正確な区分時点推定に基づく局所定常 AR モデルによる 転がり軸受の音響診断*

太田 博 光^{*1}, 瀬戸 邦 聰^{*2}

Acoustic Diagnosis on Rolling Bearings Based on Presumption of a Division Term by Locally Stationary AR Model

Hiromitsu OHTA^{*3} and Kunisato SETO

^{*3} Department of Ocean Mechanical Engineering, National Fisheries University,
2-7-1 Nagatahonmachi, Shimonoseki-shi, Yamaguchi, 759-6595 Japan

Acoustic diagnosis system with condenser microphone has some attractive characters what is more cheaper for cost of devices of sensor, is not keeping contact with machinery components and is wide band range on frequency compared with piezoelectric accelerometers. This paper proposes a method to do condition diagnosis about strong non stationary signal generated by operating rotating machineries which are rolling bearings. Especially, a signal processing technique in order to eliminate non stationary noises including operating sound is described by adopting locally stationary AR model a kind of system identification. Further, the optimum order of locally stationary AR model is determined from presumption of division terms. The effectiveness of this method has been identified by experiment based on a rotary simulator device on rolling bearings.

Key Words: Acoustic, Diagnosis, Rolling Bearings, Non Stationary Signal, Locally Stationary Auto Regressive Model, System Identification

1. 緒 言

産業界において限りある資源を有効に活用し経済発展を持続させるためには機械要素および機械システムの設備管理を最適な状態に維持し長期的に使用することが望まれる。設備管理技術者はこのような観点からメンテナンスを行っており今後さらに機械要素、機械システムに対する診断精度向上に関する欲求が強まるものと考えられる。回転機械は設備診断分野において最も多く診断対象として取り扱われており診断に対する需要が多いことが特徴である。中でも転がり軸受は設計、生産のトータルコストは低く、コストパフォーマンスも優れ、メンテナンスも比較的容易であるため使用率が高く診断対象として多くの研究が行われている^{①②}。通常、転がり軸受の診断では軸受から発生する振動や音響^{③④}などの状態変数を情報としてセンサでとらえ、その中に含まれる異常成分の解析を行う。用いられるセンサは圧電型加速度ピックアップ、AE センサ^{⑤⑥}が一般的である。これらセンサは診断対象となる機械要素近辺に設置するという作業が必要であり、また回転機械の構造、測定環境によっては設置自体が困難な

場合も多々ある。以上のような理由から圧電型コンデンサマイクロホンを使用した転がり軸受の音響診断^{⑦⑧}を行っている。

一方、診断中の運転状態に目を移すと通常、診断精度の関係上、診断中は定常状態で運転されることが望ましい。しかしながら最近では生産ラインの工程上、時系列信号の分散が急峻に変化する強非定常状態で運転されている設備も多々ある。また診断のために運転状態を定常に変更するなどの措置が必要となるため生産効率が減少するなどの問題が発生するため運転状態を変更する必要のない診断手法が必要となっている。そこで本研究では強非定常運転をする転がり軸受の音響異常診断に取り組んでいる。具体的にはシステム同定手法の1つであるパラメトリックモデルの局所定常 AR モデル^⑨（以下、LSAR モデルと略）の性質に基づいた SN 比改善のための音響診断アルゴリズムを用いた診断精度の向上を図る。また強非定常運転状態に対応させた診断を行うため運転状態が変化する区分時点を正確に推定する必要がある。本研究では各時点での AIC 値を求めその変化に基づいた推定を行い、区分時点が推定された後に区間に適切な自己回帰係数を適用

