

377.5

K-11-2

1-88

情報理論による回転機械の 状態診断に関する研究



九州工業大学附属図書館



0010459352

劉 信芳

目次

論文概要

第1章 序章	1
1.1 回転機械の状態診断の現状および問題点.....	1
1.2 情報理論による状態診断の必要性.....	2
1.3 本研究の目的.....	3
1.4 本研究の進め方.....	4
1.5 本研究の成果.....	4
第2章 情報理論による状態診断理論	7
2.1 はじめに.....	7
2.2 情報理論の要点.....	8
2.2.1 情報量とエントロピー.....	8
2.2.2 情報測度.....	9
2.3 診断用情報測度の導入.....	11
2.3.1 KIの定義と性質.....	11
2.3.2 IDの定義と性質.....	12
2.3.3 多変量KIおよび多変量ID.....	12
2.4 IDとKIの感度の検討.....	13
2.4.1 正規分布のIDとKI.....	13
2.4.2 識別感度の検討.....	15
2.5 KIとIDの判定基準.....	18
2.6 正規分布のMKIおよび判定基準.....	20
2.6.1 正規分布のMKI.....	20
2.6.2 情報量の構成要素(Components).....	21
2.6.3 MKIの判定基準.....	22
2.7 まとめ.....	23

第3章 時系列信号の振幅確率密度情報量を用いた状態診断.....24

3.1	はじめに.....	24
3.2	振幅確率密度情報量の抽出.....	24
3.2.1	時系列信号の振幅確率密度関数.....	25
3.2.2	時間領域の ID と KI.....	27
3.2.3	異常検出感度.....	28
3.3	状態診断アルゴリズム.....	28
3.3.1	異常の検出.....	28
3.3.2	異常種類の識別.....	29
3.4	実験による検証.....	30
3.4.1	実験方法.....	30
3.4.2	測定結果.....	32
3.4.3	異常検出感度と検出力の検証.....	33
3.4.4	異常の識別能力の検証.....	35
3.5	まとめ.....	35

第4章 時系列信号のパワースペクトラム情報量を用いた状態診断

.....	38
4.1	はじめに.....	38
4.2	パワースペクトラムの ID と KI.....	39
4.2.1	周波数領域の特徴抽出.....	39
4.2.2	パワースペクトラムの正規化.....	40
4.2.3	パワースペクトラムの ID と KI.....	41
4.3	技術情報量.....	41
4.3.1	周波数帯域と回転機械の諸異常.....	41
4.3.2	診断用の技術情報量.....	43
4.4	状態診断アルゴリズム.....	46
4.4.1	異常の判定.....	46
4.4.2	状態識別.....	47
4.4.3	周波数領域における状態診断の流れ.....	47
4.5	実験による検証.....	49
4.5.1	実験方法と測定結果.....	49
4.5.2	異常の検出感度の検証.....	49
4.5.3	異常の識別能力の検証.....	49
4.6	まとめ.....	54

第 5 章	多変量情報理論による状態診断	55
5.1	はじめに.....	55
5.2	状態診断のための多変量情報理論.....	57
5.2.1	MKI の状態診断への適用.....	57
5.2.2	MKI の異常判定基準.....	57
5.3	多変量状態診断のアルゴリズム.....	58
5.3.1	MKI による異常判定方法.....	58
5.3.2	MKI による状態診断の流れ.....	59
5.4	状態診断への適用例.....	61
5.4.1	実験方法と測定結果.....	61
5.4.2	異常検出力の検証.....	65
5.5	まとめ.....	66
第 6 章	シミュレーションと現場実機データによる実用性の検証	67
6.1	はじめに.....	67
6.2	振動信号の情報量による設備の劣化傾向管理.....	67
6.2.1	情報理論による劣化傾向管理の必要性.....	67
6.2.2	時間領域と周波数領域の情報量および異常の検出.....	68
6.2.3	注意レベルと危険レベルの設定.....	69
6.2.4	傾向管理図の作成および劣化傾向管理.....	70
6.2.5	シミュレーションと検証.....	71
6.2.6	まとめ.....	76
6.3	情報理論による抗菌フィルタの寿命判定.....	77
6.3.1	抗菌フィルタの診断の必要性.....	77
6.3.2	寿命判定のための KI と ID.....	77
6.3.3	寿命判定方法.....	78
6.3.4	測定結果.....	79
6.3.5	データ処理および判定結果.....	82
6.3.6	まとめ.....	84
6.4	回転機械の状態診断への応用.....	86
6.4.1	ボイラ給水ポンプ状態診断の必要性.....	86
6.4.2	状態診断方法と異常判定.....	86
6.4.3	測定結果.....	88
6.4.4	診断結果.....	90

6.4.5	まとめ.....	92
第7章	終章.....	93
7.1	本研究の結論.....	93
7.2	今後の展望.....	94
謝辞		95
参考文献		96

論文概要

産業基盤の重要な役割を担う各種プラントには、数多くの回転機械が設置されて、これらの回転機械は、生産プラントの中でも重要な設備の 1 つである。また、近年、プラントシステムは、自動化、連続化、無人化が図られつつある一方で、プラントの連続運転と稼働時間の延長など、システムに対して過酷な要求も課されている。このため、1 つの回転機械の故障がプラント全体の操業停止や大事故につながることも少なくない。したがって、機械設備の信頼性を向上させ、突発事故などによる生産損失を防止するためには、回転機械の諸異常を早期検出することができる実用的かつ信頼性の高い機械設備状態診断技術や予知保全技術の確立が必要とされている。

