

# 非線形主成分分析を用いた回転機の音響監視

Acoustic Diagnosis Using Kernel Based Principal Component Analysis

会津大学コンピュータ理工学部 兼本 茂 Shigeru KANEMOTO Member  
(株) 東芝 玉置 哲男 Tetsuo TAMAOKI  
(株) 東芝 清水 俊一 Shun-ichi SHIMIZU Member

The acoustic data remotely measured by handy type microphones are investigated for monitoring and diagnosing the ball bearing type rotational machine integrity in nuclear power plants. The present study proposes the new signal pre-processing method which normalizes the fundamental oscillation period into the same length and timing by using zero-crossing interval of filtered acoustic signal. The pre-processed signal patterns are classified by kernel-based principal component analysis (KPCA) and probabilistic neural network (PNN). It is shown that the monitoring index defined by KPCA and PNN is useful to classify the known and unknown states with high sensitivity.

**Keywords:** Acoustic diagnosis, Kernel-based PCA, Probabilistic neural network

## 1. 緒言

新検査プログラムの開始に伴って、状態監視保全(CBM)の役割はますます大きくなっていく。その際、振動、温度、油分析といういわゆる3種の神器による詳細な機器状態の監視手法が焦点となっているが、その前段階として、運転員や保守員によるパトロール監視も重要な活動の一つになると考えられる。そこでは、目視検査のほかに、音や匂いといった人間の5感に基づく俯瞰的な監視が必要となる。一方で、これは経験に基づく定性的判断でもあり、その客観化・定量化が可能であれば、より精度のよい状態監視に寄与できることになる。しかしながら、俯瞰的な監視は、遠隔からの広域監視を意味しており、得られる情報には、本来の機器状態信号が劣化・減衰した形で含まれ、さらに、計測過程での多様なノイズが混入することになり、有意な情報の抽出・定量化は容易ではない。また、毎回異なる測定感度に依存しない普遍的な特徴量を用いた状態判断を行うことも必要になってくる。

本稿では、このような遠隔計測した情報から、統計的信号処理手法を用いて必要な機器状態に関する情報を抽出し、その状態を識別する方法を提案する。具体的には、ころがり軸受けを題材にして、音響マイクによって計測した正常・異常時の音響データから、その測定感度の違いを校正し、高感度で異常状態を識別する信号処理・状態識別技術に関する新しい提案を行う。

著者らは前報[1,2]で主成分分析と確率ニューラルネ

ットワークを用いた識別法を提案しているが、本報では、これらの手法をさらに拡張し、回転機器の周期性に着目した波形前処理法と非線形主成分分析を導入した方法を提案する。さらに、基本周期そのものの微妙な変動パターンに着目した異常識別法も提案する。これにより、従来の信号処理法よりさらに高感度で異常状態が識別できることを示す。

本稿では、これらの状態監視法を、転がり軸受を組み込んだ異常模擬試験装置で収録した音響データに適用し、状態識別結果の妥当性を確認した結果を報告する。

## 2. 信号処理手法

### 2.1 前処理・回転同期信号の抽出

巡視点検での音響監視の場合、同じ計測位置での計測は現実的ではないため、測定感度に影響されない異常判定法が必要となる。また、回転機の診断でしばしば用いられるキーフェーザ(回転基準信号)を用いることも出来ない。これらを考慮し、本報告では Fig.1 に示すような前処理により、状態判定に用いる特徴量(パターン)を求める方法を新たに提案する。ここでは、回転機の基本周波数(回転同期成分)に着目した信号処理を行う。最初に、低域通過フィルターを用いて基本振動成分を抽出し、そのゼロ交叉点から、1回転ごとの正確な時刻を求める。回転機は、通常、ほぼ一定の周期で回転するが、高精度で周期の変動を計測