* 原稿受付 2003 年 4 月 3 日。

^{*1} 正員、水産大学校海洋機械工学科(〒759-6595 下関市永田本町 2-7-1)。

^{*2} 正員、佐賀大学理工学部(〒840-8502 佐賀市本庄町 1)。

E-mail: ohta@fish-u.ac.jp

しモデリングを行い、強非定常状態での異常診断の有効性を示している。

2. LSAR モデルの理論および音響診断アルゴリズム

2.1 LSAR モデルのモデリング 最初に LSAR モデルによる非定常信号のモデリング手法の解説を行う。定常時系列のモデリングに効率的な AR モデルと異なり、LSAR モデルは非定常時系列を任意の小区間に分割し、定常と仮定することで非定常時系列を近似的に表現する手法であり、それぞれの定常区間には AIC に基づいて適切に決定された次数に対応する自己回帰係数を適用させることでモデリングを行う。LSAR モデルは式(1)で表現することができる。

$$x_k = -\sum_{i=1}^{m_j} a_{ji} x_{k-i} + n_{kj} \quad (1)$$

ここで、 x_k : 推定される時系列

a_{ji} : 次数 j 、項数 i における自己回帰係数

x_{k-i} : 推定に使用される過去の時系列

n_{kj} : $x_l (l < k)$ と独立な定常白色雑音

m_j : j 区間における次数 m

モデリングを行うということは式(1)において各区間ごとに最適な自己回帰係数 a_{ji} を求めるということである。本研究では短い時系列からでも安定した解が得られる Burg 法¹³⁾により自己回帰係数 a_{ji} を求めている。まず式(1)に関する行列方程式を以下に求める。時系列 x_k の自己相関関数 c_i は式(2)で表現できる。

$$C_i = C(i \Delta t) = E\{x_k x_{k-i}\} \quad (2)$$

$E\{\}$: 期待値

式(1)の両辺に x_k を掛けて期待値を取ると式(3)となる。

$$C_0 = E\{x_k^2\} = -\sum_{i=1}^{m_j} a_{ji} C_i + E\{n_{kj}^2\} \quad (3)$$

同様に式(1)の両辺に $x_{k-1}, x_{k-2}, x_{k-3}, \dots, x_{k-m_j}$ を掛けて期待値を取ると以下の行列方程式が得られる。

ここで、 P_{m_j} : 自己回帰係数からの残差出力
式(4)の計算を簡略化するために Levinson 漸化式、式(5)を利用する。また式(5)は式(6)と表現することもできる。

$$\begin{bmatrix} C_0 & C_1 & \cdots & C_{m_j} \\ C_1 & C_0 & \cdots & C_{m_j-1} \\ \vdots & \vdots & & \vdots \\ C_{m_j} & C_{m_j-1} & \cdots & C_0 \end{bmatrix} \begin{bmatrix} 1 \\ a_{m_j,1} \\ \vdots \\ a_{m_j,m_j} \end{bmatrix} = \begin{bmatrix} P_{m_j} \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (4)$$

$$\begin{bmatrix} 1 \\ a_{m_j,1} \\ a_{m_j,2} \\ \vdots \\ a_{m_j,m_j} \end{bmatrix} \begin{bmatrix} 1 \\ a_{m_j-1,1} \\ a_{m_j-1,2} \\ \vdots \\ a_{m_j-1,m_j-1} \\ 0 \end{bmatrix} + a_{m_j,m_j} \begin{bmatrix} 0 \\ a_{m_j-1,m_j-1} \\ a_{m_j-1,m_j-2} \\ \vdots \\ a_{m_j-1,1} \\ 1 \end{bmatrix} \quad (5)$$

$$a_{m_j,k} = a_{m_j-1,k} + a_{m_j,m_j} \cdot a_{m_j-1,m_j-k} \quad (6)$$

式(6)を見るとわかるように、この漸化式を利用すると自己回帰係数 a_{m_j,m_j} が求まっていると 1 つ前の次数 $m_j - 1$ の k 項目の自己回帰係数 $a_{m_j-1,k}$ と $m_j - k$ 項目の a_{m_j-1,m_j-k} を利用して未知の自己回帰係数 $a_{m_j,k}$ が推定できるというものである。Burg 法のアルゴリズムでは未知変数 $m + 2$ 個であるが方程式の数は $m + 1$ 個であるため条件式が 1 つ不足している。その点を解決するために条件式を加える必要がある。ここで自己回帰係数に前後から時系列信号を入力する際の残差出力 P_{m_j} が最小になるという判断基準式、式(7)を付け加える。

$$P_{m_j} = \frac{1}{2(N-m_j)} \sum_{i=1}^{N-m_j} \left(\left(x_i + \sum_{k=1}^{m_j} a_{m_j,k} x_{i+k} \right)^2 + \left(x_{i+m_j} + \sum_{k=1}^{m_j} a_{m_j,k} x_{i+m_j-k} \right)^2 \right) \rightarrow \text{Min} \quad (7)$$

