

博 士 論 文

回転機械設備の状態監視・診断法 に関する研究

— 振動・AE 信号およびベイジアンネット
ワークによるアプローチ

平成 26 年 3 月

三重大学大学院生物資源学研究科

江 海洋

要旨

21世紀の地球環境時代においては、限りのある地球資源を有効に活用し、持続的な発展が強く求められる今日、設備の安全、安心を確保するメンテナンス技術の重要性はますます高まっている。設備診断技術は、設備メンテナンスの中核技術であり、設備の安全を確保する技術として一段と注目されている。回転機械は工業と農業の生産プラントに最も常用されている重要な設備で、そのトラブルや故障は生産や品質に与える悪影響が大きなものである。回転機械の異常診断は簡便さから振動法によるものが主流であるが、現在の振動法による回転機械の異常診断の主な問題点と本研究の内容は次のように挙げられる。

1、異常信号の抽出法の研究

設備故障の初期段階で、または危険な生産環境と有毒な加工物などの原因を考え、故障部位から遠く離れた距離で測定した信号はノイズに強く汚染され、異常信号成分が比較的微小であるから、このような信号から異常パターンの特徴を抽出することが困難である。ノイズ除去すれば、異常の識別が容易になるため、ノイズの除去は設備診断にとって最も重要な信号処理の内容である。

ノイズの除去についてはこれまでに多くの方法が提案されているが、設備診断のときに測定した信号は必ずしもこれらの方法の前提条件を満足するとは限らない。したがって、本研究では情報工学理論や信号処理方法などを用いて、回転機械の故障診断に適したノイズ除去法について研究した。本論文では、特に一般的に困難とされている低速軸受診断について、計測された AE 信号と振動信号から強いノイズを除去し、微小な異常信号を抽出する方法について検討し、ノイズの除去効果、すなわち AE 信号と振動信号による低速軸受診断の精度を比較評価した。

2、診断用特徴パラメータ抽出の研究

コンピュータにより異常検出および異常種類の識別を自動的に行う場合は、対象の信号の特徴を示す有限個のパラメータを計算する必要がある。設備状態を鋭敏に反映するパラメータを診断用の「特徴パラメータ」という。しかし、異常パターンが多く、異常のメカニズム解明が困難な場合、上記のような特徴パラメータの選定は、多くの時間と労力を要するだけでなく、最適な特徴パラメータが見つかることも限らない。

これらの問題点を解決するために、本研究では情報工学理論や統計理論を用いて、回転機械診断用の特徴パラメータを効率よく抽出する方法について研究し、実際の設備診断へ応用した。

3、知的診断法の研究

計測した信号からノイズを除去し、特徴パラメータを算出した後、正常か、または異常種類の識別を行うが、その内容と目的は次のようにまとめられる。

(1) 設備の状態を定量的に、かつタイムリーに把握する。

(2) 異常の有無を識別し、異常の場合は、その原因や部位を特定し、異常種類の識別は特徴パラメータの値の評価によって行われる。

しかし、現場では、測定条件、運転条件、測定者の技能および異常の程度等々の要因により、測定信号や特徴パラメータから得られた診断情報がいまいなケースが多いから、異常の症状と原因との関係が不明確になり、できるだけ明確な診断結論を得るために複雑な診断アルゴリズムが必要である。これまでに多くの診断アルゴリズムが提案されているが、現場の客観的な実データに基づいた自動的な確率診断アルゴリズムが少なく、高精度な診断結果を得るための確率的な診断方法には多くの課題が残されている。

従って、本研究では、ノイズが除去された振動信号から特徴パラメータを求め、特徴パラメータと各状態を節としたベイジアンネットワーク (bayonet) により設備状態を確率的かつ自動的に診断する方法を提案した。また、回転機械設備を診断する場合、単一な位置・方向で測定した振動信号を使って多種類の異常を検出・識別することは困難な場合が多いから、複数位置・方向

で測定した振動信号（以下、「多チャンネル信号」とよぶ）から算出した有次元特徴パラメータを用いてベイジアンネットワーク (BN) により簡易診断を行い、異常の有無（状態の変化の有無）を判定する。簡易診断で異常が検出された後、多チャンネル信号から算出した無次元特徴パラメータを用いてベイジアンネットワーク (BN) により異常種類を判定するという逐次型ベイジアンネットワーク (SBN) および多チャンネル信号融合による設備診断法を提案し、提案した方法を回転機械の構造系異常（ミスアライメント、緩み、アンバランス）の自動的監視・診断に応用し、その有効性が確認した。

目次

第一章 序論

1.1 設備診断技術の重要性	2
1.2 設備管理の歴史と現況	5
1.3 設備保全の方式	7
1.3.1 事後保全.....	7
1.3.2 予防保全.....	8
1.4 設備診断技術とは	9
1.5 設備診断システムの基本構成	11
1.5.1 振動信号測定.....	14
1.5.2 信号処理.....	16
1.5.3 特徴解析.....	18
1.5.4 簡易診断.....	21
1.5.5 精密診断.....	25
1.6 本研究の目的と本論文の内容	28

第二章 低速回転機械診断における AE 信号と加速度信号の解析と感 度評価

2.1 はじめに.....	33
2.2 衝撃系異常診断.....	34
2.3 衝撃系異常診断の装置.....	36
2.3.1 実験装置.....	36
2.3.2 軸受仕様.....	36
2.3.3 その他の実験仕様.....	38
2.4 特徴パラメータを用いた簡易診断.....	39
2.4.1 使用した特徴パラメータ.....	39
2.4.2 診断精度の判断方法 (DI 法)	40

2.4.3	診断感度の評価結果	41
2.5	周波数分析による診断感度の評価法	42
2.5.1	包絡線診断方法	42
2.5.2	ノイズ除去	43
2.5.3	診断感度の評価結果	45
2.5.3.1	加速度信号①の診断結果	46
2.5.3.2	加速度信号2の診断結果	48
2.5.3.3	AE信号の診断結果	50
2.6	まとめ	50

第三章 特徴パラメータとベイジアンネットワークによる回転機械 設備診断

3.1	はじめ	54
3.2	特徴パラメータ	56
3.2.1	診断用の特徴パラメータ	56
3.2.2	特徴パラメータの識別指標	57
3.3	ベイジアンネットワークと学習技術	58
3.3.1	ベイジアンネットワーク	58
3.3.2	確率推論	59
3.3.3	ベイジアンネットワークの学習	59
3.4	診断及び応用	61
3.4.1	異常診断設備	61
3.4.2	異常診断の識別感度	63
3.4.3	ベイジアンネットワーク診断システムの構築と検証	63
3.5	まとめ	66

第四章 逐次型ベイジアンネットワークと信号融合による設備診断法	
4.1 はじめに	70
4.2 特徴パラメータ	72
4.3 ベイジアンネットワークによる自動診断法	74
4.3.1 ベイジアンネットワークとは	74
4.3.2 確率推論アルゴリズム ^[8]	74
4.3.3 ベイジアンネットワークにより自動診断法	77
4.4 構造系異常診断への応用	77
4.4.1 診断ための実験設備と状態設定	77
4.4.2 多チャンネル信号融合と逐次型ベイジアンネットワークによる 状態診断	80
4.4.3 逐次型ベイジアンネットワークと多チャンネル信号融合による 診断結果	81
4.4.4 他の方法による診断結果との比較	83
4.4.4.1 単一チャンネル信号と逐次型ベイジアンネットワークの場合	83
4.4.4.2 一括診断用ベイジアンネットワークモデルの場合	84
4.5 まとめ	86
第五章 結言	91

第一章

序論

1.1 設備診断技術の重要性

設備診断技術の重要性は、「安全・安心」、「企業競争力」、「地球環境」、「省エネルギー」というキーワードで表せる。

(1) 社会安全・安心の為に重要な設備の重大事故を未然に防止すること

設備とは、工業、農業、商業、建築業および社会インフラストラクチャなどに備え付けられた機器や施設の事を指し、陸海空の全ての業界や分野に設備がある。重要な設備のトラブルや事故を未然に防ぐ設備診断技術は安全・安心で持続可能な経済発展に大きく貢献するものである。

しかし、近年橋梁崩壊、飛行機事故、機械設備診断事故、工場火災、爆発など、重要設備事故が頻発しており、多大な人的、経済的な損失をもたらし、時には地球環境にも大きな悪影響を与えてしまう。

(2) 地球環境時代における設備診断技術の役割が大きい

20世紀の大量生産・大量消費の時代においては、設備の取替や更新が比較的頻繁に行われ、また設備の構造や機能が現在に比べ比較的簡単で、人員による設備診断・保全も比較的容易に行えたため、設備診断技術の重要性は顕著に注目されていなかった。一方、21世紀の地球環境時代においては、省エネルギー、省資源のために、設備の延命化(なるべく長く使用する)、リサイクル及びリユーズが提唱されているが、安全・安心を確保したうえでの設

備の延命化、リサイクルリユーズは言うまでもない重要なことである。

すなわち、設備の延命化を実施した場合は、設備の故障率が上昇しやすいので、設備診断技術により状態監視・診断を行い、効率良い計画保全で安全を確保する必要がある。

(3) 生産効率向上及び生産コストの削減により企業競争能力の向上

現在の製造業では、益々激しい経済競争の中で極限までコスト削減をして生産活動を行っており、一度重要な設備の稼働が突然な故障でストップすると、生産に大きな損失をもたらすだけでなく、修復にも莫大な費用と貴重な時間が必要であり、企業の利益・信頼・存続に直結する問題に発展しかねない。企業の業績が生産高と利益で決まり、特に利益率は企業の競争力を測るための最重要な指標である。利益率は生産コストの削減により大きく向上することができる。

設備診断技術は生産コストの削減及び生産損失の防止に大きく貢献できる。その理由は大まかに言えば、突然なトラブルや事故の防止、無駄なメンテナンス費用の削減、生産効率の向上によって利益率（競争力）の向上を実現させることにある。

(4) 設備を最適な状態を保ち、無駄な電力等の消費を防ぎ、設備の使用寿命を延ばす。

回転機械設備に異常が発生したときに、無駄な電力などの消費が増加する。例えば、回転軸のミスアライメントが発生した時に、1.3mmのミスアライメントで8.4%の無駄なエネルギーの増加となる。また、無駄なエネルギーの増加だけでなく、回転軸上の部品の寿命にも重大な悪影響を与える。例えば、回転軸のミスアライメントが発生すると、軸受とメカニカルシールの寿命は大幅に短縮してしまう。もちろん、軸自身や歯車などの使用寿命も大幅に短縮し、回転機械の突然破壊の確率もかなり高くなる。よって、設備診断技術で回転のミスアライメントを早期に検出し、早期に対策を取る必要がある。

設備診断による省エネルギーのもう一例はポンプである。世界の電気エネルギーの約20%はポンプが消費し、産業界ではエネルギー消費の約50%がポンプである。図1-1示すようにポンプの一生に必要な費用は電力費:95%、メンテナンス費:4%、ポンプの購入・設備費:1%である。

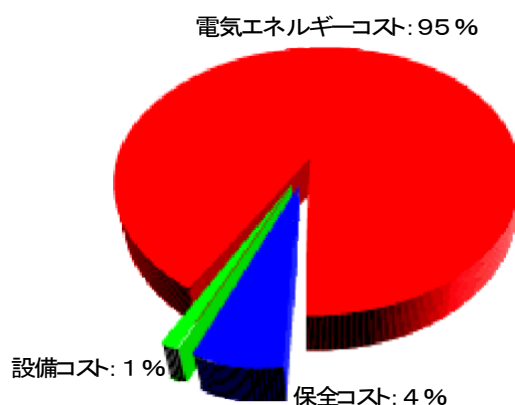


図 1-1 ポンプ一生に必要なコスト

表 1-1 に示す例のように、異常のあるポンプに対して、設備診断を適用し、保全（修復・整備）を行った結果、最大 19%の効率向上の効果が得られた。表 1-1 の割合で単純に計算すると、約 20%の電気エネルギーの節約となり、ポンプの購入・設備費の 20 倍に相当する費用の削減となる。よって、診断・保全の省エネルギーの効果が大きいことがわかる。

表 1-1 ポンプの診断・保全による省エネルギー効果

ポンプの例(No.)	診断・保全前 (効率、%)	診断・保全後 (効率、%)	診断・保全の効果 (効率向上分、%)
1	69	86	19
2	74	84	12
3	77	84	9
4	73	87	15

1.2 設備管理の歴史と現況

日本の設備管理の歴史を概観してみる。図 1-2 に示すように、1950 年代の始めに予防保全（Preventive Maintenance：以下、PM）が導入されたが、60 年代後半から 70 年代初期に、その欠点を是正する目的で、現在の主要な保全方式となっている「全員参加の生産保全（total Productive Maintenance：TPM）」「予知保全方式（Predictive Maintenance/Condition Based Maintenance：CBM）」及び「信頼性保全（Reliability Centered Maintenance：RCM）」が開発もしくは導入された。

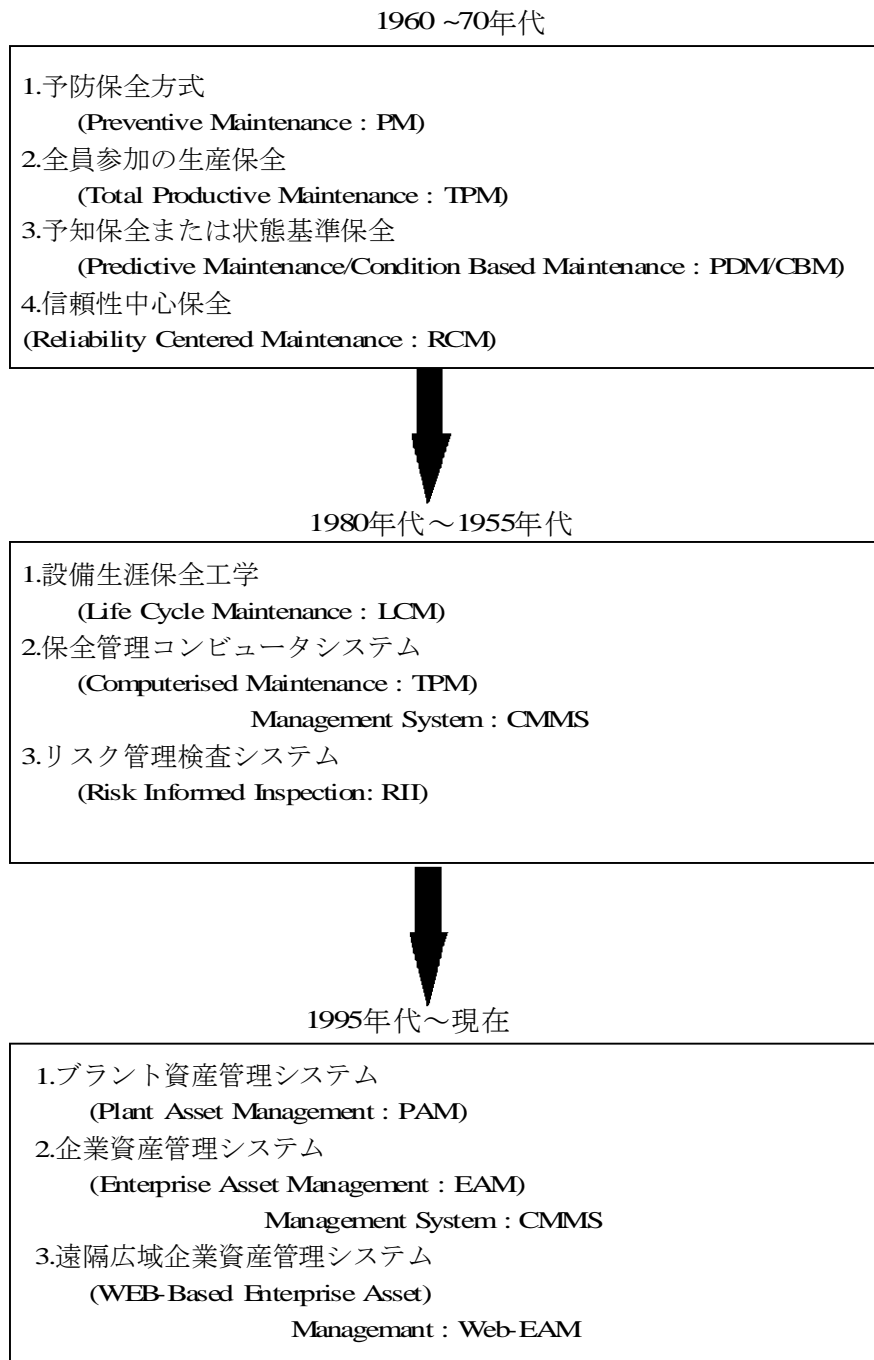


図 1-2 日本における設備管理関連技術の歴史

80年代から90年代の前半にかけて、設備の生涯コストを最適化する「ライフサイクル保全(Life Cycle Maintenance : LCM)」「設備保全コンピュー

タシステム(Computerized Maintenance Management System : CMMS)」が導入され、次いで「リスク管理点検技術(Risk Informed Inspection : RII)」が導入された。