すると、回転ごとに±2%程度の変動がある。この回転周期そのものの変動を時系列信号とみなすと、これは、回転機の状態を特徴付ける情報となっていることが推察される。一方、ゼロ交叉点を基準に、1回転に対応する音響データを同じ長さに規格化して平均化すると、1回転での音響データの変動の特徴が高精度で再現できると考えられる。これは、振動信号とキーフェーザ信号の位相変化が、異常原因の推定に重要な役割を果たすことから類推して、今回新たに試みた方法である。基本周期を同じ長さに規格化して平均化することで、周波数分析した場合の基本周波数やその高調波の推定精度を高めることも出来る。

Fig.2 には、上記方法で求めた音響信号の低周波成分と高周波成分 (200Hz で区別) を、3 回転分重ね合わせて示した。後述する 50Hz で回転している正常データの信号を例に取ったものである。以下では、この固定長に規格化した波形を「回転規格化信号」と呼ぶことにする。また、Fig.3 には、基本周期の変動の時間変化を示す。約 500 回転分、10 秒のデータを示しているが、±1%程度の変動があることがわかる。

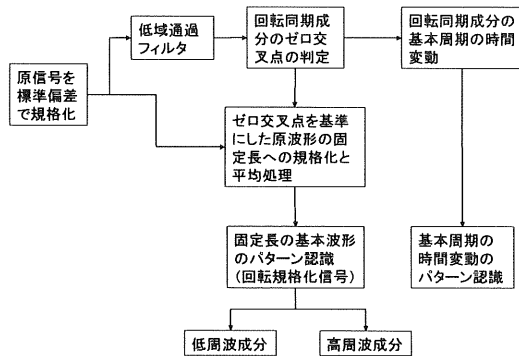


Fig.1 Pre-processing algorithm of acoustic signal measured from rotating machine




Fig.2 Extracted acoustic wave of low and high frequency component for single rotating period




Fig.3 Trend of rotating period fluctuation (fundamental period:0.02sec)

## 2.2 状態識別法

上記の回転規格化信号は、回転機の状態を示す多次元ベクトルであり、低周波成分の波形は軸の周方向の回転情報に直接関係する計測値と考えられる。一方で、高周波情報は、人間の耳に直接聞こえる情報である。これらの情報から回転機の状態を識別する際、より低次元の情報に縮約することで、直感的な状態把握が可能になる。そのための方法として、本報告では主成分分析(PCA)と、その拡張である非線形PCA(Kernel PCA、KPCA) [3,4]を利用する。

### (1) 主成分分析(PCA)による方法

正常運転時に M 回測定された p 次元回転規格化信号を  $x(m)$  ( $m=1, M$ ) とすると、相関関数は

$$\bar{C} = \frac{1}{M} \sum_{m=1}^M x(m) \cdot x(m)^T \quad (1)$$

となり、その固有値問題は下記のようになり、p 個の固有値と固有ベクトルを求めることが出来る。

$$\lambda V = \bar{C} V \quad (2)$$

このとき、M 個の回転規格化信号の、k 番目の固有ベクトルへの射影値 (主成分スコア値) は

$$z_k(m) = V^{(k)} \cdot x(m) \quad (3)$$

となる。主成分分析による方法では、p 個の固有ベクトルから選んだ少数個 (K 次元) の射影データ  $z_k(m)$ 、( $k=1, K$ )を用いて機器の状態を識別する。

### (2)非線形主成分分析 (KPCA) による方法[3,4]

Kernel PCA(KPCA)は、主成分分析の非線形空間への拡張である。まず、 $x \rightarrow \Phi(x)$  という非線形変換を考える。KPCA では、具体的な  $\Phi$  の関数形状の定義はせずに、その内積だけを定義することで、非線形空間内の射影データを求める。非線形空間での相関関数は(1)式の代わりに下記のように定義される。

$$\bar{C} = \frac{1}{M} \sum_{m=1}^M \langle \Phi(x_m) \cdot \Phi(x_m)^T \rangle \quad (4)$$