残差出力 P_{m_j} は条件式。式(8)を考慮すると式(9)で求められる。各時点における最適な次数の決定は残差出力 P_{m_j} により求められる式(10)の AIC から判断することになる。本研究では時系列の統計的性質が変化する時点の推定法として各時点における AIC 値を求め急峻に値が上昇する時点を波形の統計的性質が変化している時点と仮定し、以降の時系列に対しては別の自己回帰係数を用いてモデリングを行う。要するに波形の統計的性質が変化しない区間においては同一の自己回帰

係数によりモデリングを行い、他の統計的性質の変化する区間ではその区間で求められた最適な自己回帰係数を適用しモデリングを行う。

$$\frac{\partial P_{m_j}}{\partial a_{m_j, m_j}} = 0 \quad (8)$$

$$P_{m_j} = P_{m_{j-1}} (1 - a_{m_j, m_j}^2) \quad (9)$$

$$AIC(j) = (L - m) \log p_{m_j}(j) + 2(j + 1) \quad (10)$$

2.2 音響診断アルゴリズム 音響信号に含まれる暗騒音成分を分離し異常信号成分のみを抽出および強調させる手法として本研究では残差成分 P_{m_j} の変動に着目している。図 1 に異常成分強調を目的とした LSAR モデルによる音響診断ブロック線図を示す。まず異常のない正常時の転がり軸受から発生する音響信号（以下、正常信号と略）を用いて AIC を算出し最小値を取る回数における自己回帰係数を最適なモデリング次数とし、これを用いて正常時の LSAR モデル（以下、正常モデルと略）としモデリングを行う。次に転がり軸受が異常時に発生する音響信号（以下、異常信号と略）を正常モデルに入力させる。この際に生じる未来を予測する予測信号とさきほど入力した異常信号の差がいわゆる残差成分 P_{m_j} であり、本来、正常モデルに正常信号を入力した際の残差成分 P_{m_j} の統計的性質は理論上、白色であり、値自体の大きさも小さくなる。しかしながら、異常信号を入力した場合、残差信号の白色性は崩れ、異常成分が強調されるため値自体が大きくなる。この性質を利用して SN 比改善および異常成分の強調に貢献することができ残差成分の統計的性質の解析を行えば音響診断の高精度化が可能となる。

Fig.1 SN ratio improvement block diagram

2.3 AIC による区分時点推定法 LSAR モデルは非定常信号を任意の区間に分割し各区間に最適な次数の AR モデルを適用させる手法である。以下に分割アルゴリズムの説明を行なう。任意の非定常信号を最小分割長さ L で i 個に分割する。ここで L のデータ点数を N_j とすると各区間のデータ点数 $[n_{i0}, n_{i1}]$ は式 (11) で表現できる。

$$n_{i0} = \sum_{j=1}^{i-1} N_j + 1 \quad n_{i1} = \sum_{j=1}^i N_j \quad (11)$$

以下に分割アルゴリズムの説明を行う。

Step 1 最初に定常を仮定した任意の最小分割長さ L を時系列データ中に設定する。

Step 2 設定された定常区間のデータを $x_1, x_2, x_3, \dots, x_L$ とする。モデリングを行なう次数 $m (< L)$ を設定し $AIC_0(0), AIC_0(1), AIC_0(2) \dots AIC_0(m)$ を求め $AIC_0 = \min_j AIC_0(j)$ を求め最適な次数を決定する。ここで $k = 1, n_{10} = m + 1, n_{11} = L, N_1 = L - m$ である。 k は分割数を表す。