IT 時代を迎えた 90 年代後半は、従来の CMMS が「企業資産管理システム(Enterprise Asset Management : EAM)」へ、CBM が「プラント資産管理システム(Plant Asset Management : PAM)」へと進化して、現在にいたっている。

1.3 設備保全の方式

設備保全は、組織の目的に照らしても最も適した方式である必要があり、経済性の判断に基づき設備の生産性を最大限に高める保全が必要である。設備保全は図 1-3 に示すような方式がある。

1.3.1 事後保全

事後保全とは壊れたら直すという保全方式であり、生産設備の休止損害が無視できる場合などに、故障してから修理を行う保全方式である。修理作業の発生は突発的で事前に計画を立て難しく、要員・材料・機材手配などが効率面で不利になりがちであるが、生産性の見地から総合的にみて、事後保全が有利であると判断される場合に採用する。

(1) 緊急事後保全 (EBM) : 予防保全対象の設備が突発的な故障で停止したときに、直ちに修理を行う。

(2) 計画事後保全 (PBM) : 仮に故障しても代替により作業の振替が効く場合やあえて故障してから修理した方が保全コストが経済的である場合、故障してから修理を行う保全である。

(3) 非計画事後保全 (UBM) : 予防の概念や経済性の追求もなく、なり行き任せの事後修理をいう。

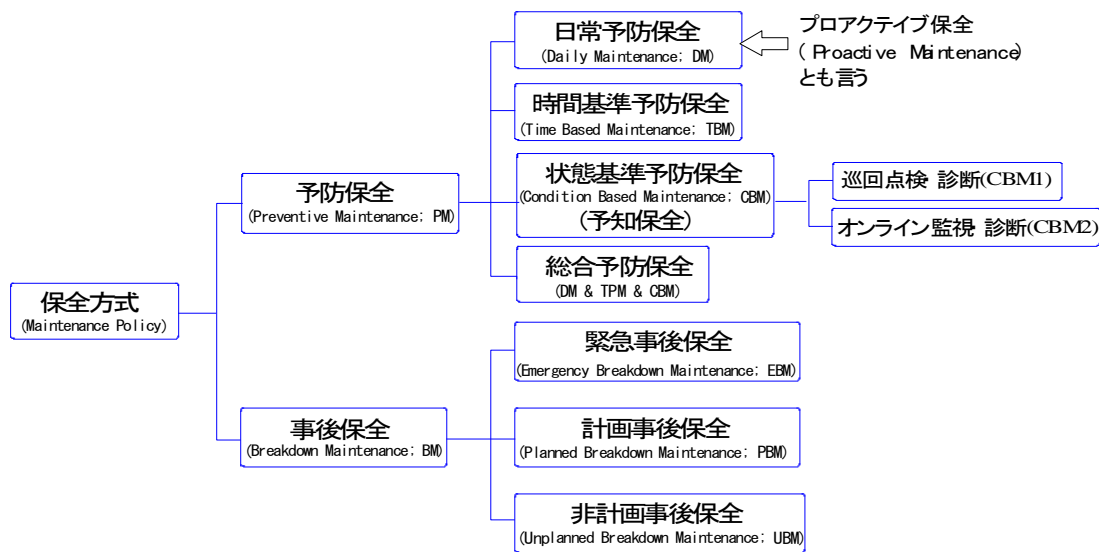


図 1-3 設備保全方式

1.3.2 予防保全

予防保全とは設備が故障する前に、あるいは設備を故障させないために予防措置をとる保全方式であり、次のような方式がある。

(1) 日常保全 (DM) : 清掃、給油、芯出しなどにより劣化や故障を防ぐ日常的な装置管理活動。なお、日常保全はポロアクティブ保全 (Proactive Maintenance) ともいわれている。

(2) 時間基準保全 (TBM) : 時間単位で従来の経験あるいは法律規制によって周期を決めて定期的に分解・点検・設備して不良を取替えるオーバーホール型保全。

(3) 状態基準保全 (CBM) : 設備の劣化状況や性能を診断し、その診断状況をもとに保全活動を展開する方法。

(4) 総合予防保全 : 日常保全、時間基準保全、状態基準保全を最適に組み合わせる保全。

1.4 設備診断技術とは

装置や機械類の異常や故障が生産及び品質に与える影響も従来と比較できないほど大きくなり、従来単独の技術分野として発達を遂げてきた品質管理や生産管理も、設備保全を無視して遂行不可能となりつつある。

このように重要性を増やした装置や機械類を効率よく維持管理するために必要なことは、何をおいてもその対象となる設備の状態を定量的に把握することである。つまり、設備の故障の原因を明らかにし、最小のコストと時間で修復し2度起こさないように対策を取るために、設備に印加され、その

故障の原因となる諸ストレス、設備の病気である劣化や故障、設備のアウトプットである性能及び機能の状態、を正確に把握しなければならない。

設備診断技術とは、以上のような目的をもって開発された設備保全のための新しくかつ強力な技術で、次のように定義される。設備診断技術とは、設備の状態すなわち、

- (1) 設備劣化の原因である諸ストレス
- (2) 劣化の程度や故障の種類
- (3) 性能や機能

を定量的に把握し、正しい保全アクションを決定するための技術とえる。

したがって、設備診断技術は単なる故障検出技術とか点検の計器化技術と解釈しなくてはいけない。設備診断技術は一般に次の4つの要素技術から構成されている。

- (1) 諸パラメータを推測するための検出技術
- (2) 雑音を除去する信号処理技術
- (3) 異常の種類や過酷度を決める識別技術
- (4) 設備状態の将来を予測する予測技術

図 1-4 はこの関係を示したものである。

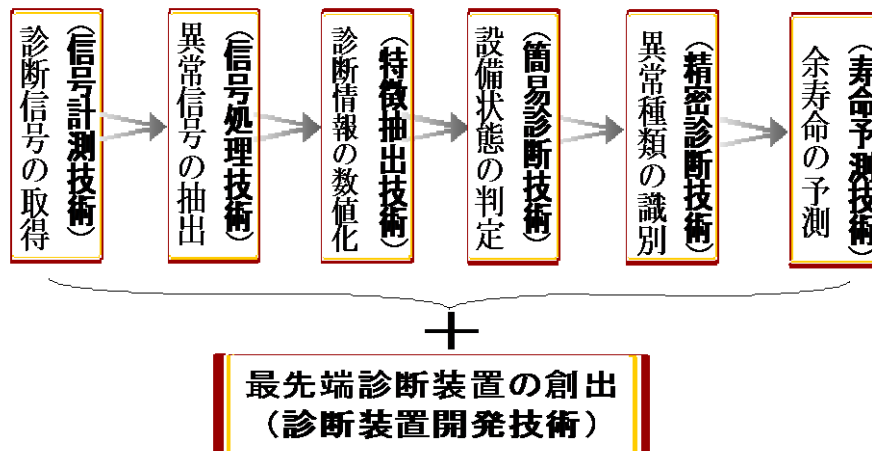


図 1-4 設備診断に必要な技術

1.5 設備診断システムの基本構成

回転機械設備の状態診断は図 1-5 に示しているように、人間の病気診断とよく似ている。

設備診断技術は大きく分ければ、計測、簡易診断技術、精密診断技術から構成される。簡易診断の役割は病気診断の定期健康診断に相当し、精密診断の役割は、簡易診断で異常が発見された後異常種類を同定することである。これらは医学における看護師と医師の関係に相当する。つまり、病気を早期に発見して治療し、さらに少ない保険費用で健康を維持するためのシステムは、人の場合も設備の場合もいわば同様である。

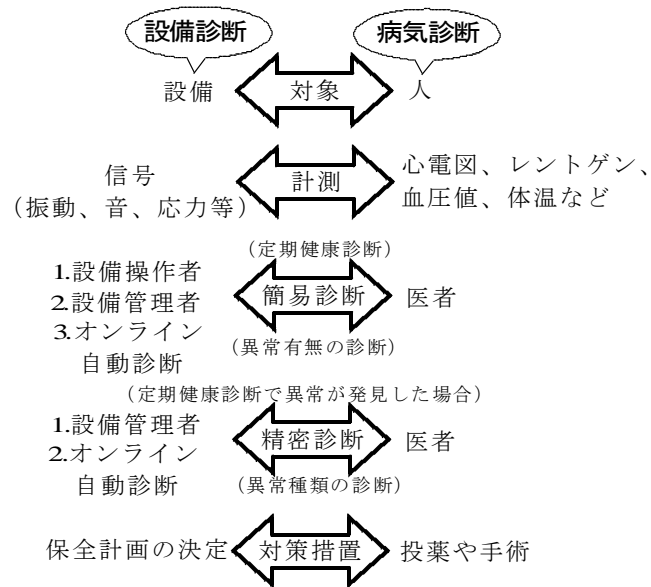


図 1-5 設備診断と病気診断

設備診断は主に以下のような方式がある。

- (1) 人間五感による診断（人間の感覚＋人間の判断）

検出：人間の感覚（触る、聞く、見る、嗅ぐ、味わう）

診断：人間の判断

- (2) 装置による補助診断（装置の感覚・計算能力＋人間の判断）

検出：センサ（振動、音響、応力等）

診断：人間が解析装置（振動計や FFT アナライザなど）を用いて判定・

識別主に振動値やスペクトルを見て判定・識別する

- (3) 準知的診断装置システムによる補助診断（装置の感覚・計算能力＋コ

ンピュータ＋人間の判断）

検出：センサ（振動、音響、応力など）

診断：人間がある程度知能化された準知的診断装置システム（ハードウェア+ソフトウェア）を用いて判定・識別準知的診断装置システムの診断結果を参考にして判定・識別する

(4) 知的診断装置システムによる自動診断（装置の感覚・計算能力+コンピュータ知能）

検出：センサ（振動、音響、応力など）

診断：人間のかわりに知的診断装置システム（ハードウェア+ソフトウェア）が自動的に用いて判定・識別する




図 1-6 設備診断処理の流れ

よって、回転機械設備の状態診断には図 1-4 に示すような技術が必要であり、これらの技術に対応する診断処理は図 1-6 に示す。ここで各処理について簡単に説明する。

1.5.1 振動信号測定

ここで、振動加速度センサの測定ポイントと測定方向を決定するとき、主に注意すべきことを紹介する。

(1) できるだけ診断対象の部品に近い所に測定ポイントを決める。たとえば、図 1-7 に示す設備の場合、①と②の箇所でポンプ診断、②と③の箇所で減速機械診断、③と④の箇所で継ぎて診断、④と⑤の箇所でモータ診断のために振動を測定する。

(2) できるだけ 3 の方向（水平方向、垂直方向、軸方向）の振動を測定する。精密診断異常状態の識別のためにた方向の測定情報が必要な場合もある。




図 1-7 振動加速度の測定ポイントの例

(3) 測定は常に同じ点で行うべきである。図 1-8 (a) に示すように、常に同じポイントで測定するために、測定ポイントにマークをつける必要がある。同じポイントで測定する必要性は図 1-8 (b) に示すように、測定ポイント

トがずれると、同じ機械が状態であっても振動値が大きく違う可能性があるから、誤診断を招くかもしれない。




図 1-8 測定ポイントのマークと感度

(4) 押し当て式の加速度センサについては先端の接触状態と傾きに注意する。図 1-9 に示すように接触面の凸凹や窪みなどによるセンサ先端との接触が良くなければ、接触共振周波数がかわり、測定データの精度も悪くなる。また、測定時にセンサの傾きは 10° 以内にすべきである。




図 1-9 押し当て式センサの注意

(5) 固定型の加速度センサと被測面との接触に注意する。固定型の加速度センサはマグネット式、接着式及びネジ式があり、いずれも図 1-10 のように被側面との接触に注意する必要がある。




図 1-10 固定型の加速度センサーの注意

1.5.2 信号処理

設備診断時の信号処理の主な内容は異常検出の感度と精度を高めるために、測定した信号からノイズを除去することである。設備診断の場合、異常が発生した時に生じた異常振動の信号（異常信号と呼ぶ）は診断にとって有用な信号であり、他の信号成分はノイズと見なす。この意味で設備の正常状態時の振動信号（正常信号と呼ぶ）も設備診断にとってはノイズである。

例えば、図 1-11 の例に示すように、ノイズを除去するためによく用いられるローパスフィルタはローパスフィルタ、ハイパスフィルタおよびバンドパスフィルタがある。

回転機械を診断する場合、異常信号を抽出するための最適なカットオフ周波数（周波数帯域）は異常種類ごとに違い、また同じ異常種類でも設備ごとに若干違う。回転機械の主な異常種類とその周波数帯域は大きく分類（大まかな分類）できる。

- （１）構造系異常（あるいは、低周波数帯域の異常）：アンバランス、軸ミスアライメント、ゆるみ、軸曲がり、滑り軸受の一部異常、軸受や歯車の末期異常などあり、低周波数帯域（ $<1\text{kHz}$ ）の特徴信号が現れる。
- （２）自励系異常（あるいは、中周波数帯域の異常）：一部の歯車異常（すこーリング、ミスアライメントなど）、滑り軸受の一部異常、一部の流体的な異常、共振などであり、中周波数帯域（ $<5\text{kHz}$ ）の特徴信号が現れる。
- （３）衝撃系異常（あるいは、高周波数帯域の異常）：軸受傷、歯車局所異常、回転部の局所接触、緩みに伴う衝撃などであり、高周波数領域（ $>5\text{kHz}$ ）の特徴信号が現れる。

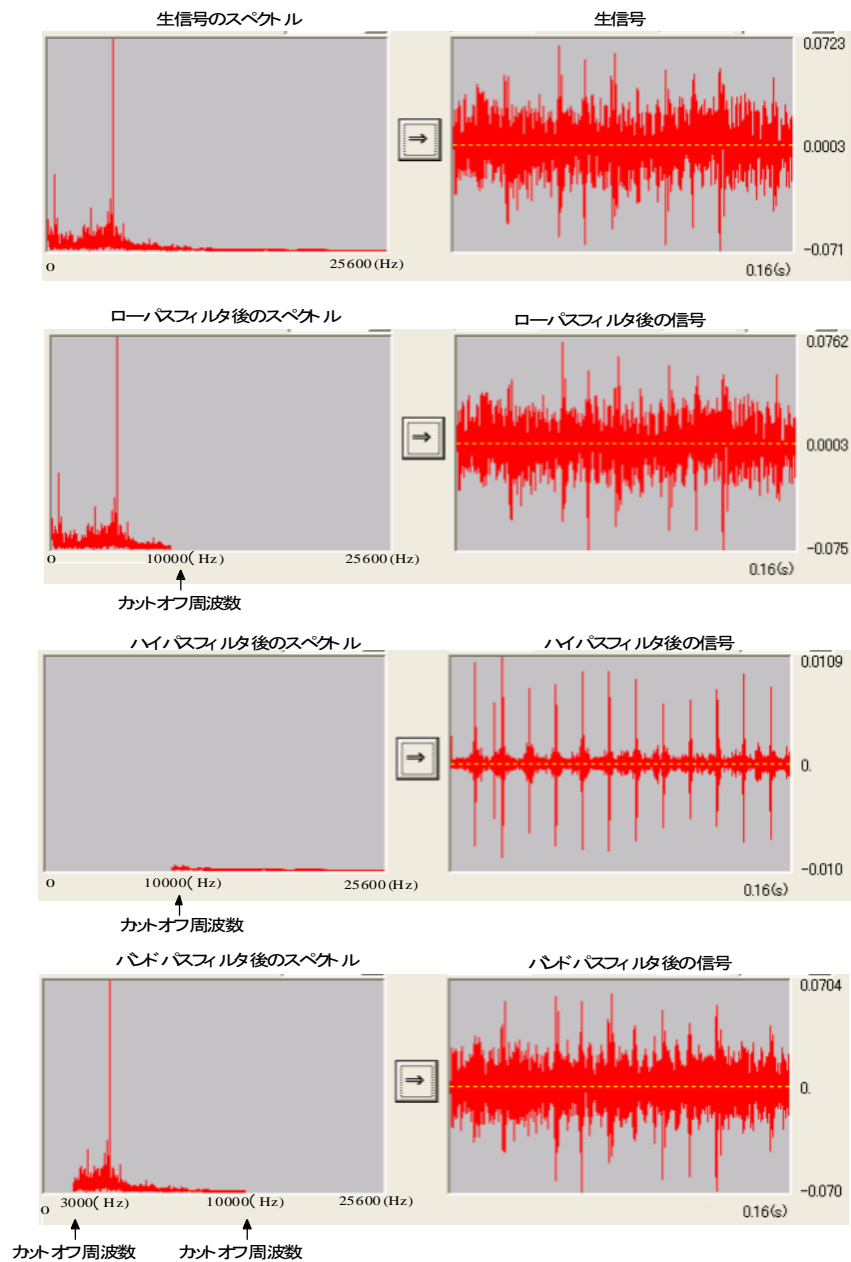


図 1-11 ロー・ハイ・バンドパスフィルタ

1.5.3 特徴解析

回転機械の振動診断の場合、振動を計測し、振動信号の特徴から設備の状態を推定している。振動信号の特徴を表し設備状態も鋭敏に反映する、振動

信号から算出されたパラメータを診断用の「特徴パラメータ」という。設備診断用の特徴パラメータは「有次元特徴パラメータ」と「無次元特徴パラメータ」にわけることができる。