この固有値問題は(3)式と同じ形となる。ただし、固有ベクトル  $V$  の次元は異なることに注意が必要である。この  $V$  は、 $M$  個の非線形空間でのデータ  $\Phi(x(m))$  で張られる空間にあることから、次の関係式が成り立つ。

$$\lambda \langle \Phi(x_m) \cdot V \rangle = \langle \Phi(x_m) \cdot \bar{C} V \rangle \quad (m=1, M) \quad (5)$$

$$V = \sum_{m=1}^M \alpha_m \Phi(x_m)$$

ここで定義した  $M$  次元ベクトル  $\alpha$  は、(5)式より、

$$M \lambda \alpha = K \alpha \quad (6)$$

を満たすことが分かるので、この固有方程式を解くことで得られる。ここで、カーネル行列  $K$  は次のように定義される。

$$K(x_i, x_j) = \langle \Phi(x_i) \cdot \Phi(x_j) \rangle \quad (7)$$

本報告では、このカーネル関数として以下を用いた。

$$K(x_i, x_j) = \langle \Phi(x_i) \cdot \Phi(x_j) \rangle = \exp\left(-\frac{|x_i - x_j|^2}{2\sigma^2}\right) \quad (8)$$

なお、(6)式で、固有ベクトル  $\langle V^{(k)} \cdot V^{(k)} \rangle = 1$  を満たす必要があるため、 $\lambda_k \langle \alpha^{(k)} \cdot \alpha^{(k)} \rangle = 1$  なる規格化が必要である。こうして、非線形空間での固有ベクトルが求まると、この固有ベクトルへのデータ  $x$  の非線形空間での値  $\Phi(x)$  の射影値は下記のように求まる。

$$z_k = \langle V^{(k)} \cdot \Phi(x) \rangle = \sum_{m=1}^M \alpha_m^{(k)} \langle \Phi(x_m) \cdot \Phi(x) \rangle \quad (9)$$

即ち、(3)式に相当する、 $k$  番目の非線形空間での固有ベクトルへの射影値は、非線形空間での内積演算だけで求めることができ、写像関数  $\Phi$  の具体的な形状を知る必要はない。

線形の主成分分析では、固有ベクトルの数が、データの属性値の次元  $p$  を超えられないが、KPCA では、学習データ数  $M$  まで可能になる。入力となる観測データの次元が、例えば2次元である場合、主成分分析では、二つの固有軸しか求まらないが、カーネル PCA では、データ数に応じた固有軸を求めることができ、より詳細な状態識別が可能になる。

### (3) 確率ニューラルネットワーク (PNN) による監視

PNN (Probabilistic Neural Network) は混合ガウス分布の確率密度関数を識別関数とするもので、以下で定

義される[5]。ここで、 $X_{ij}$  は、 $j$  グループに属する ( $i=1, n_j$ ) 個の特徴ベクトルであり、平滑化パラメータ  $\sigma$  を用いたガウス関数の和で次式のように識別関数を計算する。

$$f_j(X) = \frac{1}{(2\pi\sigma^2)^{p/2}} \cdot \frac{1}{n_j} \cdot \sum_{i=1}^{n_j} \exp\left[-\frac{(X - X_{ji})^T (X - X_{ji})}{2\sigma^2}\right] \quad (10)$$

この確率が、以下のようにある閾値  $\varepsilon$  以下かどうかで、特徴パターン  $X$  がグループ  $G_j$  に属するかどうかを判断する。

$$f_j(X) \geq \varepsilon \Rightarrow X \in G_j$$

$$f_j(X) < \varepsilon \Rightarrow X \notin G_j \quad (11)$$

識別グループとして、正常グループ、 $k$  個の異常グループを用意しておいたとすると、そのどれかに属するか、または、どれにも属さないか (Don't know) を識別できる。どのグループに属するかは、識別関数の最大値 (尤度) を用いて判断すればよい。また、連続監視には、監視指標  $MI$  として、上式の対数をとった対数尤度関数を用いて行う。即ち

$$MI(X(t)) = \log(f_{normal}(X(t))) \quad (12)$$

ここで、 $X(t)$  は各監視時刻で計測された特徴ベクトルであり、 $f_{normal}(X)$  は、正常時に計測した複数個の学習用特徴ベクトルから計算される識別関数である。