Step 3 次の最小区間データ $x_{n_{k1}+1}, \dots, x_{n_{k1}+L}$ に m 次の AR モデルを当てはめる。 $AIC_1(0), AIC_1(1), \dots, AIC_1(m)$ を算出し $AIC_1 = \min_j AIC_1(j)$ を求め最適な次数を決定する。ここで Step 2 で求めた $AIC_0 = \min_j AIC_0(j)$ および AIC_1 を加え AIC_0 と定義しこれを分割モデルと呼ぶ。

$$AIC_D = AIC_0 + AIC_1 \quad (12)$$

Step 4 前述の分割モデルは 2 つの最小区間 $[n_{k0}, n_{k1}]$ および $[n_{k1} + 1, n_{k1} + L]$ においてそれぞれ最適な次数を決定し AR モデルを当てはめた。次に 2 つの区間データ $x_{n_{k0}}, \dots, x_{n_{k1}+L}$ に対して単独に次数 m の AR モデルを設定し $AIC_0(0), AIC_0(1), \dots, AIC_0(m)$ を算出し $AIC_0 = \min_j AIC_0(j)$ を求める。これを併合モデルと呼ぶ。

Step 5 Step 3 と Step 4 で定義した分割モデルの AIC_0 および併合モデルの AIC_D の大きさを比較し $AIC_0 < AIC_D$ ならば対応する区間は分割モデルでモデリングを行ない $AIC_0 > AIC_D$ ならば併合モデルにてモデリングを行なう。

Fig.2 Partition algorithm to make optimum LSAR model

Step 6 前述の区間で分割モデルが採用されたならば次に対象となる区分点は $n_{k1} + 1$ となり $k = k + 1$ とし Step 2 に戻り各区間 L の AIC を求め次数を決定する。併合モデルが採用されたならば次に対象となる区分点は $n_{k1} + L$ となり次の区間 $2L$ 相当分の AIC を求めるために Step 4 に戻る。分割アルゴリズムの概念図を図 2 に示す。

本研究では説明を行った分割アルゴリズムに従って時系列の強非定常性を持つ区分点の推定を行うのであるがさらに正確な区分時点を求めるために設定された最小分割長さ L を各時刻ごとにずらし、そのたびに AIC の計算を行い各時刻の AIC 値の変化から正確な区分時点の推定を行っていることが特長である。

3. 回転シミュレータを用いたモデリング

回転シミュレータを用いて得られた正常信号から LSAR モデルのモデリングを行う。本研究で用いた回転シミュレータと診断の対象となる自動調心玉軸受(以下、軸受と略)を図 3 に示す。回転シミュレータは 2 つの軸受によって保持されたフライホイール付きのロータを有する構造になっている。動力は電動モータからベルト駆動でロータに伝えられる。診断対象軸受の仕様は形式 1302 でピッチ円直径 27.6mm、球の直径 6.35mm、球の個数 20、接触角 9° である。軸受は外輪に任意に傷を付けた異常ベアリングと交換可能である。正常信号は診断対象の軸受から 30mm 離れた位置に配置している圧電型 1/2inch コンデンサマイクロホン 1 組によって測定される。また異常成分確認のため軸受ラジアル方向の振動加速度を圧電型加速度ピックアップ 1 組によって同時に測定が行われる。正常信号はアンプにより増幅されデジタルデータレコーダに保存された後、LSAR モデルに関するモデリングを行う。診断は外輪に傷のない正常軸受を用いて得られた正常

信号および外輪に傷を付けた異常軸受で得られた異常信号を LSAR モデルに入力し音響診断アルゴリズムに従い残差出力を検討する。さらに本研究では回転機械の運転状態が変化し、それに伴い強非定常的に変化