特徴パラメータは、時系列信号から求めた時間領域の特徴パラメータ、およびスペクトルから求めた周波数領域の特徴パラメータなどがある。どのような特徴パラメータを用いるは診断の内容や異常の種類などによって異なる。

現在市販の回転機械診断用の装置には殆ど有次元特徴パラメータが使用されている。有・無次元特徴パラメータを総合した回転機械診断法が有効と考えられる。

数個の無次元特徴パラメータを総合して、状態を判別することもできる。例えば、主成分分析法や正準判別法などが設備診断に適用されている。

1.5.3.1 有次元特徴パラメータとは

有次元特徴パラメータは、信号の平均値、実効値、ピーク値などどのように単位（速度、加速度など）を持ち、信号の振動幅の大きさを表す。

有次元特徴パラメータは次のような性質を持ち。

(1) 設備の大きさによって正常状態でも振動レベルが違うので、判定基準も違う。

(2) 値は、同じ設備で正常状態であっても、回転数や負荷数が変動すると変化する。

(3) 早期異常の時、その値が顕著に変化しないから、異常の早期検出に適さない。

(4) 値は、殆どの設備においては異常時に大きくなるが、中には異常時に逆に小さくなる設備や部品もある

(5) 異常種類の識別（精密診断）に用いられない。

1.5.3.2 無次元特徴パラメータとは

無次元特徴パラメータは、従来の統計学で使われている歪度、尖度などのような特徴パラメータで、単位を持たなく、信号の大きさに関係なく、信号の特徴を反映する。

無次元特徴パラメータは次のような特徴を持つ。

(1) 振動波形の形状さえ相似すれば、値は設備の大小に関係なく、ほぼ一定である。

(2) 値は回転数の変化に影響されにくい。

(3) 異常種類によって敏感と鈍感なものがある。

(4) 値の大小は異常種類によって違う。

(5) 一般に危険レベル（設備を停止すべきレベル）の設定が困難である。

無次元特徴パラメータの意味を理解するために、例えば、尖度、歪度、波高率については異常状態の振動波形の形に反応して値が変化する。正常状態時に比べ、尖度、歪度、波高率の値が変化したときに、どのような異常状態が起きている可能性があるかを表 1-2 にしめしている。

表 1-2 各無次元特徴パラメータ値と異常種類との関係

		歪度	尖度	波高率
正常状態に比べて	小さい	稀	アンバランス 緩み 軸曲がり	稀
	大きい	歯車摩耗 緩み 非線形振動	軸受傷 歯車局所異常 衝撃的な振動	軸受傷 歯車局所異常 衝撃的な振動


1.5.4 簡易診断

簡易診断の役割は、設備状態を特徴パラメータにより定量的に評価し、異常の有無（状態変化の有無）及び異常の程度（注意・危険状態）を判別すると共に、設備状態の傾向を管理することである。簡易診断の精度が良ければ、殆どの重大事項を未然に防ぐことができる。

簡易診断の検査対象として、例えば、振動値（加速度、速度、変位）または音、温度などが挙げられる。判定基準として注意値、危険値などの閾値を

設定し設備状態をひょうかする。例えば、表 1-3 は振動値の判定基準の例を示す。

表 1-3 振動値の傾向管理の例



一般に簡易診断用の有次元特徴パラメータは設備の状態変化だけでなく、負荷の変動によっても変化する。そのために簡易診断の場合、判定基準の決定は重要である。統計検定理論や可能性理論などによる判定基準の決定法が提案されている。

有次元特徴パラメータは波形の大きさを表すから、一般に現場では、振動の強さの指標として回転機械状態（正常、注意、危険）の判定に用いられる。運転条件（負荷と回転速度）が一定な回転機械の有次元特徴パラメータの判定基準は国際規格（ISO）や各国によって与えられたものがある。例えば、
図 1-12 絶対判定基準をしめしている。

このような判定基準は、与えられた有次元特徴パラメータの値をそのまま

状態判定に用いられるから、「絶対判定基準」という。

絶対判定基準は多くの現場実験や経験によりまとめた平均的な基準であり、一般に状態判定の目安として使用されているが、全ての現場設備に完璧に適用するとはかぎらない。

区分境界の値	クラスⅠ	クラスⅡ	クラスⅢ	クラスⅣ
45.0				
28.0				D
18.0			D	C
11.2		D	C	
7.1	D	C	B	B
4.5	C	B	A	A
2.8				
1.8	B	A	A	A
1.12				
0.71	A	A	A	A
0.45				
0.28				

注: 境界値間の比率は 2.5 倍 (8dB) であり、クラスⅡとⅢの境界値間の比率は 6.5 倍 (16dB) である。

- A は良好（優）、正常状態で何もする必要がない
- B は順調（良）、やや正常状態、補修の必要がなし、注意の必要
- C は不調（可）、用注意状態、保全費用の節約のため近い日時に修理が必要
- D は危険（不可）、危険な状態で直ちに修復が必要

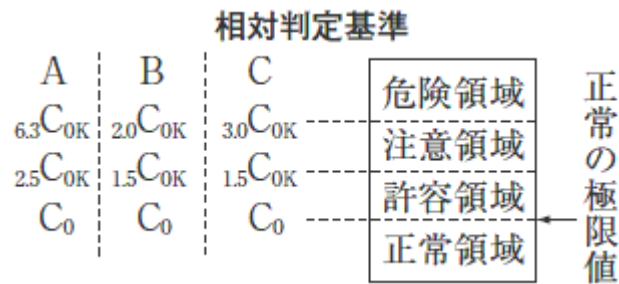
図 1-12 絶対判定基準の例

しかし、図 1-12 の絶対判定基準を分析すれば、機械の種類の違いによって絶対判定基準の値が違いますが、各状態範囲の境界値の比率は一定（約 2.5）であることが分かる。この性質を利用して、図 1-13 のように、全ての回転機械設備に適用できる。「相対判定基準」を定義する。

低周波領域（1kHz 以下）における振動速度の実効値にかんしては、基準状態（正常状態）の限界値を C_0 とすれば、注意状態と危険状態の限界値はそれぞれ $2.5C_0K$ と $6.3C_0K$ とすればよい。ここで、 K は調整係数で、デフォルトとして 1 とするが、設備の種類や重要度によって変更すればよい。

C_0 は統計理論により正常状態の 99.9%信頼領域として次のように求める。

$$C_0 = \bar{P}_i + 3S_i \quad (1-1)$$



A：低周波数領域（<1kHz）の速度信号の RMS (mm/s)

B：中周波数領域（<5kHz）の速度信号の RMS (G)

C：高周波数領域（>5kHz）の速度信号の RMS (G)

図 1-13 絶対判定基準と相対判定基準

ここで、 \bar{P}_i と S_i はそれぞれ特徴パラメータ P_i の平均値と標準偏差である。

なお、実際に現場で測定した振動の実効値などの特徴パラメータは必ずしも正規分布に従うとは限らないので、上記の \bar{P}_i と S_i を求めるときには注意を払う必要がある。

他の周波数領域における相対判定基準も絶対判定基準の参照により作成

できる。例えば、中周波数領域（＜5kHz）においては、相対判定基準の例として図 1-13 の B に示す。この領域では振動加速度の実効値を用いて、「自励系」異常状態の簡易診断を行う。また、高周波数領域（5kHz）の相対判定基準の例は、図 1-13 の C に示す。この領域はお主に「局所衝撃系」異常状態の簡易診断に適している。

1.5.5 精密診断

簡易診断で異常が検出された後、異常種類を特定し、余寿命を予測するために、精密診断を行う必要がある。精密診断の手法を大きく分ければ 2 つある。すなわち、設備管理者がスペクトルや特徴パラメータを用いて診断する手動法、及びニューラルネットワークや遺伝的アルゴリズムなどを用いた自動法がある。

手動法による精密診断は振動信号を低・中・高周波帯域にわけて測定する。各周波数帯域のサンプリング周波数（SF）は設備種類や回転数によって違いますが、サンプリング周波数でよいと考えられる。また、計算機でデータ処理を行う場合、高周波数帯域の波形のみ測定した後、間引きを行うことにより低・中・高周波帯域の振動波形を得ることもできる。一般に低・中周波帯域においては、振動信号のスペクトルを用いて、特徴周波数成分（回転周波数成分、共振周波数成分など）を確認して精密診断を行う。高周波数帯域にお

いては、主に振動波形の包絡線のスペクトルを用いて軸受傷や歯車局所異常の診断を行う。

人工知能的な手法を用いた知的診断（自動診断）とは、自動フィルタや各種信号処理の手法に加えて、アルゴリズム、ベイジアンネットワーク、ニューラルネットワーク、サポートベクトルマシン、可能性理論などを用いて設備状態の自動判別を行うことである。

① 構造系異常 (<1kHz)

構造系異常とは、異常が発生した時に低周波帯域 (<1kHz、あるいは、<20 f_r 、 f_r ：回転周波数) に異常振動のスペクトルが現れる異常種類のことである。歯車の一部が破損したとか、回転軸が回転体の中心からずれて取り付けられている場合のように、軸中心まわりの質量分布に不均衡があると、回転軸が周期の振動を発生する。このような状態をアンバランスと言う。

また、低速機械のように軸継手で結ばれた2台の回転機械において、結合された2本の回転軸の中心線がずれた状態で軸を回転させると、アンバランスと同様に回転数と同じ周期の振動を発生する。この軸ずれの状態をミスアライメントと言う。




図 1-14 構造系異常の診断時に注目すべき周波数成分

回転軸系の共通主な異常種類はアンバランス、緩み、ミスアライメント、軸曲がり、の部品共振などである。スペクトルによる診断の時には注目すべき周波数成分は図 1-14 に示すように、以下の周波数成分である。

回転周波数： f_r （アンバランス、緩み、ミスアライメント、軸曲がり、亀裂）

回転周波数の 2 倍： $2f_r$ （アンバランス、緩み、ミスアライメント、軸曲がり、亀裂）

回転周波数の i 倍： if_r （緩み、ミスアライメント、軸曲がり、亀裂）

軸系の共振周波数： f_{s0} （緩み、軸共振、接触）

軸系以外の共振周波数： f_{u0} （軸系以外の共振、緩み、接触）

② 衝撃系異常 (>5kHz)

衝撃系異常とは、回転に伴って回転部分と部品の傷との衝撃、あるいは、回転部分と静止部分との接触により生じた異常振動状態のことである。

軸受異常、歯車異常、ベルト異常、リーク等のように手で触ったり、音で聴いたりして判別できない高周波数帯域の衝撃系異常に関しては入力信号を振動加速度の包絡線処理波形に変換して使用している。

例えば軸受の外輪、内輪に転動体が繰り返し接触し疲労により欠陥が発生すると微細な衝撃波を生じるようになる。歯車やベルトなどの局所異常に関しても同様に繰り返しの疲労により摩耗する現象と似ていることから衝撃系異常と呼ぶ。

このような衝撃系異常に関しては人間が感じる程度のレベルになるとかなり症状が進んでいることが多く早期の検知が肝要となってく。無次元特徴パラメータとして振幅確率密度関数を用いた判定手法も報告されている。

1.6 本研究の目的と本論文の内容

本研究の目的は 1.1～1.6 項までの内容に沿って、回転機械設備診断の領域に残されている諸問題のうち、特に低速回転軸受診断法および確率的な自動診断法に関して検討し、新たな諸提案を行い、その有効性を検証することである。本論文はこれらの成果をまとめたものであり、主な内容は以下の通りである。

第二章では、一般的に異常診断が難しいとされている低速回転軸受について、AE信号と加速度信号による診断の感度を評価するために、特徴パラメータ解析法および周波数領域解析法による感度評価法を提案し、実機に近い低速回転機械実験装置を用いて、AE信号と加速度信号による低速軸受診断時の特徴、およびそれぞれのセンサーによる低速軸受診断の限界速度を示す。

第三章では、特徴パラメータとベイジアンネットワーク(BN)をもちいて、回転機械の自動診断方を提案する。まず、振動信号の特徴を反映する周波数領域の特徴パラメータを定義する。次に、DI値(識別指標)処理法で異常の識別にとって良好な特徴パラメータを選出する。最後に、選出した特徴パラメータをベイジアンネットワーク(BN)のモデルに代入し、軸受の異常を診断する。診断の結果により、提案した方法の有効性を検証する。

第四章では、設備異常を早期検出し、異常種類を判別するために、逐次型ベイジアンネットワーク(SBN)による設備診断法を提案し、回転機械の構造系異常へ適用した。また、診断対象の回転機械において単一な位置と方向で測定した振動信号および複数位置・方向で測定した振動信号により診断用の最適なSBNモデルについて検討し、時間領域・周波数領域の有次元特徴パラメータを用いて簡易診断(状態の変化有無の判定)を行い、異常が検出された後、無次元特徴パラメータを用いて異常種類を判定する自動診断法も提

案する。提案した方法を回転機械診断実験によりその有効性を検証する。

参考文献

- [1] 陳山 鵬：「回転装置の設備診断技術の基本と応用」、三恵社出版(2009)
- [2] 陳 鵬、豊田 利夫：有・無次元特徴パラメータの総合による設備診断法及び歯車異常診断への応用、評価・診断に関するシンポジウム講演論文集、社団法人日本機械学会、pp. 112-117、(2002)
- [3] 陳山 鵬、宮崎 修治、橋本 和也：低速軸受の最新診断法、評価・診断に関するシンポジウム講演論文集、社団法人日本機械学会、pp. 1-3、(2004)
- [4] 豊田 利夫：「設備診断のための信号処理の進め方」、日本プラントメンテナンス協会、pp. 177、(1996)
- [5] Peng Chen、Toshio Toyota and Zhengjia He：Automated Function Generation of Symptom Parameters and Application to Fault Diagnosis of Machinery in Variable Operation-conditions、IEEE Transactions on System、Man、and Cybernetics (Part A)、Vol. 31、pp. 775-781、(2001)
- [6] Akito Tomita、PengChen and Toshio Toyota：Dynamic Analysis Method and Diagnosis Method for Misalignment State of Rotating Shaft、Proc.International Symposium on Machine Condition Monitoring and Diagnosis、pp. 151-155、(2002)
- [7] 村瀬 一哉、陳山鵬：回転軸ミスアライメント状態の動特性解明、日本機械学会第4回評会診断シンポジウム論文集、(2006)
- [8] 王 曉東、坂 倫嘉、陳山 鵬：回転軸のミスアライメント状態の動特性と診断法(1)－継手の種類による異常振動特徴の解明－、平成20年度日本設備管理学会創立20周年記念大会論文集、pp. 240-244、(2008)
- [9] 坂 倫嘉、王 曉東、陳山 鵬：回転軸のミスアライメント状態の動特性と診断法(2)－アングル・オフセット及び複合ミスアライメント状態の

- 特徴解明一、平成 20 年度日本設備管理学会創立 20 周年記念大会論文集、
pp. 240-244、(2008)
- [10] H. Q Wang and P. Chen. Fuzzy Diagnosis Method for Rotating Machinery
in Variable Rotating Speed、 *IEEE Sensors Journal*、 Vol. 11、 No. 1、
pp. 23-34、(2011)
- [11] 豊田 利夫：回転機械診断の勧め方、日本プラントメンテナンス協会、
pp. 9-40、(1999)
- [12] 豊田 利夫：予知保全 (CBM) の勧め方、日本プラントメンテナンス協会、
pp. 8-55、(1998)
- [13] 里永 憲昭、陳山 鵬：化学プラントにおける設備診断の現状と課題、
潤滑経済、11月号、pp. 28-35、(2007)
- [14] 陳 鵬、豊田 利夫：特徴周波数帯域の抽出及び可能性理論による設備
異常の逐次診断法、日本信頼性学会誌 Vol. 2、No 4 . pp. 31-34、(1998)
- [15] 豊田 利夫、陳 鵬、溝田 武人：スペクトルの統計的検定による故障
信号の抽出、精密工学会誌、Vo158、No6、pp. 1041-1046、(1992)
- [16] 金森 啓祐、陳山 鵬、里永 憲昭、三苫 哲郎：回転機械設備の状
態予測法について (1)、第 6 回評価診断に関するシンポジウム予稿
集 No210 (2007)

第二章
低速回転機械診断における
A E 信号と加速度信号の解析と感度評価

2.1 はじめに

低速（100rpm 以下）回転機械の異常診断では、診断のために計測した信号の S N 比（信号・雑音比）が中高速回転機械の異常診断時の信号に比べ低いので、異常検出が困難である。よって、これまでに生産現場において低速回転機械の保全・管理には様々な問題点が生じている。