## 3. 試験装置とデータ測定

転がり軸受けの状態監視は多く報告されているが、加速度計による計測がほとんどであり、マイクを用いた遠隔からの状態監視はあまり報告されていない。マイクによる監視は、加速度計に比べて監視精度が劣るという欠点はあるが、簡便であり、非接触で広域の情報が取れることから、状態監視においては重要な役割を担うと考えられる。また、パトロール時の運転員の定性的判断をより定量化できれば状態監視の手段としてより有用なものにできる。ただ、マイクを用いて計測したデータは、音源との距離が不定で信号強度が相対値としてしか取れないため、それを考慮した信号処理が必要である。さらに、遠隔からの計測情報であることから、観測ノイズの混入によって本質的な特徴が隠されてしまうことも多く、より精密な信号処理・特徴抽出手段が望まれる。

本稿では、このような背景の下に、Fig.4 に示した転

がり軸受けの模擬試験装置で収集した音響データを用いて、状態識別方法の検討を行う。これらのデータは、前報[1,2]と同じものを用いている。Fig.4 に示す例のように、本試験装置では、外輪傷3種、内輪傷3種、玉傷1種の異常模擬が可能で、この各データを、Fig.4 に示すような音響マイクを用いて 44.1kHz のサンプリング周期で、約 10 秒間採取した。これらのデータは、異なる回転数 (3000、2000、1500、1000、500rpm) で計測している。

計測データの一例として、定格運転(3000RPM) の正常運転時と、内輪傷大と小の場合の周波数分析結果 (APSD) の比較を Fig.5,6 に示しておく。回転同期成分と高調波が明確に観測されているが、正常と異常時の変化は高周波数成分で顕著であるものの、基本周波数やその高調波成分ではそれほど明確な差は現れていない。特に、内輪傷小の場合、正常時との差はほとんどないことが分かる。軸受けに接触させて計測した加速度計のデータからは、異常時の振動の変化は、外輪傷小の場合も含めて明確に観測されるが、非接触で計測した音響データの場合、異常による観測データの変化はわずかになってしまう。



Fig.4 Mockup facility of rolling bearing and simulated failures (Outer and Inner race defects)




Fig.5 Auto-Power Spectral Density of acoustic sound for

Normal and Inner race defect (Large) condition

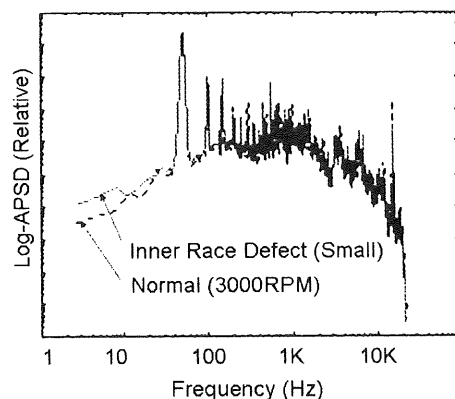


Fig.6 Auto-Power Spectral Density of acoustic sound for Normal and Inner race defect (Small) condition

## 4. 適用結果

### 4.1 状態識別性能の評価

定格運転 (3000RPM) での内輪傷 (大、中、小) 3 ケースのデータを例にとって、正常データからの識別性能を評価する。各データは、基本周期 (50Hz、0.02s) 10 波分を平均して得た周波数スペクトル密度 (APSD)、ないし、低周波通過フィルターを通した後の生データ波形の平均値を特徴量として用いる。3 種の異常時と正常時の各状態で夫々 50 ケース分のデータを識別することを試みる。1 ケース 0.2 秒のデータ長になるので、50 ケースは、10 秒のデータに相当する。