Fig.3 Photographs of rotating machinery simulator and a tested rolling bearing

Fig.4 Non stationary normal acoustic signal

Fig.5 AIC values of each time

する信号の区分時点の正確な推定も行う。非定常的に変化する音響信号を得るために回転シミュレータの回転数を 800rpm から 1700rpm に急峻に変化する区分時点点を 1 点設定している。測定はサンプリング周波数 20kHz、測定時間は 0.04 秒間、測定点数は 800 点、時刻 0.015 秒までが回転数 800rpm、それ以降は回転数 1700rpm である。図 4 は非定常的に変化する区分時点点を 1 点持つ正常信号である。時刻 0.015 秒までは信号の振幅も小さく分散も少ない正常信号で構成され、時刻 0.015 秒以降では急激に振幅が大きく分散も多い特徴を持つ正常信号である。本正常信号の非定常性の程度を確認するため各時刻における AIC を算出したものが図 5 である。図から明かなように時刻 0.015 秒付近までの AIC 値の変化はそれほど顕著でないためこの領域では定常的な信号で構成されていることが示されている。一方、時刻 0.015 秒付近から急激に AIC 値の増加を示しており、この時刻において非定常性が強まっていることがわかる。一旦、増加した AIC 値はその後、顕著な変化は現れておらず定常的な信号に復元したことが現れている。以上から判断すると区分時点は時刻 0.015 秒であり、AIC 値を各時刻ごとに計算することでその正確な推定が可能であることがわかる。またモデリングに際しては区分時点を境にして個別の領域で行う必要がある。本条件の場合、時刻 0.015 秒以前

Fig.6 AIC values of time 0.014 second

Fig.7 AIC values of time 0.037 second

Fig.8 Optimum auto regressive coefficients of 45 order

Fig.9 Optimum auto regressive coefficients of 50 order

の領域では時刻 0.014 秒において最小値を取っている。また 0.015 秒以降の領域では時刻 0.037 秒において同様に最小値を取っていることから各領域のモデリングはそれぞれ時刻 0.014 秒および時刻 0.037 秒での自己回帰係数を用いる。次にモデリングに用いる最適な次数の選択を行う。図 6 および図 7 はそれぞれの領域で最小値を取った時刻 0.014 秒および 0.037 秒における AIC 値の変化を示している。図では最小分割長さ L をデータ点数 50 とし次数 50 次までの計算を行った結果を示している。時刻 0.014 秒では次数 45 次で最小値を取り、時刻 0.037 秒では次数 50 次で最小値を取ることが計算の結果判明している。よって本条件では時刻 0.015 秒以前の領域では次数 45 次、時刻 0.015 秒以降の領域では次数 50 次でのモデリングが最適であることが示されている。またモデリングに使用された自己回帰係数を図 8 および図 9 に示す。

4. 強非定常音への有効性の検討

音響診断アルゴリズムに従い正常モデルに非定常な区分時点を持つ正常信号および異常信号を入力した際の残差成分をそれぞれ検討し診断の有効性を確認する。残差成分は LSAR モデルによって予測される予測信号と事前に入力された正常信号もしくは異常信号の差

である。理論上、モデルが正常信号でモデリングされており、入力が正常信号であれば差成分の統計的性質は白色性を有し、異常信号を入力するのであれば残差成分には異常成分のみが強調されることになる。図 10 は回転シミュレータによりモデリングを行った条件、回転数 800rpm から 1700rpm に変化する非定常な区分時点を持つ正常信号を入力したときの残差成分である。区分点はモデリングに使用した正常信号と同一で時刻 0.015 秒である。残差成分は全体的に白色性を有していることがわかりモデリングが良好に行われたことを示している。振幅は回転数 1700rpm に相当する時刻 0.015 秒以降は多少大きいようであるが大きな違いは現れていない。時刻 0.015 秒直後に見られる振幅の乱れは回転数 1700rpm の自己回帰係数、図 9 を使用してモデリングしているにも関わらず区分時点である時刻

0.015 秒直後ではモデリングに使用しているデータがまだ区分時点以前のデータであることに原因がある。

一方、図 11 は同一の正常モデルに軸受外輪に傷を有する異常信号を入力した際の残差信号である。図 12 は同時刻に振動加速度ピックアップを用いて測定を行った振動加速度であり軸受の球が外輪上の傷に衝突する際に生じる衝撃振動が現れていることがわかる。図 11 の残差成分と比較すると衝撃振動の位置と対応する箇所に異常成分の振幅の大きな箇所が見られることから異常成分の強調が良好に行われていることがわかる。