振動値（実効値やピーク値）による点検・診断においては、中高速回転機械の場合、振動値が異常程度の増加に伴い大きくなり、設備状態の傾向管理が比較的行きやすい。一方、低速回転機械の場合は、振動値が早・中期異常時にほとんど変化せず、末期異常になると突然大きくなるから、設備の突然破壊がしばしば生じる。たとえば、軸受の場合、低速なので欠陥（傷や剥離）があっても、伝動体が欠陥を通過する時に生じる衝撃が小さいので、異常の検出や特徴判明が困難である。

A E（acoustic emission）信号は低速回転機械の異常診断によく用いられているが、A E のサンプリング周波数は数百 kHz～数 MHz で、膨大な量の生信号の処理に長時間と大容量のメモリが必要である。また、A E 信号はノイズの影響を受けやすいが、A E 信号から異常の特徴信号を抽出する有効な方法（フィルタリングのカットオフ周波数）が確立されていない。

振動加速度信号は A E 信号に比べ低速回転機械の診断感度が低いと言わ

れているが、その比較評価についての詳細な技術資料や文献が見当たらない。振動加速度信号はA E 信号よりサンプリング周波数が低く、処理にかかる時間も短いので、低速回転機械の診断に用いられるならば診断効率がよいと考えられる。

以上のように、低速回転機械の診断において振動加速度信号とA E 信号との短所を克服し、長所を活かすために、本研究では、低速回転機械を診断するときに、特に低速軸受異常の検出・診断について特徴パラメータ解析法および周波数領域解析法によりA E 信号と加速度信号の診断感度についての感度評価法を提案し、実機の診断例を用いて解析・比較結果およびA E 信号と加速度信号の異常検出限界の算出法との算出例を示す。

2.2 衝撃系異常診断

軸受異常は衝撃系異常と言われ、衝撃系異常とは回転に伴って回転部分と部品の傷との衝突、あるいは、回転部分と静止部分との接触により生じた異常振動状態のことである。

例えば、図 2-1⁽¹⁾に示すように軸受外輪に傷が生じた場合、ローラあるいは玉が傷を通過した時に、外輪を敲くような衝撃的な振動が発生する。本研究では衝撃によって生じた波形の特徴を数値化（特徴パラメータ）し識別指

標 D. I. (Discrimination Index) ⁽²⁾ を用いて異常の検出・診断が可能か否かについて検討した。

また、軸受傷による衝撃的な生信号のスペクトルでは衝撃波形のパス周波数 $f_0=1/t_0$ を検出できない。そこで包絡線処理および包絡線のスペクトル解析により、低速軸受に起きた異常の種類を精密に診断できるか否かを検証することにより診断感度の評価を行った。包絡線検波処理を施した上で周波数分析を行う方法は、衝撃により生じたパルス波の発生間隔の周波数（軸受傷のパス周波数）を分析するのに有効である。

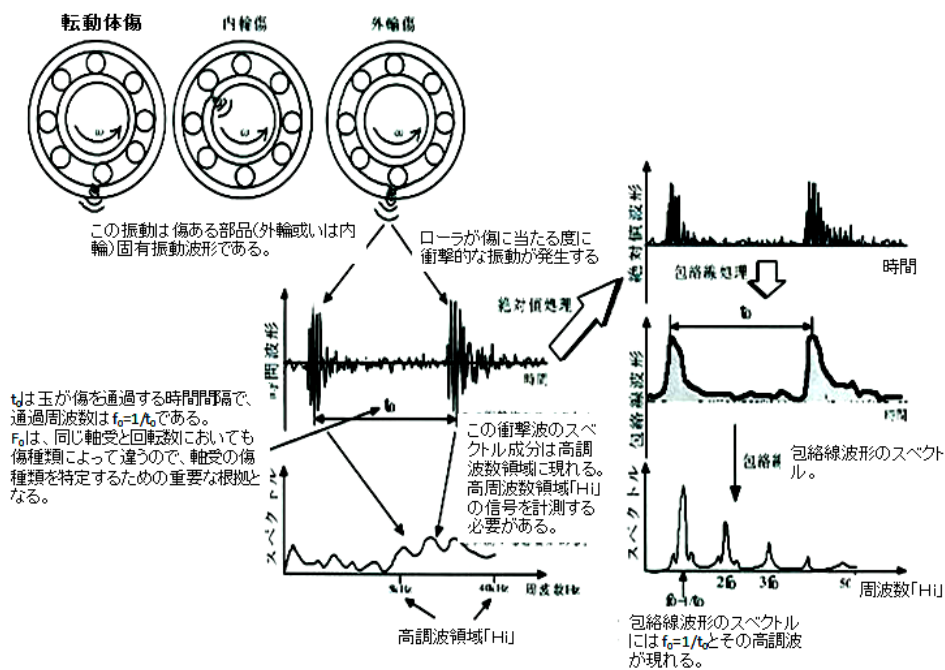


図 2-1 軸受外輪傷時の衝撃的な振動波形

2.3 衝撃系異常診断の装置

2.3.1 実験装置

本実験には三重大学設備診断実験室の低速回転実験装置を使用した。使用した実験装置は図 2-2、2-3 に示す。この装置の軸受を正常や外輪傷などの異常状態のものに代え振動の測定をした。図 2-3 は軸受固定部分と軸受傷を示す。図 2-4 は外輪傷を示す。

2.3.2 軸受仕様

本研究で使用したベアリングは、エヌティーエヌ (NTN) の 円筒ころ軸受 (N312ET2X NSN) である。軸受の詳細仕様は表 2-1 に記載する。また外輪傷の軸受の作成方法は正常の軸受にワイヤーカットでスポット傷を入れた。外輪傷 (大) には幅 5.0mm * 深さ 0.5mm の傷を、外輪傷 (小) には幅 1.2mm * 深さ 0.3mm の傷を人工的につけた。




図 2-2 低速回転機械実験装置



図2-3 軸受



図2-4 外輪傷

表2-1 軸受仕様

ピッチ円直径	105(mm)
外輪直径	115(mm)
内輪直径	60(mm)
転動体直径	17(mm)
接触角	0°
転動体数	13

2.3.3 その他の実験仕様

回転速度は 10、30、50、100rpm の 4 段階の速度を設定した。

信号の種類、サンプリング周波数、サンプリング時間などについては表 2-2 に示す。信号計測・処理の流れと信号の種類は図 2-5 に示す。

表 2-2 センサ種類とサンプリング周波数、時間

信号の種類	サンプリング周波数	サンプリング時間
加速度信号①	100kHz	20s
加速度信号②	100kHz	20s
AE 信号（包絡線）	100kHz (2kHz)	20s

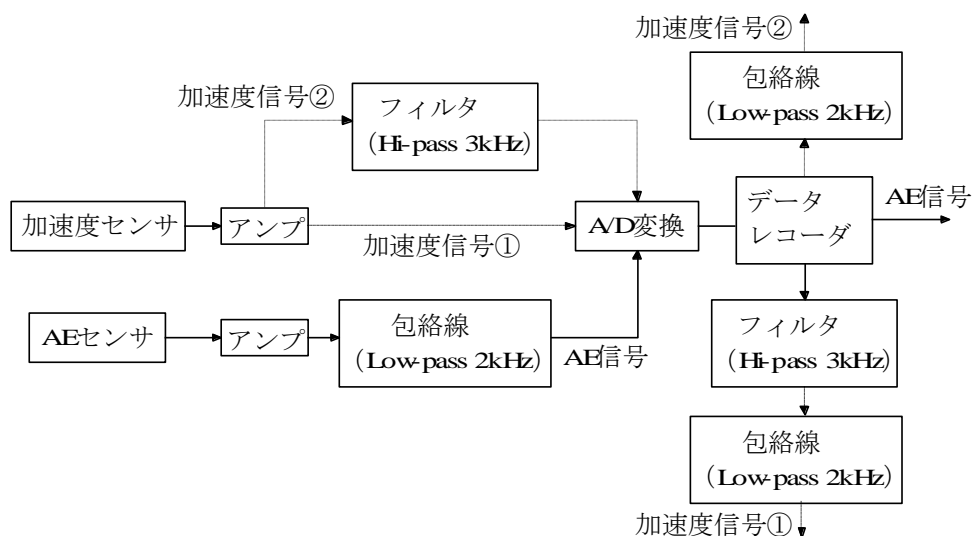


図2-5 信号計測・処理の流れと信号の種類

なお、A/D 変換の後に Hi-pass フィルタをかけて得た加速度信号は「加速度信号①」であり、A/D 変換の前に Hi-pass フィルタをかけて得た加速度信号は「加速度信号②」である。

2.4 特徴パラメータを用いた簡易診断

2.4.1 使用した特徴パラメータ

設備診断を行う際、振動信号や音響信号を測定し、信号の特徴を表す「特徴パラメータ」から設備の状態を判定する⁽²⁾。時間領域における様々な特徴パラメータが定義されているが⁽²⁾、本論文では常用の特徴パラメータの中から、低速軸受診断時に感度が比較的高い 9 個のパラメータを振動信号と AE 信号との診断感度に用いる。9 個のパラメータの定義式は次に示す。

測定した離散の時系列信号を $x_i (i=1\sim N)$ とする。特徴パラメータの計算式は次に示す。

$$p_1 = \sqrt{\frac{\sum_{i=1}^N x_i^2}{N}} \quad (\text{実効値}) \quad (2-1)$$

$$p_2 = \frac{\sum_{i=1}^{N_p} |x_i|_p}{N_p} \quad (\text{ピーク平均値}) \quad (2-2)$$

ここで、 $|x_i|_p$ は信号の絶対値のピーク値（極大値） N_p はピーク値の総数である。

$$p_3 = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{N\sigma^3} \quad (\text{歪度}) \quad (2-3)$$

ここで、 σ は標準偏差値である。

$$p_4 = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{N\sigma^4} \quad (\text{尖度}) \quad (2-4)$$

ここで、 N_{+p} は極大地の数で、 N_0 は波形が平均値をクロスする数である。

$$p_5 = p_2 / \sigma \quad (2-5)$$

$$p_6 = N_{+p} / N_0 \quad (2-6)$$

$$p_7 = N_{-p} / N_0 \quad (2-7)$$

ここで、 N_{-p} は極大地の数である。

$$p_8 = \sum_{i=1}^I F(f_i) \quad (2-8)$$

ここで、 $F(f_i)$ は周波数 f_i における波形のスペクトル値である。

$$p_9 = \sqrt{\sum_{i=1}^I F^2(f_i)} \quad (2-9)$$

2.4.2 診断精度の判断方法 (DI法)

診断のために測定した波形の特徴を数値化 (特徴パラメータ) し、その特徴パラメータを用いて2状態を識別できるか否かを判断する方法としては、2状態の波形で求めた各特徴パラメータの確率密度関数が離れているほど特徴パラメータの識別感度が高いといえる。確率密度の離れる程度を評価するための識別指標 DI (Discrimination Index) を用いて診断の感度解析・評価が行える。DIは次の式で計算される。

$$DI = \frac{|x_1 - x_2|}{\sqrt{\sigma_1^2 + \sigma_2^2}} \quad (2-10)$$

x_1 : 状態1の平均値
 x_2 : 状態2の平均値
 σ_1 : 状態1の標準偏差
 σ_2 : 状態2の標準偏差

一般に $DI > 1.5$ 以上で識別に十分な約 95%以上の異常識率⁽³⁾が得られる。

2.4.3 診断感度の評価結果

表 2-3、2-4 には正常状態と外輪傷状態を識別する感度として、各信号から計算した特徴パラメータの感度解析 (DI 値) の結果を示す。表の中には $DI > 2.5$ で識別感度が良好で「2」を、 $DI > 1.5$ で識別が可能で「1」をマークし、識別感度が悪いものに「-」をマークしている。

外輪傷大の場合には AE センサーより加速度センサーの識別感度が比較的高く、特に p_6 と p_7 の識別感度が高い。AE センサーの場合は、 p_1 、 p_2 、 p_8 、 p_9 の識別感度が高い。外輪傷小の場合は加速度信号の p_1 、 p_2 、 p_8 、 p_9 は識別感度が高い。以上の比較結果により異常信号が強弱にもかかわらず、加速度信号の方は AE 信号より識別感度が比較的高い。

表 2-3 外輪傷大の識別感度

		p1	p2	p3	p4	p5	p6	p7	p8	p9
加速度信号①	10rpm	1	1	-	-	-	2	2	-	-
"	30rpm	2	2	-	1	2	2	2	2	2
"	50rpm	-	-	1	-	1	1	1	-	-
"	100rpm	-	-	-	-	2	2	2	-	-
加速度信号②	10rpm	2	1	-	-	-	2	2	1	2
"	30rpm	2	2	2	-	-	2	2	1	1
"	50rpm	1	1	2	2	-	2	2	1	1
"	100rpm	-	-	2	-	2	2	2	-	-
AE信号	10rpm	2	2	-	-	-	-	-	1	-
"	30rpm	1	-	1	-	-	1	-	1	1
"	50rpm	2	2	-	-	-	2	-	2	2
"	100rpm	2	2	-	-	-	1	1	2	2

表 2-4 外輪傷小の識別感度

		p1	p2	p3	p4	p5	p6	p7	p8	p9
加速度信号①	10rpm	1	1	-	-	2	2	2	-	-
"	30rpm	2	2	1	1	2	2	2	2	2
"	50rpm	-	-	-	-	1	1	1	-	-
"	100rpm	2	2	-	-	-	2	2	2	2
加速度信号②	10rpm	2	2	-	-	-	-	-	1	2
"	30rpm	2	2	-	1	2	1	1	1	1
"	50rpm	2	2	-	1	2	2	2	1	1
"	100rpm	2	2	-	-	1	2	2	1	1
AE信号	10rpm	2	2	-	-	-	-	-	1	-
"	30rpm	1	-	-	-	-	-	-	1	1
"	50rpm	-	-	-	-	-	-	-	-	-
"	100rpm	2	2	-	-	1	1	1	2	2

2.5 周波数分析による診断感度の評価法

2.5.1 包絡線診断方法

表 2-1 に示すように、軸受傷による衝撃的な生波形のスペクトルだけでは、その衝撃波形のパス周波数 $f_0=1/t_0$ を検出できないので、一般に包絡線及び包絡線スペクトル分析により異常の精密診断を行う。ここで、軸受外輪の信号処理と精密診断の方法を簡略的に説明する。

表 2-1 に示すような軸受仕様を用いて、外輪傷のパス周波数 f_0 は次の計算式⁽⁵⁾によって求められる。

$$f_0 = \frac{zf_r}{2} \left(1 - \frac{d}{D} \cos \alpha \right) \quad (2-11)$$

ここで、 f_r は軸回転周波数、 z は転動体数、 d は転動体直径、 D はピッチ円直径、 α は転動体の接触角である。

一般に転がり軸受は、内輪、外輪、転動体および保持器から構成されている。これらの部品に欠陥が生じると、転動体と欠陥が周期的に衝突するので、衝撃パルス波形が発生する。本報の評価対象の傷が外輪傷であるので、(2-11)式で算出された外輪傷のパス周波数は表 2-5 に示す。

表 2-5 外輪傷パス周波数値

回転数	10rpm	30rpm	50rpm	100rpm
周波数	0.9Hz	2.7Hz	4.6Hz	9.2Hz

2.5.2 ノイズ除去

生信号にはノイズが含まれているので、現場において外輪傷によるパルス状の衝撃的な波形信号が鮮明に表れない場合が多い。図 2-6 に示しているように、スペクトルの高周波数帯域に外輪傷による衝撃的な異常振動信号のスペクトル成分が存在しているため、異常振動信号を抽出するため、ハイパスフィルタをかけてノイズを除去する。図 2-7 はノイズの除去例を示す。

図 2-6 に示しているように、スペクトルの高周波数帯域に外輪傷による衝撃的な異常振動信号のスペクトル成分が存在している。異常振動信号を抽出するため、ハイパスフィルタをかけノイズを除去する。

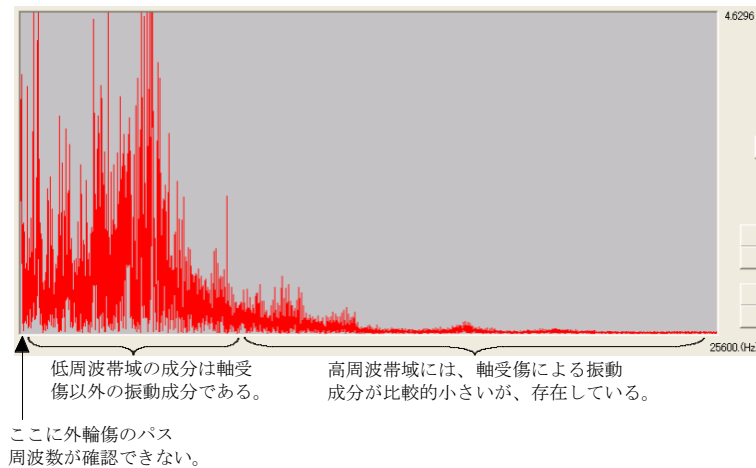


図 2-6 外輪傷状態の生波形のスペクトル

図 2-7 の上段の波形がノイズ除去前の信号の生波形で、中段の波形が 3kHz のハイパスフィルタをかけたあとの波形である。ノイズ除去後の波形の方が外輪傷による衝撃的な異常振動信号がはっきり抽出されたことわかる。