特徴量は、PSD の場合 512 点、生データの場合 1024 点となるが、この中から代表的な 2 点を、経験的、ないし、PCA/KPCA によって選択し、さらに、(10)式による PNN でモデル化し、各状態の確率密度関数を求める。このとき、正常と異常の識別性能を、下記のように正常データの最小対数尤度と異常データの最大対数尤度の差 CI (Classification Index) で定義する。この値が正で大きいほど識別性能がよくなる。また、CI が負になると、一部の異常データを正常とみなしてしまうことになる。

$$\begin{aligned}
 L_1 &= \min_{j \in \text{normal}} \log \{f_{\text{normal}}(X_j)\} \\
 L_2 &= \max_{j \in \text{Abnormal}} \log \{f_{\text{normal}}(X_j)\} \\
 CI &= L_1 - L_2
 \end{aligned} \tag{13}$$

Fig. 7 は、経験的特徴量として、高周波数(200Hz 以上)の振幅、基本周波数(50Hz)の振幅、第 2 高調波の振幅を用いた際の各状態(正常、3 種の異常)の違いを図示したものである。図から分かるように、正常と内輪傷小の状態は、基本周波数と第 2 高調波の振幅によって識別されることが分かる。このときの CI 値は、8.72 である。内輪傷小の状態は、Fig. 6 からわかるように、正常状態とほとんど差がないため、着目する特徴量を適切に選ぶことで始めて識別が可能になる。

一方、Fig. 8 は 512 次元の PSD を入力として主成分分析を行い、(3)式により求めた第 1、第 2 主成分を軸にとって 4 種の状態を識別したものである。正常と内輪傷小はより明確に識別できており、CI 値 14.5 が得られている。また、Fig. 9 は、1024 次元の生データを入力として KPCA を行い、(9)式に基づいた第 1、第 2 主成分によって分類した結果である。このとき、識別はさらに明確になっており、CI 値 25.2 が得られた。

これらの結果より、KPCA は、小さな変化を感度良く識別できることがわかる。前報[1,2]の結果と比べても識別性能が大きく向上している。




Fig.7 State classification using three heuristic feature indices for Normal and Inner race defects( Small, Middle and Large)

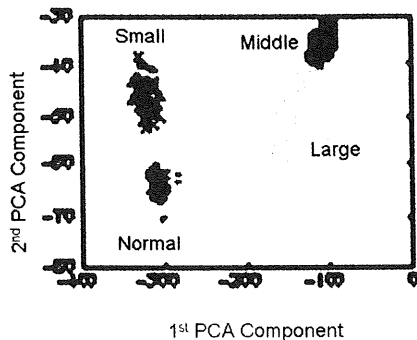


Fig.8 State classification using PCA for Normal and Inner race defects( Small, Middle and Large)

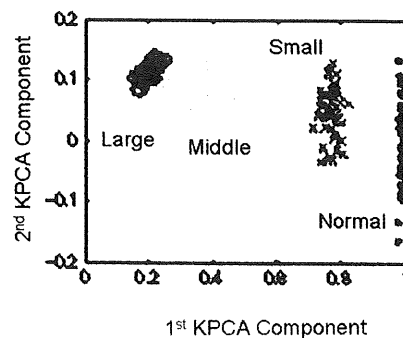


Fig.9 State classification using KPCA for Normal and Inner race defects( Small, Middle and Large)

## 4.2 連続監視性能の評価

ここでは、(12)式で定義した監視指標 MI による連続監視性能を評価する。前記の正常状態の 50 ケースを半分に分け、25 ケースから PNN の基準モデル(10)式を作成し、これを用いて、残り 25 ケース、ならびに、3 種の異常状態 150 ケースの状態識別を行った。Fig. 10 は、PCA 第 1, 2 主成分により求めた MI の結果であるが、内輪傷小、中、大のそれぞれの結果を適切に識別できていることが分かる。また、Fig. 11 は、KPCA による結果である。PCA に比べ、内輪傷小の状態がより明確に識別できていることが特徴的である。即ち、微小な差を高感度で識別できることが分かる。

