再度 FFT 処理を行った後得られたケフレンシ領域の波形から算出した。そのため 1 つの測定データから、領域、BPF、統計量、センサを考慮し、合計 378 種類の特徴量が得られる。

4.3 変動係数による特徴量の選別

測定データから算出さ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測定データ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、入力データを作成した。学習に使用する測定データの組合せにより、4.2項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。

4.4 学習データ・評価データの選択

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の組合せをランダムに変更して提案手法を評価した。図1の赤枠部における測定データの組合せの詳細を図3に示す。実験で得た各人工欠陥サイズ33個の測定データのうち、正常軸受、および人工欠陥サイズ2b、4bおよび6bの測定データ各24個を学習に、各人工欠陥サイズ9個の測定データの評価に使用した。学習時にはまず正常軸受の測定データ24個および人工欠陥サイズ2b、4bまたは6bのいずれかの測定データ（図中は2b）24個から得られる入力データを用いて、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った。次に正常軸受における特徴選択後の入力データを外れ値検出手法の学習に使用し、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を選定した。評価時にはまず各人工欠陥サイズ9個の測定データから得られる入力データに対し、学習時に算出した重要度による特徴選択を行った後、異常度を算出した。なお、学習と評価に用いる測定データは重複しないようにした。

4.5 予備実験

4.5.1 外れ値検出手法の比較

図4に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 1500 min^{-1} における人工欠陥サイズと異常率の関係を示す。また表3に人工欠陥サイズNDと4bを対象とした各外れ値検出手法のAUC Scoreを示す。

図4より人工欠陥サイズ2b~6bの異常率の平均はどれもLOFが最も高い。また表3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、4b以上に比べ低い。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。

4.5.2 Random Forestによる特徴量重要度算出

回転速度 1500 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で分類を行い、

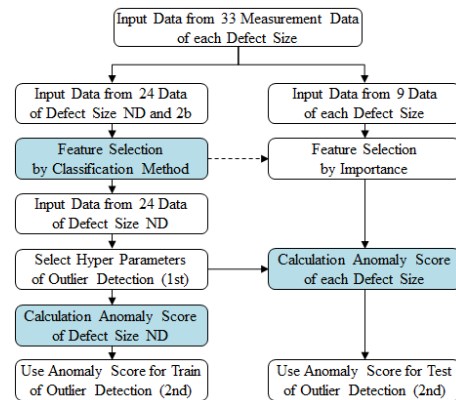


図3 学習および評価に用いるデータの組合せ

Fig. 3 Selection of Measured Data for Train and Test.




図4 外れ値検出手法の比較

Fig. 4 Comparison of Outlier Detection Methods.

表3 各手法のAUC Score

Table 3 AUC Score for each Method.

Method	Average	Max	Min	Standard Deviation
OC SVM	0.974	0.995	0.941	0.016
LOF	0.998	1.000	0.996	0.001
IF	0.980	0.992	0.963	0.009

それぞれ重要度の高い特徴量を10個抽出した例を表4に示す。人工欠陥サイズNDと2b、NDと4bの分類に共通して寄与する特徴量を太字、人工欠陥サイズNDと4b、NDと6bの分類に共通して寄与する特徴量を太字（下線）で表記する。また、表内の特徴量は統計量-領域-BPF（センサ方向）で表記する。

RFによる人工欠陥サイズNDと2bの分類精度は平均で0.98となった。また、表4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。

4.5.3 再構成した特徴ベクトルによる欠陥検出精度

各人工欠陥サイズに重要度の高い特徴量10個を用いて再構成した特徴ベクトルを入力データとし、LOFによる欠陥検出精度を評価した。回転速度 1500 min^{-1} における再構成後の特徴ベクトルに対する人工欠陥サイズと異常率の関係を図5に示す。人工欠陥サイズ2b、4b、6bを対象

表 4 各欠陥サイズに重要度の高い特徴

Table 4 Features with High Importance to Defect Size.

	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 5 欠陥サイズ毎の再構成特徴ベクトルにおける異常率

Fig. 5 Anomaly Ratio for each Reconstruct Feature Vector Selected for each Defect Size.

として再構成した特徴ベクトル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, 再構成前の特徴ベクトルから LOF を用いて直接欠陥サイズ毎の異常率を算出した結果を従来手法 (Original) として示す. 再構成前の特徴ベクトルに対する結果は図 4 と同じである.