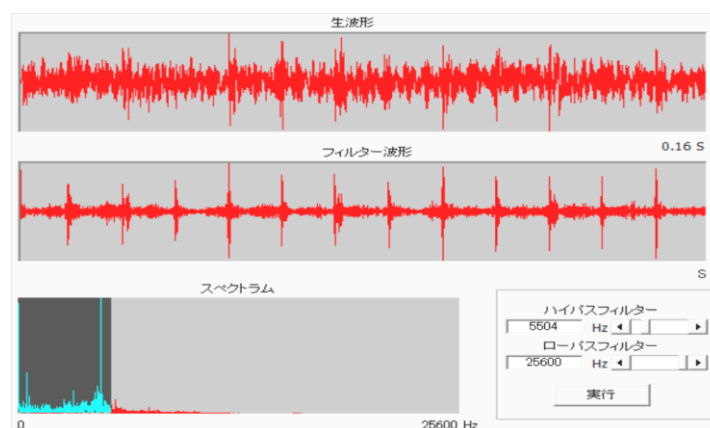


図 2-7 カットオフ周波数 = 3k の場合

なお、図 2-6 と 2-7 の信号は回転軸の回転速度が 1000rpm 時に測定された信号であるが、低速回転 (<100rpm) 時に測定された信号はこのようなハイパスフィルタをかけても衝撃的な異常振動信号を抽出できるとは限らない。

図 2-7 の上段の波形がノイズ除去前の生波形で、中段の波形がカットオフ周波数 5.5kHz のハイパスフィルタをかけた後の波形である。ノイズ除去後の波形には外輪傷による衝撃的な異常振動信号が鮮明に抽出されたことわかる。

2.5.3 診断感度の評価結果

図 2-7 に示しているハイパスフィルタで抽出した異常振動信号のパス周波数を検出するために、図 2-1 に示すような包絡線処理を行い、包絡線波形のスペクトルに現れるピーク値の周波数を(2-11)式の外輪傷状態のパス周波数 f_0 と比較して、外輪傷が発生しているか否かを診断することにより、振動信号と AE 信号との診断感度を比較評価した。

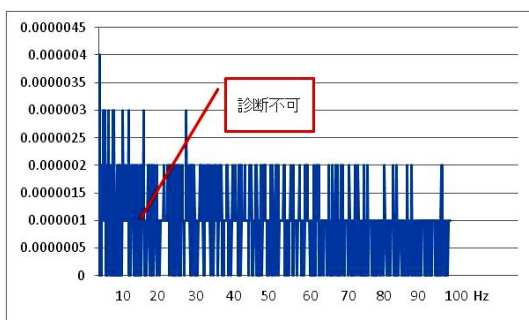


図 2-8 傷小 (10rpm)




図 2-12 傷大 (10rpm)

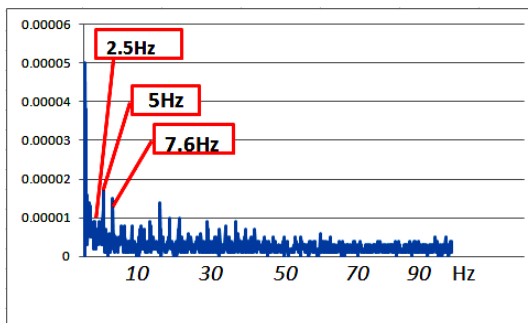


図 2-9 傷小 (30rpm)




図 2-13 傷大 (30rpm)

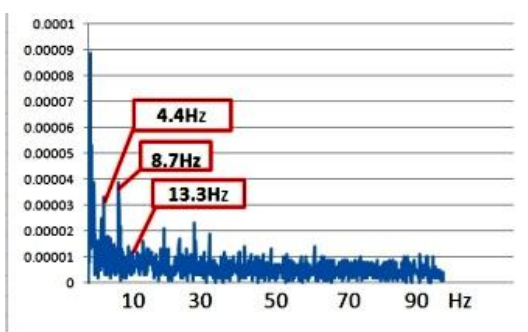


図 2-10 傷小 (50rpm)

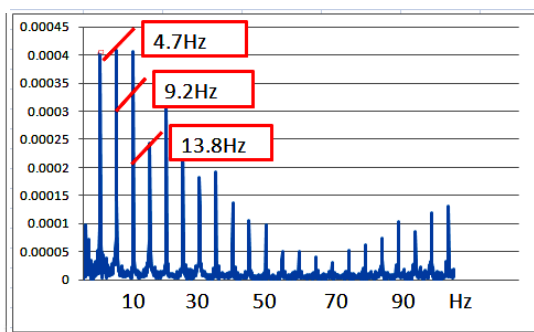


図 2-14 傷大 (50rpm)




図 2-11 傷小 (100rpm)

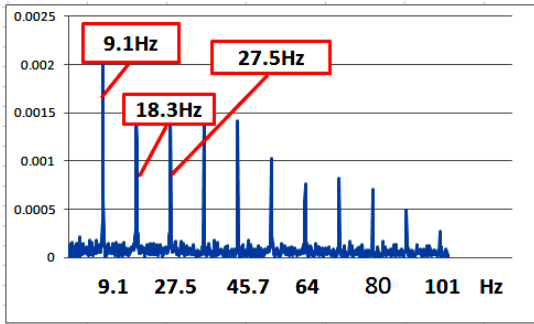


図 2-15 傷大 (100rpm)

2.5.3.1 加速度信号①の診断結果

図 2-8、2-9、2-10、2-11 は、外輪傷小の時に加速度信号①の包絡線スペクトルであり、図 2-12、2-13、2-14、2-15 は、外輪傷大の時に加速度信号

①の包絡線スペクトルである。

加速度信号①の包絡線スペクトルをみると、10rpmの時には、回転速度がかなり低いから、異常検出の感度がよくない。外輪傷大の30、50、100rpmの場合は、異常検出の感度が高く、(2-11)式を用いて計算した外輪傷のパス周波数値と包絡線スペクトルのピーク周波数値はほぼ一致である。外輪傷小の30、50rpmの場合は、包絡線スペクトルに外輪傷のパス周波数が鮮明に表れていなく、異常検出の感度がよくない。外輪傷小の100rpmの場合は、包絡線スペクトルのピーク周波数値は外輪傷のパス周波数値にほぼ一致しているので、異常の検出ができる。このように加速度センサーの異常識別感度は軸受の傷の大きさや回転速度によって影響される。




図 2-16 傷小 (10rpm)

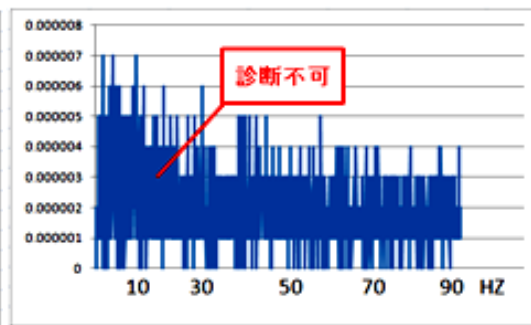


図 2-20 傷大 (10rpm)


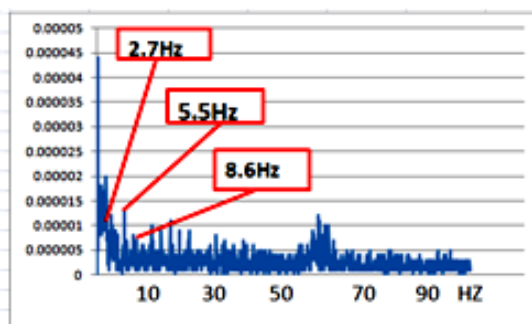


図 2-17 傷小 (30rpm)

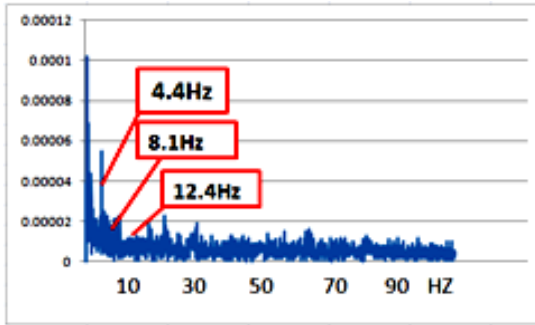


図 2-21 傷大 (30rpm)




図 2-18 傷小 (50rpm)




図 2-22 傷大 (50rpm)




図 2-19 傷小 (100rpm)

2.5.3.2 加速度信号 2 の診断結果

図 2-16、2-17、2-18、2-19 は、外輪傷小の時に加速度信号②の包絡線スペクトルであり、図 2-20、2-21、2-22、2-23 は、外輪傷大の時に加速度信号②の包絡線スペクトルである。

加速度信号②の包絡線スペクトルをみると、加速度信号①の包絡線スペクトルの形とほぼ同じ、異常検出感度もほぼ同様である。




圖 2-24 傷小 (10rpm)

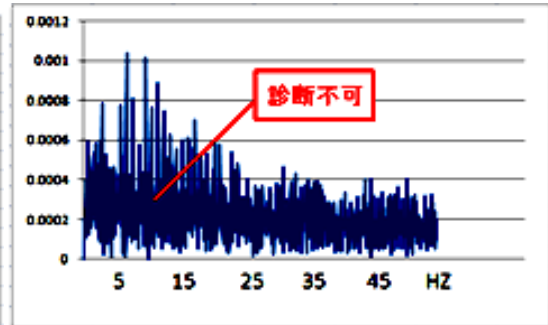


圖 2-28 傷大 (10rpm)




圖 2-25 傷小 (30rpm)




圖 2-29 傷大 (30rpm)




圖 2-26 傷小 (50rpm)

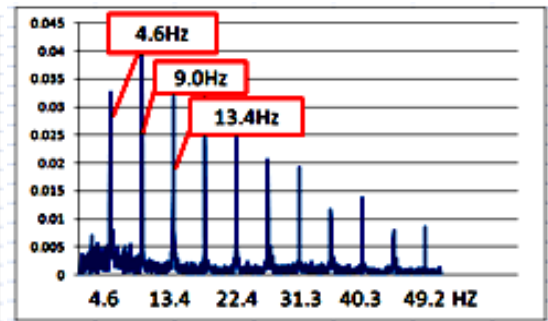


圖 2-30 傷大 (50rpm)




圖 2-27 傷小 (100rpm)




圖 2-31 傷大 (100rpm)

2.5.3.3 AE信号の診断結果

図 2-24、2-25、2-26、2-27 は、外輪傷小の時に AE 信号の包絡線スペクトルであり、図 2-28、2-29、2-30、2-31 は外輪傷大の時に AE 信号の包絡線スペクトルである。

AE 信号の包絡線スペクトルをみると、回転速度が 10rpm の場合は、異常検出の感度はやや低いが、回転速度が 30rpm 以上であれば、傷大小にも関わらず、(2-11)式を用いて計算した外輪傷のパス周波数値と包絡線スペクトルのピーク周波数値はほぼ一致である。

以上の比較結果から低回転数と傷小の時には、AE 信号の異常検出感度は加速度信号より高いと考える。

2.6 まとめ

本研究では AE 信号と加速動信号を用いて低速軸受を診断する場合、その診断感度を比較・評価するために「特徴パラメータによる診断感度の評価法」と「周波数分析による診断感度の評価法」を提案した。低速回転機械の状態診断を行うときには、AE 信号と加速度信号の診断感度は軸受傷の大きさと回転速度に関係がある。傷の大きさと回転速度が小さければ小さいほど、診断の感度は悪くなる。AE 信号と加速度信号との診断感度を比較・評価した

結果は以下のようにまとめられる。

- (1) 「特徴パラメータによる診断感度の評価法」においては、AE 信号は加速度信号に比べて特に優れた検出能力がない。その原因は AE 信号がノイズの影響を受けやすく、正常信号の中にも様々なノイズも含まれているので、識別指標 DI 値があまり高くない。
- (2) 「周波数分析による診断感度の評価法」においては、低回転数（30～50rpm）と傷小の時には、AE 信号の異常検出感度は加速度信号より高いが、回転数が 50rpm 以上と傷大の時には、両者の診断感度の差はほとんどない。
- (3) 今回の評価・実験結果から一般的な結論（異常検出限界）を導くために、動体と外輪との接触点の周速 v を次式で計算する。

$$v = \frac{\pi DN}{60} \quad (2-12)$$

加速度信号は 50rpm 以上であれば、異常がほぼ検出できると考えるから、今回使用した軸受の 50rpm 時の周速 v が約 300mm/s であるので、300mm/s は加速度信号の異常検出の限界周速と一般的に言える。

また、AE 信号は 30rpm 以上であれば、異常がある程度検出できるので、30rpm の周速 v が約 180mm/s であるので、180mm/s は AE 信号の異常検出の限界周速と考える。

今回の実験では、図 2-2 の実験機を用いたので、ノイズの影響が比較的小さい。現場設備の場合はノイズの影響が大きくなるから、特に低回転速度 (<30rpm) 時の AE 信号の有効性がさらに現場の検証・確認をする必要がある。

また、低速回転機械の異常診断のために、P パラメータ法⁽³⁾も提案されているが、P パラメータ法と AE 法の比較・評価は今後の研究により明らかにする必要がある。

参考文献

- [1] 陳山 鵬： 「回転装置の設備診断技術の基本と応用」、三恵社出版(2009)
- [2] 陳 鵬、豊田 利夫:有・無次元特徴パラメータの総合による設備診断法及び歯車異常診断への応用、評価・診断に関するシンポジウム講演論文集、
社団法人日本機械学会、
pp. 112-117、(2002)
- [3] 陳山 鵬、宮崎 修治、橋本 和也：低速軸受の最新診断法、評価・診断に関するシンポジウム講演論文集、社団法人日本機械学会、pp. 1-3、(2004)
- [4] 豊田 利夫： 「設備診断のための信号処理の進め方」、日本プラントメンテナンス協会、pp. 177、(1996)
- [5] Peng Chen、 Toshio Toyota and Zhengjia He : Automated Function Generation of Symptom Parameters and Application to Fault Diagnosis of Machinery in Variable Operation-conditions、 IEEE Transactions on System、 Man、 and Cybernetics (Part A)、 Vol. 31、 pp. 775-781、(2001)

第三章

特徴パラメータとベイジアンネットワーク

による回転機械設備診断

3.1 はじめに

コンピュータにより異常検出および異常種類の識別を自動的に行う場合は、対象の信号の特徴を示す有限個のパラメータを計算する必要がある。設備状態を鋭敏に反映するパラメータを診断用の「特徴パラメータ」という。しかし、異常パターンが多く、異常のメカニズム解明が困難な場合、上記のような特徴パラメータの選定は、多くの時間と労力を要するだけでなく、最適な特徴パラメータが見つけるとも限らない。

これらの問題点を解決するために、本研究では情報工学理論や統計理論を用いて、回転機械診断用の特徴パラメータを抽出する方法について研究し、実際の設備診断へ応用した。

また、計測した信号からノイズを除去し、特徴パラメータを算出した後、正常か、または異常種類の識別を行うが、その内容と目的は次のようにまとめられる。

- (1) 設備の状態を定量的に、かつタイムリーに把握する。
- (2) 異常の有無を識別し、異常の場合は、その原因や部位を特定し、異常種類の識別は特徴パラメータの値の評価によって行われる。

しかし、現場では、測定条件、運転条件、測定者の技能および異常の程度等々の要因により、測定信号や特徴パラメータから得られた診断情報があい

まいなケースが多いから、異常の症状と原因との関係が不明確になり、できるだけ明確な診断結論を得るために複雑な診断アルゴリズムが必要である。これまでに多くの診断アルゴリズムが提案されているが、現場の客観的な実データに基づいた自動的な確率診断アルゴリズムが少なく、高精度な診断結果を得るための確率的な診断方法には多くの課題が残されている。

したがって、本章では、周波数領域無次元特徴パラメータとベイジアンネットワークを用いて新たな自動診断方法を提案する。周波数領域無次元特徴パラメータは振動信号のスペクトルから求められ、設備状態の特徴を反映するものである。また、回転機械設備の異常検出及び状態識別をする識別感度が高い特徴パラメータを識別指標により選出する方法を提案し、特徴パラメータと各状態を節としたベイジアンネットワーク (bayonet) により設備状態を確率的かつ自動的に診断する方法を提案する。回転機械実験装置を用いて、衝撃系異常状態である軸受異常（内輪傷、外輪傷及び転動体傷）を診断する実例で提案した方法の有効性を検証する。