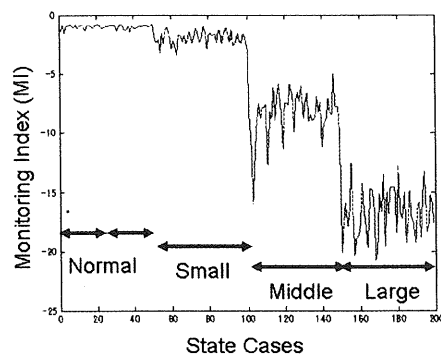


Fig.10 Continuous monitoring by PNN log likelihood index (PCA)

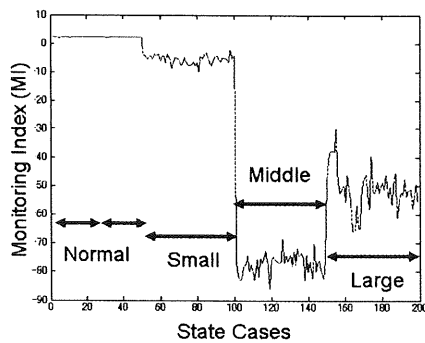


Fig.11 Continuous monitoring by PNN log likelihood index (KPCA)

### 4.3 回転周期の変動パターン

Fig.1 で定義した回転周期そのものの変動パターンの例を Fig.12 に示す。回転機の基本回転周期が異常兆候の一つとしてどんな意味を持っているかは現状明らかにはされていないが、この例のように、 $\pm 2\%$ 程度の揺らぎを持っており、正常状態と外輪傷大の場合でそのパターンは異なっていることが分かる。カオス分析でしばしば取り上げられる基本周期そのものの変動が、回転機の監視で有意義かどうかは今後の課題であるが、状態監視の一つの指標として、今後検討してゆく価値はあると思われる。




Fig.12 Fluctuation of principal rotating periods for normal and Outer race defect (Large) state data

## 4. 結言

音響マイクを用いた転がり軸受けの異常監視を例に、各種の信号処理・状態識別法の検討を行った。音響マイクの利用は、運転員の俯瞰的な監視手段として有用と考えられるが、遠隔からの監視であるため、データ

の定量化に工夫が必要である。このために、回転周期ごとにデータを規格化する前処理と、PCA・KPCA と PNN を組み合わせた状態識別法を提案した。これによって、微小な状態変化を高感度で識別できることを明らかにした。

音響監視は、監視の容易性という点で有用であるが、監視精度（保全に結びつく異常をどの程度正確に評価できるか）や、判断基準（保全の必要性を判断する基準）を明確にすることが、必ずしも容易ではない。特に、音響信号の変化の中には、異常に結びつく可能性のある兆候と、環境変化などに起因した正常範囲内での変化があるため、これを見分けることが大事になる。そのためには、状態監視データの蓄積と同時に、本報で述べたような多様な特徴を抽出・評価するデータ処理法に関する研究が重要となると考えられる。

## 謝辞

本研究は保全学会状態監視技術分科会の活動の一環として行ったものである。支援を受けた保全学会に感謝の意を表す。

## 参考文献

- [1] 玉置哲男、榎本光広、兼本 茂、日隈幸治、永森明、「主成分分析と確率ネットワークによる音響診断」、第2回評価・診断に関するシンポジウム、日本機械学会 (2003.12)
- [2] 玉置哲男、榎本光広、兼本 茂、日隈幸治、永森明、「確率ネットワークを用いた音響診断システム」、日本原子力学会 2003 年春の年会、K47 (2003.3).
- [3] D.F.Spect: Probabilistic Neural Networks for Classification, Mapping, or Associative Memory, Proc. IEEE Int. Conf. On Neural Networks, Vol.1, pp525-531 (1988).
- [4] N. Cristianini, J. Shawe-Taylor, An Introduction to Support Vector Machines, Cambridge University Press, 2000.
- [5] B. Scholkopf, A. Smola, K.R. Muller, Nonlinear Component Analysis as a Kernel Eigenvalue Problem, Neural Computation, 10, p.1299-1319(1998).