図 5 より, 人工欠陥サイズ 2b への重要度の高い特徴量を用いた場合, 人工欠陥サイズ 4b または 6b への重要度の高い特徴量を用いた場合に比べ, 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. そのため再構成した各特徴ベクトル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 提案手法による欠陥検出精度

再構成後の特徴ベクトルを用いた場合に対象の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, 提案手法では再構成後の各特徴ベクトル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ひとつのベクトル (異常度ベクトル) として LOF の入力データに用い, 再度欠陥検出精度を評価した. 異常度ベクトルに対する人工欠陥サイズと異常率平均の関係を提案手法 (Proposed) として図 6 に示す. 比較として再構成前の特徴ベクトルから LOF を用いて直接人工欠陥サイズ毎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 4 と同じである. また図 7 に人工欠陥サイズ ND, 2b

を対象とした提案手法と従来手法による AUC Score の比較結果を示す. 図 6, 図 7 において提案手法における異常率, AUC Score について従来手法に対し有意水準 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.

図 6 より提案手法では, 回転速度に関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に比べ有意に上昇する. 図 7 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に比べ改善した. 回転速度 1000 min^{-1} , 1500 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といえる.

5. 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, 提案手法による欠陥検出精度を評価した. 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 による分類精度の評価の結果, 人工欠陥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わかった. また, 特定の欠陥サイズに重要度の高い特徴量を用いて欠陥検出を行った場合, すべての特徴量を用いた場合に比べ, 対象の人工欠陥サイズ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, 野田万朶, 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.

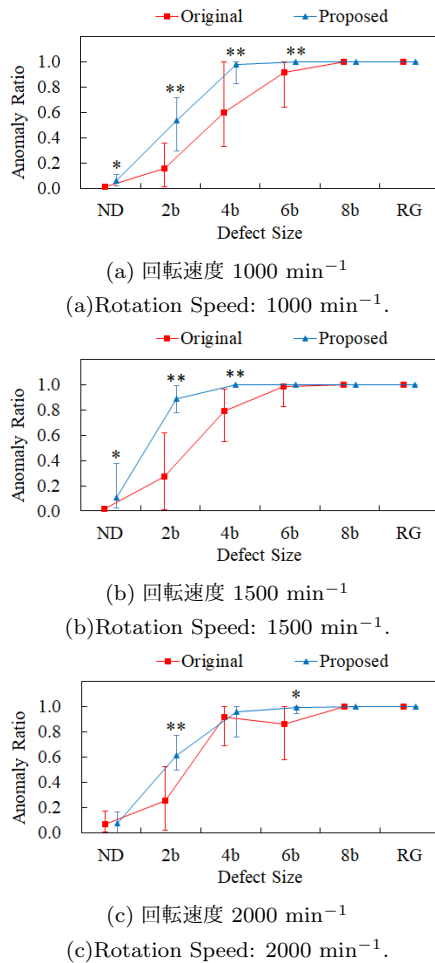


図 6 提案手法と従来手法の異常率の比較

Fig. 6 Comparison of Anomaly Ratios between the Original Method and the Proposed One.

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

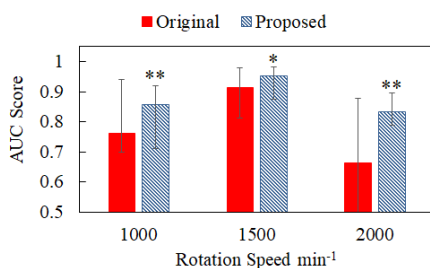


図 7 提案手法と従来手法の AUC Score の比較

Fig. 7 Comparison of AUC Score between the Original Method and the Proposed One.

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

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] 近藤裕, 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, IEEE International Conference on Acoustics, Speech, and Signal Processing. Proceedings, 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 Multitopic Conference, pp. 1-6(2005)
- [16] 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)
- [17] 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)
- [18] Kilundu, B., Chimentin, X. and Dehombreux, P. : Singular Spectrum Analysis for Bearing Defect Detection, Journal of Vibration and Acoustics, Vol. 133, No. 5, p. 051007(2011)
- [19] 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)
- [20] 井出剛, 杉山将: 異常検知と変化検知, 講談社, pp. 11-12(2015)
- [21] Liu, F.T., Ting, K.M. and Zhou, Z.H. : Isolation Forest, Eighth IEEE International Conference on Data Mining, pp. 413-422(2008)
- [22] 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)