3.2 特徴パラメータ

3.2.1 診断用の特徴パラメータ

回転機械の自動診断のために、多くの特徴パラメータを定義されている。

ここでは、以下に示す6個の周波数領域の無次元特徴パラメータを用いられる。

$$p_1 = \frac{\sum_{i=1}^I (f_i - \bar{f})^3 \cdot F(f_i)}{\sigma^3 I} \quad (3-1)$$

$$p_2 = \frac{\sum_{i=1}^I (f_i - \bar{f})^4 \cdot F(f_i)}{\sigma^4 I} \quad (3-2)$$

$$p_3 = \sqrt{\frac{\sum_{i=1}^I f_i^4 \cdot F(f_i)}{\sum_{i=1}^I f_i^2 \cdot F(f_i)}} \quad (3-3)$$

$$p_4 = \frac{\sum_{i=1}^I f_i^2 \cdot F(f_i)}{\sqrt{\sum_{i=1}^I F(f_i) \sum_{i=1}^I f_i^4 \cdot F(f_i)}} \quad (3-4)$$

$$p_5 = \sum_{i=1}^I F(f_i) \quad (3-5)$$

$$p_6 = \sqrt{\sum_{i=1}^I F^2(f_i)} \quad (3-6)$$

ここで、 $F(f_i)$ と f_i はそれぞれスペクトルと周波数であり、 I はスペクトルのライン数である。

3.2.2 特徴パラメータの識別指標

状態1と状態2で求めた特徴パラメータ p の値をそれぞれ x_1 と x_2 とし、 x_1 と x_2 はそれぞれ正規確率分布の $N(\nu_1, \sigma_1)$ と $N(\nu_2, \sigma_2)$ に従うとする。 $|x_1 - x_2|$ が大きければ大きほど、状態1と状態2との識別感度がよいから、 $z = x_2 - x_1$ について検討する。 z が正規確率分布 $N(\nu_2 - \nu_1, \sigma_1 + \sigma_2)$ に従うので、その確率密度分布関数 $f(z)$ は次式で表せる。

$$f(z) = \frac{1}{\sqrt{2\pi(\sigma_1^2 + \sigma_2^2)}} \exp\left\{-\frac{\{z - (\nu_2 - \nu_1)\}^2}{2(\sigma_1^2 + \sigma_2^2)}\right\} \quad (3-7)$$

ここで、 $\nu_2 \geq \nu_1$ とするが、 $\nu_1 \geq \nu_2$ も同様である。

$X_2 < X_1$ の確率、つまり $Z = X_2 - X_1 < 0$ の確率は次式で計算できる。

$$p_0 = \int_{-\infty}^0 f(z) dz \quad (3-8)$$

ここで、 $\nu = \frac{Z - (\nu_2 - \nu_1)}{\sqrt{\sigma_1^2 + \sigma_2^2}}$ を (3-7) と (3-8) に代入すれば、次式が得られる。

$$p_0 = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{-DI} \exp\left(-\frac{\nu^2}{2}\right) d\nu \quad (3-9)$$

$$DI = \frac{\nu_2 - \nu_1}{\sqrt{\sigma_1^2 + \sigma_2^2}} \text{ or } DI = \frac{\bar{x}_2 - \bar{x}_1}{\sqrt{\sigma_1^2 + \sigma_2^2}} \quad (3-10)$$

よって、 $X_2 > X_1$ の確率、 $Z = X_2 - X_1 > 0$ の確率は次式で計算できる。

$$DR = 1 - p_0 \quad (3-11)$$

DR は $X_2 > X_1$ の確率を表し、状態 1 と状態 2 との識別率である。DI が大きければ、DR も大きいから、DI は、2 状態を識別するための任意の特徴パラメータ p の良さ（感度）を評価する識別指標として用いられる。

3.3 ベイジアンネットワークと学習技術

3.3.1 ベイジアンネットワーク

ベイジアンネットワークは不確実な状況を表現するために幅広く用いられている。因果関係のあるイベントの確率変数をノードとするグラフ構造と、各ノードに割り当てられた条件付確率分布群によってベイジアンネットワークは定義される。因果関係の有無は有向グラフで表される。また、因果関係の強さを条件付確率で表す。各変数の条件付確率分布は、本研究で対象とする離散的な確率変数の場合には、親ノードと子ノードの各変数がとる具体的な値ごとに割り当てられた条件付確率を離散的な表、すなわち条件付確率表(Conditional Probability Table(CPT))で表現する。図3-1 にベイジアンネットワークの例を示す。このベイジアンネットワークは①、②、③、④の4 イベントで構成されている。

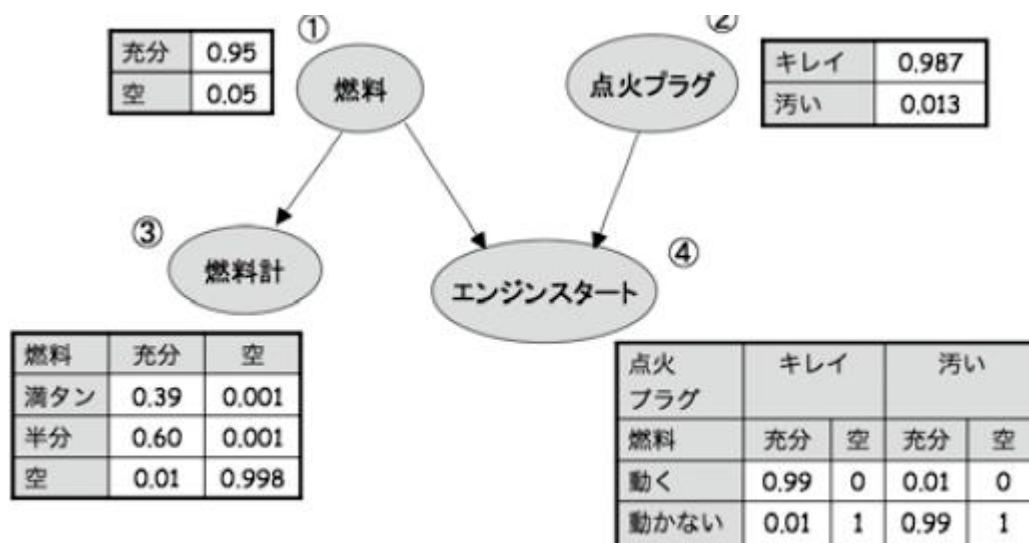


図 3-1 ベイジアンネットワークの例

3.3.2 確率推論

確率推論は、「Aという事象が起きた時にBという事象が起こる確率は〇%である」のように確率的に推論を行う技術である。「AならばBである」と決定論的に導かれる論理推論とは違い、不確定要素の多い事象のモデル化に向いている。「熱がある。喉が痛い」などの症状からその病因を探る原因推定や、「売上、利益、資産、借り入れ状況」から倒産の確率を推論する予測など、様々な分野に適用可能である。

3.3.3 ベイジアンネットワークの学習

ベイジアンネットワークの作成手法に目を向けてみる。図3-1で示したベイジアンネットワークでは因果関係が明確であり、モデルを作成するのは非

常に簡単である。また確率テーブルも、過去の故障報告などからエンジンがかからなかった場合の原因として燃料がなかった場合、およびプラグが汚れていた場合の報告事例を集計することで容易に確率を求めることができる。しかしながらこのような単純なベイジアンネットワークでは実用とすることはできないであろう。さらに多くのノードを持つ複雑なベイジアンネットワークを作成する場合、それぞれのノード間の関連性を判断することは難しくなる。また接続されるノードが増えるに従って次元が増える確率テーブルを全て埋めることは困難な作業となり、推論精度の高いベイジアンネットワークを人手で作成することはすぐに非現実的となる。

そこで注目されるのがデータからノード間の関連性を計算して適切に接続し、データを数え上げて確率テーブルを埋める学習技術である。ところが従来の学習技術では、ノード数やそれぞれのノードが取りうる状態の数が増えるに従って指数関数的に計算時間が増えてしまうという課題を抱えている。通常のデスクトップレベルの性能のPCでは、数百ノード程度までの学習が限度となる。

3.4 診断及び応用

3.4.1 異常診断設備

図 3-2 に示すのは衝撃系異常を診断する設備装置であり、図 3-3 には軸受の傷を示す。図 3-4 にしめすのは計測した軸受の各状態（常、転動体、外輪傷、内輪傷）の生信号である。設備の回転スピードは 800rpm に設定し、測定したサンプリング周波数は 50kHz、サンプリング時間は 20s である。



図 3-2 実験設備




図 3-3 軸受 (a) 外輪傷 (b) 内輪傷 (c) 転動体







図 3-4 各状態の振動信号

3.4.2 異常診断の識別感度

表 3-1 には DI 値により診断感度の識別結果を示す。表 3-1 から見ると、計算した特徴パラメータの中では、特徴パラメータ p_1 、 p_2 、 p_4 の値は他の特徴パラメータより大きくて分かるから、識別感度が高いと判定する。

表 3-1 各状態の識別感度結果

状態	P_1	P_2	P_3	P_4	P_5	P_6
正常－内輪傷	2.245	3.013	0.411	4.093	3.173	0.579
正常－外輪傷	23.006	21.182	13.092	37.879	19.856	10.941
正常－転動体	7.898	4.874	4.915	9.09	1.705	2.219
転動体－外輪傷	3.441	1.848	3.140	14.991	9.715	5.578
転動体－内輪傷	4.682	4.110	3.374	9.776	0.11	1.997
内輪傷－外輪傷	3.057	8.951	1.519	3.588	14.134	10.405

3.4.3 ベイジアンネットワーク診断システムの構築と検証

本研究では、ベイジ定理に基づいて故障診断モデルのベイジアンネットワークを築く。図 3-5 に示すようにベイジアンネットワーク診断モデルである。モデルの中では、第一層は正常状態と異常状態、第二層は、各種異常（内輪傷、外輪傷、転動体）状態であり、第三層は診断用の 6 個の特徴パラメータである。

表 3-2 は第一層の中では、正常状態と異常状態の定義と状態値に示す。

表 3-3 は第二層の中では、各異常状態の定義と状態値に示す。

表 3-4 は第三層の中では、6 個の特徴パラメータの定義と状態値に示す。

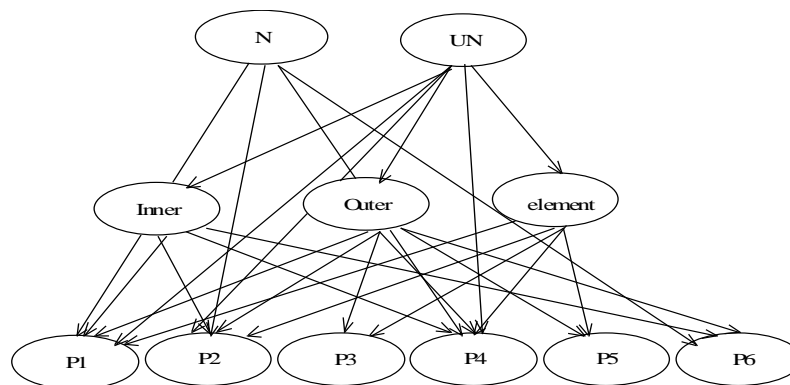


図 3-5 ベイジアンネットワークの診断モデル

表 3-2 第一層の状態名及び状態値

状態	状態値
正常 (N)	0、1(0:正常; 1:異常)
異常 (UN)	0、1(0:正常; 1:異常)

表 3-3 第二層の状態名及び状態値

状態	状態値
内輪傷 (Inner)	0、1(0: 内輪傷ではない; 1: 内輪傷)
外輪傷 (Outer)	0、1(0: 外輪傷ではない; 1: 外輪傷)
転動体 (Element)	0、1(0: 転動体ではない; 1: 転動体)

表 3-4 第三層の状態名及び状態値

特徴パラメータ	値
P ₁	
P ₂	1、 2、 3、 4、 5
P ₃	1、 2、 3、 4、 5
P ₄	1、 2、 3、 4、 5
P ₅	1、 2、 3、 4、 5
P ₆	1、 2、 3、 4、 5

表 3-5 ノートとモデルの関係

ノート		モデル			
正常					
異常					
内輪傷	*異常				
外輪傷	*異常				
転動体	*異常				
P ₁	*正常	*異常	*内輪傷	*外輪傷	*転動体
P ₂	*正常	*異常	*内輪傷	*外輪傷	*転動体
P ₃	正常	異常	内輪傷	外輪傷	転動体
P ₄	*正常	*異常	*内輪傷	*外輪傷	*転動体
P ₅	正常	異常	内輪傷	外輪傷	転動体
P ₆	*正常	*異常	*内輪傷	*外輪傷	*転動体

ベイジアンネットワークの故障診断のモデルにおいては、親ノートと子ノートの関連性を確認することは重要である。訓練したベイジアンネットワークの故障診断のモデルのノート名とノートの間に関連性は表 3-5 のように示す。

表 3-5 にノートとモデルの関係によって、ベイジアンネットワークの訓練モデルを築いた、図 3-5 のように示す。

実験の中では、測定した振動信号は二組を分割して、一組はベイジアンネットワークモデルの学習データとして使い、二組はベイジアンネットワークモデルの有効性を検証しようとする。

表 3-6 にはベイジアンネットワークモデルで各状態の診断結果である。

表 3-6 診断の結果

状態	正確率
正常	0.9859
外輪傷	0.9999
内輪傷	0.9847
外輪傷	0.9975

以上の診断結果から見ると、今築いているベイジアンネットワークモデルを用いて軸受の正常状態、内輪状態、外輪状態及び転動体状態を自動・正確的に診断することが分かる。

3.5 まとめ

回転機械設備の異常を早期に検出し、異常種類を早期に判明するために、本研究では周波数領域の無次元特徴パラメータとベイジアンネットワークによる自動診断法を提案した。計測した振動信号から回転機械設備の状態を鋭敏に反映する6個の周波数領域の無次元特徴パラメータを定義し、DI値（識別指標）を用いて識別感度が高い特徴パラメータを抽出した。最後に、特徴パラメータと各状態を節としたベイジアンネットワークの診断モデルを構築し、回転機械実験装置を用いて、衝撃系異常状態である軸受異常（内輪傷、外輪傷及び転動体傷）を診断し、98%以上の正確な診断結果が得られ、提案した方法の有効性が確認できた。

参考文献

- [1] P. CHEN、 T. TOYOTA、 Fuzzy Diagnosis and Fuzzy Navigation for Plant Inspection and Diagnosis Robot、 *Proc. of FUZZ-IEEE*、 Vol. 1、 pp.185-193、 1995.
- [2] H. Q Wang and P. Chen. Fuzzy Diagnosis Method for Rotating Machinery in Variable Rotating Speed、 *IEEE Sensors Journal*、 Vol. 11、 No. 1、 pp. 23-34、 2011.
- [3] Peng Chen、 Toshio Toyota and Zhengjia He、 Automated Function Generation of Symptom Parameters and Application to Fault Diagnosis of Machinery under Variable Operating conditions; *IEEE Transactions On Systems*、 NO.6、 pp.775-781、 2001.
- [4] T. Stich、 T. *Bayesian networks and structure learning* [Diploma Thesis、 Computer Science and Engineering]. University of Mannheim. available: <http://66.102.1.104>
- [5] Jianghua Luo. “The application of Bayesian Network in the mechanical fault diagnosis、” Chongqing University [D]、 2006.
- [6] Jianchuan Li、 Huniao Qing、 etc、 “Bayesian Network theory in the equipment fault device、” *China Mechanical Engineert*、 vol.10、 2000.
- [7] Songqing Peng、 Yousheng Zhang、 “Research on the theory of Bayesian Network and Its implication in Image Analysis、” Hefei industrial university[D]、 2005.
- [8] Wilson Quansheng Wang 、 “Rotary machinery health condition monitoring、 fault diagnosis、” Waterloo University、 2002.
- [9] Zhang、 N.L and D. Poole. Exploiting causal independence in Bayesian network inference、 *journal of Artificial Intelligence Research*、 Vol. 5、 pp.301-328、 1996.

- [10] K. Murphy, “A brief introduction to graphical models and Bayesian networks,” *The Bayes Net Toolbox for Matlab*, Computing Science and Statistics, 33, 2001.