よって正常信号と異常信号の判別は可能であることから軸受の異常診断は可能である。よって本手法を用いることによって信号の統計的性質の変化する区分時点をも有した非定常異常診断の高精度化も実現可能である。

5. 結 言

本研究では強非定常状態で運転される機械要素の 1 つである転がり軸受の音響診断を試み、以下の結論を得た。

信号の分散が急峻に変化する区分時点をも有する運転状態いわゆる強非定常運転状態の回転機械、その中でも転がり軸受の音響診断の高精度化を行った。手法としては強非定常音に対応したパラメトリックモデルの 1 つである LSAR モデルを用い回転シミュレータから得られる正常信号を基にモデリングを行い、そのモデルに正常信号および異常信号を入力した際の残差成分の統計的特徴から音響診断を試みた。また運転状態が急峻に変化する区分時点の正確な推定手法として各時刻の AIC 値を算出し値の変化から正確な区分時点の推定が可能となっており、これまで困難であった強非定常状態での転がり軸受の音響診断の高精度化が実現できた。

今後は診断精度におよぼす SN 比の影響、最小分割長さ L 中に含まれる異常成分の割合および測定データのサンプリング周波数は異常成分の強調度合に直接影響をおよぼすため LSAR モデルによる最適な診断条件を決定するにはなお検討が必要である。

文 献

- (1) 劉 信芳・豊田利夫・陳鵬・二保知也・馮芳, 対称型カルバック情報量による回転機械の異常診断, 日本設備管理学会誌, Vol. 10 No.3, (1998), 22-27.

Fig.10 Normal signal residual component

Fig.11 Abnormal signal residual component

Fig.12 Non stationary abnormal vibration signal

- (2) 豊田利夫・二保知也, 正常時の振動波形のみを用いた回転機械の異常診断, 日本設備管理学会誌, Vol. 11, No.1, (1999), 4-11.
- (3) 邵毅敏・根津紀久雄・松浦勤・長谷川祐樹・寒澤則明, 適応フィルタを用いたベアリングの故障診断, 日本設備管理学会誌, Vol. 12, No.3, (2001), 9-15.
- (4) 関口泰久・中川紀壽, リアプノフ指数解析による転がり軸受の異常診断, 機講論アブストラクト集, No.02-9, (2002), 59.
- (5) 鈴木英男, 音響法と振動法による診断, 騒音制御, Vol.22, No.5, (1998), 283-287.
- (6) 陳 鵬, 音響・振動による機械装置の診断, 日本音響学会誌, Vol.58 No.5, (2002), 289-294.
- (7) 吉岡武雄, AE 法による機械システムの故障予知診断, 日本機械学会誌, Vol.105, No.1009, (2002), 32-33.
- (8) 中嶋智, 適応フィルタを用いたころがり軸受の音響診断, 日本設備管理学会平成 11 年度秋季研究発表大会論文集, (1999), 4-1 - 4-6.
- (9) 太田博光・江副寛・瀬戸邦聰, 回転機械の非定常運転時における音響診断, 機講論アブストラクト集, No.02-9, (2002), 101.
- (10) Hiromitsu OHTA and Kunisato SETO, Diagnosis for Rotary Machinery Based on Locally Stationary AR Model, The Sixth International Conference on Motion and Vibration, No.02-201, (2002), 1163-1167.
- (11) 橘弘幸・林弘能・竹田博, 機械音の線形予測係数を基にしたニューラルネットワークによる機械の故障診断, 日本マリンエンジニアリング学会誌, Vol. 38, No.3, (2003), 26-31.
- (12) 北川源四郎, Fortran77 による時系列解析プログラミング, 岩波書店, (1999), 185-204.
- (13) 日野幹雄, スペクトル解析, 朝倉書店, (1996), 217-223.