第四章

逐次型ベイジアンネットワークと信号融合 による設備診断法

4.1 はじめに

設備診断を行うときには、診断用の良好な特徴パラメータが見つければ、特徴パラメータの値の変化を監視することにより設備の状態が判明できるため、コンピュータによる設備の自動監視・診断は可能である^[1]。

特徴パラメータは、時系列信号から求めた時間領域の特徴パラメータ、およびスペクトルから求めた周波数領域の特徴パラメータなどがある。また、特徴パラメータは「有次元特徴パラメータ」と「無次元特徴パラメータ」に分けることができる^[2]。

しかし、異常の早期段階でノイズの影響などにより特徴パラメータと異常種類との間にあいまいな関係が存在する。また、回転機械設備を診断する場合、単一な位置・方向で測定した振動信号（以下、「単一チャンネル信号」とよぶ）を使って多種類の異常を検出・識別することは困難な場合が多い。

本研究では、複数位置・方向で測定した振動信号（以下、「多チャンネル信号」とよぶ）から算出した有次元特徴パラメータを用いてベイジアンネットワーク (BN) により簡易診断を行い、異常の有無（状態の変化の有無）を判定する。簡易診断で異常が検出された後、多チャンネル信号から算出した無次元特徴パラメータを用いてベイジアンネットワーク (BN) により異常種類を判定するという逐次型ベイジアンネットワーク (SBN) および多チャネル

ル信号融合による設備診断法を提案する。また、提案した方法を回転機械の構造系異常（ミスアライメント、緩み、アンバランス）の自動的監視・診断に応用し、その有効性を検証する。図1に示すように、本研究で提案する診断方法は「診断の準備」と「診断の実施」から構成される。本論文では図1の中の具体的な内容について説明していく。

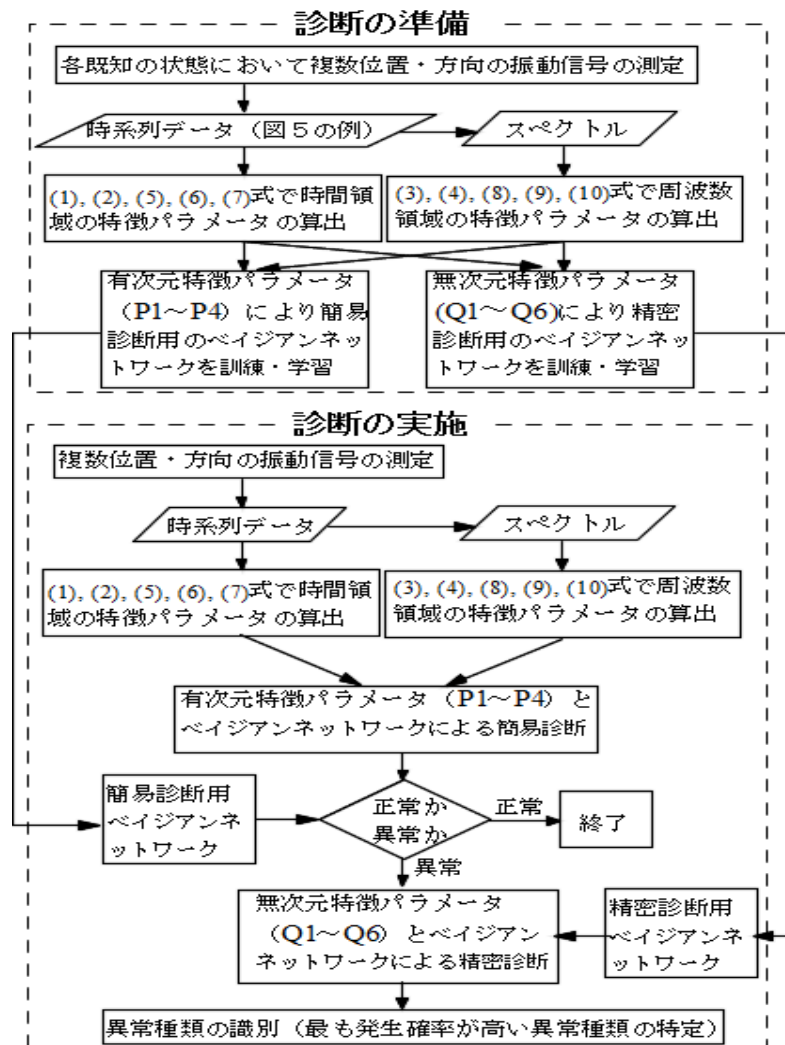


図 4-1 本研究で提案する自動診断法の流れ図

4.2 特徴パラメータ

特徴パラメータはパターン認識の領域で多く定義されているが、本研究において回転機械の構造系異常の簡易診断に使用される時間領域・周波数領域の有次元特徴パラメータ、および精密診断に使用される時間領域・周波数領域の無次元特徴パラメータは以下のように定義される。時間領域の有次元特徴パラメータは式(4-1)、(4-2)に示し、周波数領域の有次元特徴パラメータは式(4-3)～(4-4)に示し、時間領域の無次元特徴パラメータは式(4-5)～(4-7)に示し、周波数領域の無次元特徴パラメータは式(4-8)～(4-10)に示す。

$$p_1 = \sqrt{\frac{\sum_{i=1}^N x_i^2}{N}} \quad (\text{実効値}) \quad (4-1)$$

ここで、 x_i と N はそれぞれ測定した振動信号の時系列離散データとその総数である。

$$p_2 = \frac{\sum_{i=1}^{N_p} |\bar{x}_i|_p}{N_p} \quad (\text{ピーク値}) \quad (4-2)$$

ここで、 $|\bar{x}_i|_p$ と N_p はそれぞれ信号 x_i の絶対値のピーク値(極大値)と絶対値ピーク値の総数である。

$$p_3 = \sum_{i=1}^I F(f_i) \quad (\text{パワースペクトルの総和}) \quad (4-3)$$

$$p_4 = \sqrt{\sum_{i=1}^I F^2(f_i)} \quad (4-4)$$

(パワースペクトルの平方総和のルート値)

ここで、 $F(f_i)$ と f_i はそれぞれスペクトルと周波数であり、 I はスペクトルのライン数である。

$$Q_1 = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{\sigma^4 N} \quad (\text{尖度}) \quad (4-5)$$

$$Q_2 = p_2 / \sigma \quad (\text{波形率}) \quad (4-6)$$

ここで、 \bar{x}_i と σ はそれぞれ x_i の平均値と標準偏差である。

$$Q_3 = \frac{\left| \sum_{i=1}^{N_p} (x_{pi} - \bar{x}_p)^3 \right|}{\sigma_p^3 N_p} \quad (\text{極大値の歪度}) \quad (4-7)$$

ここで、 x_{pi} はピーク値（極大値）であり、 \bar{x}_p と σ_p はそれぞれピーク値（極大値）の平均値と標準偏差である。

$$Q_4 = \frac{\sum_{i=1}^I (f_i - \bar{f})^3 \cdot F(f_i)}{\sigma^3 I} \quad (\text{スペクトルの歪度}) \quad (4-8)$$

$$Q_5 = \frac{\sum_{i=1}^I (f_i - \bar{f})^4 \cdot F(f_i)}{\sigma^4 I} \quad (\text{スペクトルの尖度}) \quad (4-9)$$

$$Q_6 = \frac{\sum_{i=1}^I f_i^2 \cdot F(f_i)}{\sqrt{\sum_{i=1}^I F(f_i) \sum_{i=1}^I f_i^4 \cdot F(f_i)}} \quad (\text{波形の安定指数}) \quad (4-10)$$

4.3 ベイジアンネットワークによる自動診断法

4.3.1 ベイジアンネットワークとは

ベイジアンネットワークは複数個の確率変数の定性的な依存関係をグラフ構造で表現する確率モデルである。




図4-2 ベイジアンネットワークの例

4.3.2 確率推論アルゴリズム^[8]

図4-2のようなベイジアンネットワークの場合、構成要素としては、確率変数 (X、Y、Z、W)、条件付確率及び事前確率 {P(X)、P(Y|X、Z)、P(Z)、P(W|Z)}、そして図4-3にあるような有向グラフで表現される。モデルにお

ける全確率変数の確率 $P(X, Y, Z, W)$ は

$$P(X, Y, Z, Y) = P(X)P(Y | X, Z)P(Z)P(W | Z) \quad (4-11)$$




図4-3 ベイジアンネットワークのモデル

ここで、図3に示すように、確率変数Bの事後確率を求めたいとする。このとき、ノードAはノードBの親ノードであり、ノードCはノードBの子ノードである。Bの親ノード群に入力される観測情報と、Bの子ノード群に入力される観測情報としてそれぞれ e^+, e^- を与える。このとき、ベイズの定理より、事後確率 $P(B | e^+, e^-)$ は以下のように計算できる。

$$P(B | e^+, e^-) = \frac{P(e^- | e^+, B)P(B | e^+)}{P(e^+ | e^-)} \quad (4-12)$$

このとき、 $\frac{1}{P(e^+ | e^-)}$ は確率変数Bに依らないものだから、定数として扱

える。よって求めたい事後確率は、と記述できる。

$$P(B|e^+,e^-) = \alpha P(B|e^+)P(e^-|B) \quad (4-13)$$

ここで親ノードからの寄与確率値を $P(B|e^+) = \pi(B)$ とおき、子ノードからの寄与確率値を $P(e^-|B) = \lambda(B)$ とおく。まず、定義済みである $P(B|A)$ と $P(A|e^+)$ の周辺化により計算が可能である。

$$\pi(B) = \sum_A P(B|A)P(A|e^+) \quad (4-14)$$

このとき、ノード A が親ノードを持たない最上流の親ノードであれば、予め用意された事前確率を与える。観測値が与えられているのならば、その値は決定できる。それ以外の場合、つまりノード A には入力無く、かつノード A の上流に親のノードが存在するとき、式(4-15)を再帰的に適用することでその値を求めることが出来る。

同様に $\lambda(B)$ も定義済みの $P(C|B)$ とノード C の状態の周辺化によって計算が可能である。

$$\pi(B) = \sum_A P(B|A)P(A|e^+) \quad (4-15)$$

ここで、下流に与えられた情報 e^- と変数 B は独立関係にあることを考慮すると、以下のように式を書き換えることが出来る。

$$\lambda(B) = \sum_C P(C|B)P(e^-|C) \quad (4-16)$$

このように、あるノードの上流と下流からの確率伝播を局所的に考慮する

ことで、計算量が大幅に削減される。

4.3.3 ベイジアンネットワークにより自動診断法

ベイジアンネットワークにより自動診断法は、状態の因果関係をグラフィカル確率モデル（ベイジアンネットワークのモデル）で表し、観測データと確率推論アルゴリズムに基づき、不確定な各状態の発生確率を自動的に求める方法である。

すなわち、まずベイジアンネットワークのモデル（節点と枝の組合せ）を決め、既知状態の信号を用いて求めた特徴パラメータによりベイジアンネットワークの学習を行い、診断の時に測定した信号を用いて求めた特徴パラメータを学習済みのベイジアンネットワークへ入力して、各状態の発生確率を自動的に診断することである。

4.4 構造系異常診断への応用

4.4.1 診断ための実験設備と状態設定

図 4-4 には本研究で使用した構造系異常診断の実験装置を示す。本実験では三つの加速度センサ（図 4-4 の ch1、ch2、ch3）を用いた。加速度センサの取り付け位置は被駆動軸側における右の軸受台座の軸方向、水平方向、垂直方向に取り付け、振動信号を測定・記録し、異常の検出・識別に用いた。

構造系異常状態は、図 4-4 のように人工的に設定した。回転軸アンバランス状態は静・動二種類があり、回転軸ミスアライメントはオフセットミスアライメントとアングルミスアライメントの二種類があるので、静アンバランス (SU)、動アンバランス (DU)、オフセットミスアライメント (OM)、アングルミスアライメント (AM) および緩み (L) を設定し、正常状態 (N) と合わせて 6 状態の振動加速度信号を測定した。

なおサンプリング周波数を 5 kHz、測定時間を 20sec、実験時の軸回転数を 1200rpm として信号を測定した。図 4-5 は各状態の振動信号の例である。





図 4-4 構造系異常診断ための回転機械装置と設定した各構造系異常状態

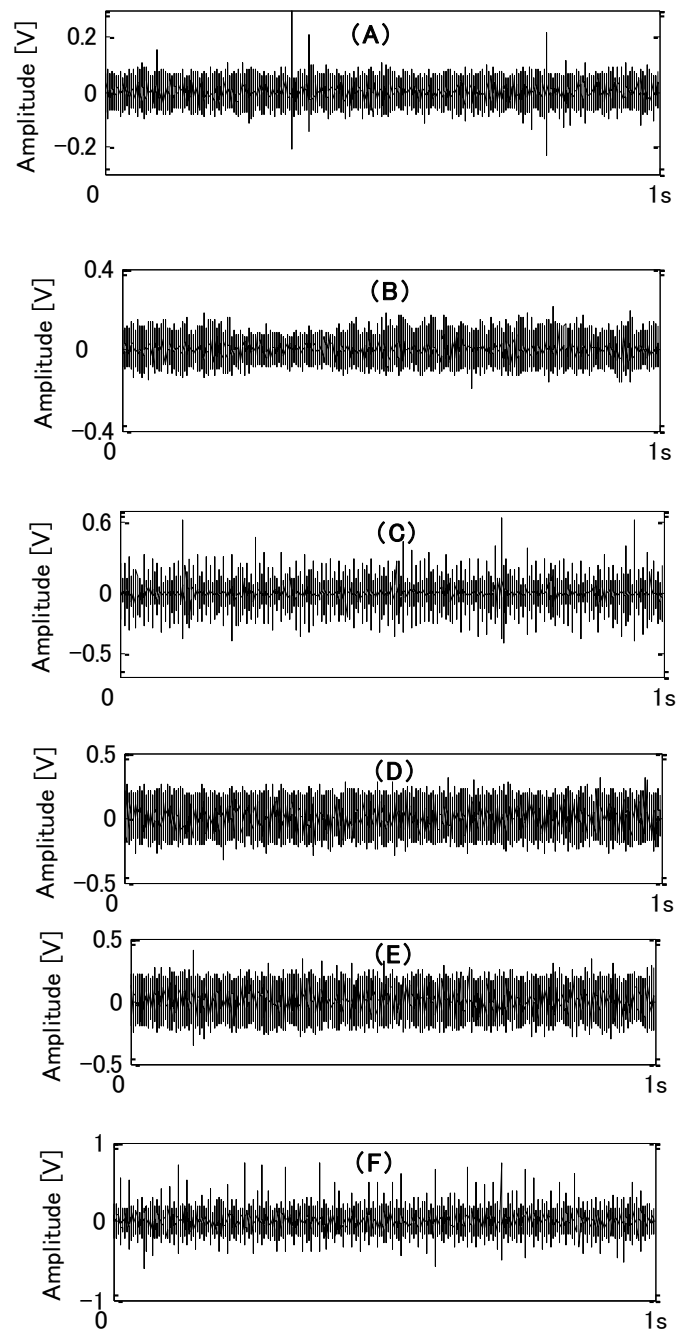


図 4-5 正常状態と構造系異常の振動信号（垂直方向信号）：(A)正常、(B)アングルミスアライメント、(C)オフセットミスアライメント、(D)静アンバランス、(E)動アンバランス、(F)緩み

4.4.2 多チャンネル信号融合と逐次型ベイジアンネットワークによる

状態診断

ベイジアンネットワークでは、モデル（構造）の違いによって異常診断の精度に影響が与えられるため、異常診断にとって最も適切なモデルを構築することは最重要である。

構造系異常状態の種類によって測定した振動信号の特徴が大きく異なる。例えば、アンバランス状態の特徴は一般的にラジアル方向の振動が大きく軸方向の振動が小さい。ミスアライメント状態の特徴は特に軸方向の振動がアンバランス状態より大きい。つまり、単一方向だけでは、各異常状態の特徴が完全に表せない。また、診断しようとする異常種類が多いとき、全ての異常種類が識別できる万能的な特徴パラメータを見つけることは困難である。これらの問題を解決のために、本研究では、多チャンネル信号融合および逐次的に簡易・精密診断が行える逐次型ベイジアンネットワーク（図 4-6）による診断法を提案する。

逐次型ベイジアンネットワークでは、まず有次元特徴パラメータを用いて簡易診断を行い、正常か異常かを判定し、もし異常状態と判定されたら、さらに、無次元特徴パラメータを用いて、異常種類を精密に特定する。

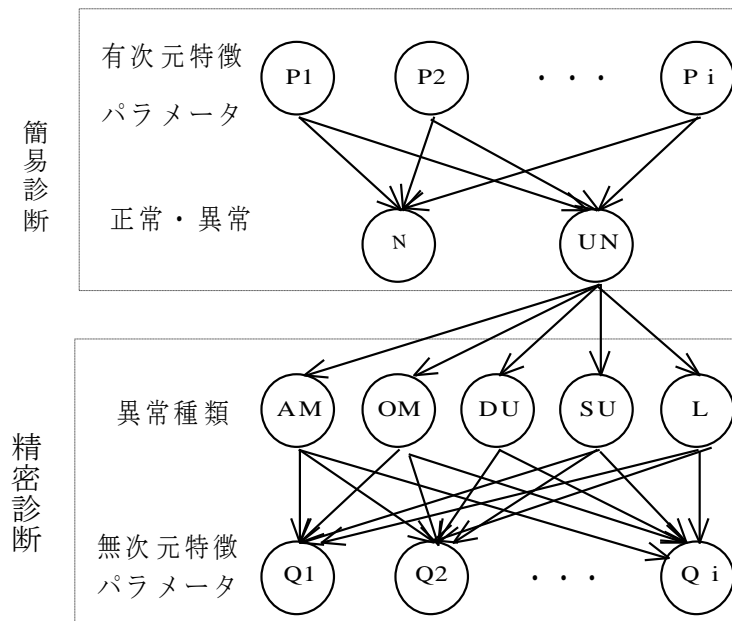


図 4-6 逐次型ベイジアンネットワーク

4.4.3 逐次型ベイジアンネットワークと多チャンネル信号融合による 診断結果

各状態における三方向（鉛直方向、水平方向、軸方向）の振動信号を 48 分割して算出した 48 個の特徴パラメータのうち、30 個はベイジアンネットワークモデルの学習に用い、確率変数、条件付確率及び事前確率を確定した後、残りの 18 個は未学習データとして状態判定の確率推論結果の検証に用いる。

表 4-1 に示すように、3 チャンネル信号の有次元特徴パラメータ $p_1 \sim p_4$ を用いて、正常 (N) か異常 (UN) かの簡易診断を行う。さらに、表 4-2 に示すように、3 チャンネルの無次元特徴パラメータ $Q_1 \sim Q_6$ を用いて異常種類を

精密に診断する。

表 4-1 簡易診断用の有次元特徴パラメータの数値例

状態	軸方向				水平方向				垂直方向			
	P1	P2	P3	P4	P1	P2	P3	P4	P1	P2	P3	P4
N	1	1	3	3	1	1	1	1	1	1	1	1
N	2	1	3	4	1	1	1	1	1	1	1	1
...
N	2	1	3	3	1	1	1	1	1	1	1	1
UN	5	4	7	1	7	5	5	4	6	5	5	4
UN	5	3	6	4	7	6	5	4	5	4	4	4
...
UN	5	3	5	3	6	4	5	4	6	4	4	4

なお、特徴パラメータの数値は、表 4-1 と表 4-2 に示すように、1～10 のように正規化・整数化されて、診断に用いられた。

表 4-2 精密診断用の無次元特徴パラメータの数値例

状態	軸方向						水平方向						垂直方向					
	Q1	Q2	Q3	Q4	Q5	Q6	Q1	Q2	Q3	Q4	Q5	Q6	Q1	Q2	Q3	Q4	Q5	Q6
AM	1	2	2	7	6	7	3	7	6	6	6	8	1	4	5	5	4	7
AM	1	4	3	6	6	7	5	8	7	6	7	8	2	4	3	3	3	6
...
AM	1	4	2	3	6	6	4	7	6	9	7	9	1	3	4	5	4	6
OM	2	4	3	7	8	8	4	8	7	3	6	7	3	7	6	6	7	9
OM	2	5	2	3	6	5	4	7	6	5	5	7	3	7	7	6	6	8
...
OM	4	8	6	7	5	8	4	7	7	6	4	8	6	9	8	9	9	2
SU	1	1	2	2	6	3	1	2	2	5	3	7	1	1	1	2	4	5
SU	1	2	2	1	5	4	1	2	2	6	4	7	1	3	4	1	2	3
...
SU	1	1	1	1	5	3	1	2	2	5	4	7	1	1	2	1	1	3
DU	1	2	2	2	7	5	1	2	3	3	2	5	1	2	3	1	2	4
DU	1	1	1	2	6	4	1	3	3	5	4	7	1	2	4	2	2	1
...
DU	1	1	1	1	5	5	1	1	1	2	3	5	1	1	2	1	3	3
L	1	4	2	5	3	6	3	6	5	1	1	5	1	1	1	3	3	5
L	2	6	3	2	1	4	2	5	4	1	1	3	1	2	3	2	3	4
...
L	4	4	3	5	1	5	3	6	5	1	1	4	1	1	1	2	1	4

表 4-3 多チャンネル信号と逐次型ベイジアンネットワークによる診断結果

診断状態	診断の正確率(%)
N	100
SU	80
DU	75
OM	100
AM	94
L	99

表 4-3 には多チャンネル信号と逐次型ベイジアンネットワークによる診断結果による診断結果を示す。これらの結果から、動・静アンバランスの識別率がやや低い、他の状態の正解率は 90%以上であり、各状態は比較的正しく判定されたことが分かる。

4.4.4 他の方法による診断結果との比較

逐次型ベイジアンネットワークと多チャンネル信号融合による診断法の有効性を示すために、本節では、他の方法による診断結果を示す。

4.4.4.1 単一チャンネル信号と逐次型ベイジアンネットワークの場合

三方向（軸方向、水平方向、垂直方向）の振動信号をそれぞれ個別に用いて求めた特徴パラメータを逐次型ベイジアンネットワーク（図 4-6）に入力して、

診断した結果は表 4-4 に示す。表 4-3 の結果と表 4-4 の結果を比較してみれば、多チャンネル信号と逐次型ベイジアンネットワークによる診断の正解率が比較的高いことが分かる。

表 4-4 単一チャンネル信号と逐次型ベイジアンネットワークによる診断結果

診断状態	各方向の信号による診断の正確率 (%)		
	軸方向	水平方向	垂直方向
N	100	100	100
SU	43	57	75
DU	56	28	40
OM	41	88	89
AM	40	56	100
L	83	95	55

4.4.4.2 一括診断用ベイジアンネットワークモデルの場合

図 4-7 に一括診断用ベイジアンネットワークモデルを示す。このモデルでは、第一層が正常と異常状態の出力層（確率）で、第二層が五種類の異常状態の出力層（確率）で、第三層が振動信号の無次元特徴パラメータの入力層（数値）である。

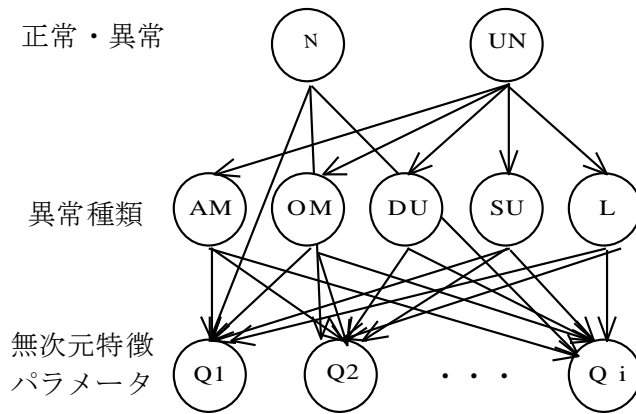


図 4-7 一括診断用ベイジアンネットワークモデル

図 4-7 のモデルに各方向の振動信号をそれぞれ単独に入力して得られた診断結果は表 4-5 に示す。

表 4-5 単一チャンネル信号と一括診断用ベイジアンネットワークモデルによる診断結果

診断状態	各方向の信号による診断の正確率(%)		
	軸方向	水平方向	垂直方向
N	28	67	0
SU	0	0	0
DU	17	0	0
OM	53	88	89
AM	0	55	77
L	72	83	0

さらに、3チャンネル信号を融合した後、図 4-6 のモデルに入力して得られた診断結果は表 4-6 に示す。表 4-6 と表 4-5 の結果を比べてみれば、多

チャンネル信号融合により異常の識別率が顕著に改善されたが、表 4-3 ほど良くないことが分かる。以上の諸結果の比較により、逐次型ベイジアンネットワークと多チャンネル信号融合による診断法の有効性が示された。

表 4-6 多チャンネル信号と一括診断用ベイジアンネットワークモデルによる診断結果

診断状態	診断の正確率(%)
N	95
SU	20
DU	47
OM	94
AM	81
L	89

4.5 まとめ

本研究では、多チャンネルの振動信号の融合、時間領域と周波数領域の特徴パラメータを用いた逐次型ベイジアンネットワークを用いて、高識別感度の診断方法を提案した。具体的な成果等は以下の通りである。

(1) 回転機械の異常を高精度で検出・識別するために、多位置と多方向で測定した振動信号を用いて、複数の時間・周波数領域の特徴パラメータを定義・算出方法を示した。

(2) 回転機械異常を検出し、異常種類を識別するために、逐次型ベイジアンネットワークを提案した。すなわち、状態監視の簡易診断を行うために、時間・周波数領域における有次元特徴パラメータを用いて、正常か否かを簡易診断用のベイジアンネットワークにより判定し、異常が検出された後、時間・周波数領域における無次元特徴パラメータを用いて、精密診断用のベイジアンネットワークにより異常種類の識別を行う。

(3) 提案した「逐次型ベイジアンネットワークと信号融合による設備診断法」の有効性を検証するために、この方法を回転機械構造系異常の診断に適用した結果、以下の結論と問題点がまとめられる。

1) 簡易診断を行った結果、正常か異常かの検出率が 100%でした。

2) 精密診断を行った結果、識別率が雑音や測定条件などにより全ての異常種類の識別率が 100%に達していないが、動・静アンバランス以外の状態の正解率は 90%以上に達した。正常状態から動・静アンバランス状態に変化したとき、特徴パラメータの値の変化が他の異常状態に比べて比較的少ないのはその識別率が低下している原因だと考えられる。なお、全ての異常種類が 100%識別できる単一な手法が存在していないから、多手法の併用が推奨される。たとえば、ベイジアンネットワークで診断結果が得られた後、その結果を参考にして、更に従来のスペクトル解析で再確認することがより

有効だと考える。

3) 「逐次型ベイジアンネットワークと信号融合」の有効性を示すために、「単一チャンネル信号と逐次型ベイジアンネットワーク」および「一括診断用ベイジアンネットワークモデル」による診断の結果も示し、「逐次型ベイジアンネットワークと信号融合」の方が最も診断精度(診断の正確率)が高いことが示された。

4) ベイジアンネットワークの大きな問題点は、ニューラルネットワークやサポートベクターマシンなどの自動診断法と同じように、学習データが必要なことであるが、現場において如何に良い学習データを獲得するかは今後の大きな課題である。

参考文献

- [1] 陳山鵬、三笥哲郎、里永憲昭、豊田利夫：時間領域の有・無次元特徴パラメータの統合による回転機械設備の状態診断法、日本設備管理学会誌、Vol. 19、 No. 2、 pp. 96-105 (2007)
- [2] 陳山鵬：「回転装置の設備診断技術の基本と応用」、三恵社出版 (2009)
- [3] 陳鵬、豊田利夫：有・無次元特徴パラメータの総合による設備診断法及び歯車異常診断への応用、評価・診断に関するシンポジウム講演論文集、社団法人日本機械学会、 pp. 112-117 (2002)
- [4] 陳山鵬、宮崎修治、橋本和也：低速軸受の最新診断法、評価・診断に関するシンポジウム講演論文集、社団法人日本機械学会、Vol. 3、 pp. 1-3

(2004)

- [5] 豊田利夫: 「設備診断のための信号処理の勧め方」、日本プラントメンテナンス協会、pp. 177 (1996)
- [6] Chen P. and Toyota T. and He Z. J.: Automated Function Generation of Symptom Parameters and Application to Fault Diagnosis of Machinery in Variable Operation-condition、 *IEEE Transactions on System, Man, and Cybernetics(Part A)*、 Vol. 31、 ISSUE 6、 PP. 77-781 (2001)
- [7] MOTOMURA YOICHI: Bayesian network modeling and reasoning algorithms for Practical Applications, IEIC Technical Report(Institute of Electronics, Information and Communication Engineers), Vol. 104, pp. 29-34(2004)
- [8] H.T. Xue, H.Q. Wang, P. Chen, K. Li and L.Y. Song: Automatic Diagnosis Method for Structural Fault of Rotating Machinery based on Distinctive Frequency Components and Support Vector Machines under Varied Operating Conditions, *Neurocomputing* , Vol. 116, pp. 326–335(2013)

第五章

結 言

5 結言

本研究では、工業・農業生産設備の安全かつ安定運転に寄与することを目指として、回転機械の状態監視・診断を行うときに測定した振動信号と AE 信号を用いて、コンピュータにより異常検出および異常種類の識別を自動的に行うために、異常信号の抽出法、診断用特徴パラメータ抽出および知的診断法について諸提案を行い、本論文で以下のような成果がまとめられた。

第二章では、AE 信号と加速動信号を用いて低速軸受を診断する場合、その診断感度を比較・評価するために「特徴パラメータによる診断感度の評価法」と「周波数分析による診断感度の評価法」を提案した。低速回転機械の状態診断を行うときには、AE 信号と加速度信号の診断感度は軸受傷の大きさと回転速度に関係がある。傷の大きさと回転速度が小さければ小さいほど、診断の感度は悪くなる。AE 信号と加速度信号との診断感度を比較・評価した結果は以下のようにまとめられる。

(1) 「特徴パラメータによる診断感度の評価法」においては、AE 信号は加速度信号に比べて特に優れた検出能力がない。その原因は AE 信号がノイズの影響を受けやすく、正常信号の中にも様々なノイズも含まれているので、識別指標 DI 値があまり高くない。

(2) 「周波数分析による診断感度の評価法」においては、低回転数（30

～50rpm)と傷小の時には、AE信号の異常検出感度は加速度信号より高いが、回転数が50rpm以上と傷大の時には、両者の診断感度の差はほとんどない。

(3) 今回の評価・実験結果から一般的な結論(異常検出限界)を導くために、動体と外輪との接触点の周速 v を次式で計算する。

$$v = \frac{\pi DN}{60} \quad (2-12)$$

加速度信号は50rpm以上であれば、異常がほぼ検出できると考えるから、今回使用した軸受の50rpm時の周速 v が約300mm/sであるので、300mm/sは加速度信号の異常検出の限界周速と一般的に言える。

また、AE信号は30rpm以上であれば、異常がある程度検出できるので、30rpmの周速 v が約180mm/sであるので、180mm/sはAE信号の異常検出の限界周速と考える。

今回の実験では、研究室内の実験機を用いたので、ノイズの影響が比較的少ない。現場設備の場合はノイズの影響が大きくなるから、特に低回転速度(<30rpm)時のAE信号の有効性がさらに現場の検証・確認をする必要がある。

また、低速回転機械の異常診断のために、Pパラメータ法も提案されているが、Pパラメータ法とAE法の比較・評価は今後の研究課題となる。

第三章では、回転機械設備の異常を早期に検出し、異常種類を早期に判明

するために、周波数領域の無次元特徴パラメータとベイジアンネットワークによる自動診断法を提案した。計測した振動信号から回転機械設備の状態を鋭敏に反映する6個の周波数領域の無次元特徴パラメータを定義し、DI値（識別指標）を用いて識別感度が高い特徴パラメータを抽出した。最後に、特徴パラメータと各状態を節としたベイジアンネットワークの診断モデルを構築し、回転機械実験装置を用いて、衝撃系異常状態である軸受異常（内輪傷、外輪傷及び転動体傷）を診断し、98%以上の正確な診断結果が得られ、提案した方法の有効性が確認できた。

第4章では、多チャンネルの振動信号の融合、時間領域と周波数領域の特徴パラメータを用いた逐次型ベイジアンネットワークを用いて、高識別感度の診断方法を提案した。具体的な成果等は以下の通りである。

（1）回転機械の異常を高精度で検出・識別するために、多位置と多方向で測定した振動信号を用いて、複数の時間・周波数領域の特徴パラメータを定義・算出方法を示した。

（2）回転機械異常を検出し、異常種類を識別するために、逐次型ベイジアンネットワークを提案した。すなわち、状態監視の簡易診断を行うために、時間・周波数領域における有次元特徴パラメータを用いて、正常か否かを簡易診断用のベイジアンネットワークにより判定し、異常が検出された後、時

間・周波数領域における無次元特徴パラメータを用いて、精密診断用のベイジアンネットワークにより異常種類の識別を行う。

(3) 提案した「逐次型ベイジアンネットワークと信号融合による設備診断法」の有効性を検証するために、この方法を回転機械構造系異常の診断に適用した結果、以下の結論と問題点がまとめられる。

1) 簡易診断を行った結果、正常か異常かの検出率が 100%でした。

2) 精密診断を行った結果、識別率が雑音や測定条件などにより全ての異常種類の識別率が 100%に達していないが、動・静アンバランス以外の状態の正解率は 90%以上に達した。正常状態から動・静アンバランス状態に変化したとき、特徴パラメータの値の変化が他の異常状態に比べて比較的少ないのはその識別率が低下している原因だと考えられる。なお、全ての異常種類が 100%識別できる単一手法が存在していないから、多手法の併用が推奨される。たとえば、ベイジアンネットワークで診断結果が得られた後、その結果を参考にして、更に従来のスペクトル解析で再確認することがより有効だと考える。

3) 「逐次型ベイジアンネットワークと信号融合」の有効性を示すために、「単一チャンネル信号と逐次型ベイジアンネットワーク」

および「一括診断用ベイジアンネットワークモデル」による診断の結果も示し、「逐次型ベイジアンネットワークと信号融合」の方が最も診断精度（診断の正確率）が高いことが示された。

- 4) ベイジアンネットワークの大きな問題点は、ニューラルネットワークやサポートベクターマシンなどの自動診断法と同じように、学習データが必要なことであるが、現場において如何に良い学習データを獲得するかは今後の大きな課題である。

謝 辞

本論文の作成に際し、当初から直接的なご指導をいただいた、三重大学大学院、生産資源学研究科共生環境学専攻環境情報システム工学講座、陳山鵬教授に感謝申し上げます。陳山鵬教授には、三重大学に入学してから、様々な面において公私共にご指導いただきました。

また、三重大学に留学中においてご指導とご支援をいただいた同環境情報システム講座、佐藤邦夫教授、王秀崙教授、村上克介教授、鬼頭準教授、森尾吉成準教授、山下助教、福島助教に感謝申し上げます。

また、論文発表の場の提供をいただいた日本設備管理学会の皆様方に感謝申し上げます。

また、同じ研究室にて様々な形でご協力、ご支援いただいた博士後期課程の薛紅涛さんをはじめ研究室メンバーの皆さんに感謝申し上げます。