現在、振動、音響や AE 信号などの信号の有次元特徴パラメータによる設備状態診断方法は広く実用化されている。しかし、1 つの信号の有次元特徴パラメータは信号の持つ情報の一部を定量化したものであり、得られた情報を有効に活用しているとは言えない。また、生産設備の正常・異常を判定するための統一的な判定基準の設定が不可能である。さらに、測定した複数信号の情報を統合的に考えられていない。このため、有次元特徴パラメータによる設備状態診断においては、機械設備の諸異常の早期発見、早期検出が困難となる場合がある。

そこで、本研究では、情報理論による機械設備の状態診断方法を提案した。本方法は振動、音響や AE 信号などの波形の確率密度分布と周波数領域のパワースペクトラムの周波数密度分布関数に着目し、分布間の情報を効率的に抽出する情報量であるカルバック-ライブラー情報量 (Kullback-Leibler Information: KI) およびインフォメーションダイバージェンス (Information Divergence: ID) を用いて診断を行う。この方法は、情報理論の定義より、生産設備の点検時の「テスト状態」、あるいは「未知状態」と生産設備の「参照状態」、あるいは「既知状態」との「距離」測度を測ることにより、生産設備の個性情報を考慮して異常の判定と識別を行うため異常検出感度が高い。さらに、二つ以上の信号から統合的に設備異常を診断することができる多変量カルバック-ライブラー情報量 (Multivariate Kullback-Leibler Information: MKI) による回転機械の状態診断方法を確立した。

第 1 章では、回転機械の状態診断の現状および問題点と本研究の必要性を述べ、本研究の目的、本研究の進め方および成果を示した。

第 2 章では、本状態診断方法で必要となる情報理論の要点をまとめ、機械設備の状態同定と識別に用いる KI の定義を示した。また、この KI の診断に対する欠点を克服するために、ID を導入した。さらに、多変量状態診断のため、多変量カルバック-ライブラー情報

量 MKI を導入した。また、これらの情報量の識別感度を検討し、KI, ID および MKI の判定基準の設定方法を示した。

第 3 章では、時系列信号の振幅確率密度分布の「距離」を表すカルバック-ライブラー情報量とインフォメーションダイバージェンスの抽出方法を示し、時間領域の時系列信号を用いた簡易診断方法および精密診断方法を確立した。また、歯車装置と軸受の状態診断を行い、本診断方法が有効であること、および、ID が優れた診断能力を持つことを確認した。

第 4 章では、周波数領域のパワースペクトルの情報量に着目した診断方法について述べた。通常のパワースペクトラムはエネルギーの密度関数であり、情報理論を適用できないため、まず、パワースペクトラムを確率密度関数へ変換する正規化方法を示した。また、精密診断用の帯域情報量と技術情報量を定義し、全パワースペクトラムの平均情報量による簡易診断方法と技術情報量による精密診断方法を確立し、軸受の診断例により本診断方法の有効性を確認した。

また、設備状態診断の信頼性を高めるためには、機械設備から同時に測定した振動、音響、AE などの複数信号の情報を統合した状態診断方法、あるいは多変量状態診断方法が必要となる。そこで、第 5 章では、1 変量の KI による状態診断方法を複数の信号による状態診断に拡張した、多変量カルバック-ライブラー情報量 MKI による状態診断方法を提案した。はじめに、多変量状態診断のために、MKI 理論を導入した。また、MKI による状態診断の統一的な判定基準を設定し、診断アルゴリズムを確立した。さらに、多変量情報理論による状態診断方法の有効性を転がり軸受の実験により検証した。

第 6 章では、現場およびシミュレーションのデータを用いて、情報理論による設備状態診断方法の実用性を以下の三つの実用例により確認した。

- (1) 情報理論による状態診断方法の基本的な応用として、情報理論による回転機械の劣化傾向管理方法を検討した。まず、時間領域と周波数領域の情報量の算出方を示した。また、時間領域と周波数領域における設備劣化傾向管理用の統一的な判定基準（注意レベル、危険レベル）を情報検定理論により設定した。さらに、「情報理論による設備劣化傾向管理法」をまとめ、シミュレーションにより本方法の有効性を検証した。
- (2) 情報理論による状態診断方法の応用として、静止機械である抗菌フィルタの寿命判定を行った。工場現場で測定されたデータに基づき、情報理論による状態診断方法を適用し、良好な結果を得た。
- (3) 情報理論による状態診断方法の一般的な応用として、回転機械であるボイラ給水ポンプの状態診断を行った。原子力発電所現場のポンプ（テスト機）から測定したデータを用いて、その時間領域と周波数領域で、情報理論による状態診断を行い、診断結果はポンプの状態と一致した。

第 7 章では、本研究の結論を示した。

第1章 序章

1.1 回転機械の状態診断の現状および問題点

近年、産業基盤の重要な役割を担う各種プラントは、ますます大型化、連続化、自動化、無人化が図られている。また、プラントには、数多くの回転機械が使用され、これらの回転機械は、プラント全体に対して、非常に重要な機械であることが多い。このため、1つの回転機械の異常が製品の品質および生産性に悪影響を及ぼし、さらに、プラント全体の操業停止や大事故につながることも少なくない。したがって、機械設備の信頼性の向上、突発事故などによる生産損失を防止するためには、回転機械の諸異常を事前に予知する状態診断技術の確立が必要不可欠である。

現在実用化されている回転機械のおもな状態診断技術は、

- (1) 稼働中の回転機械から測定される振動や音響などの機械的兆候の解析に基づく状態診断。
- (2) 回転機械の潤滑油に含まれる金属摩耗粉の化学的分析による状態診断。
- (3) 稼働中の回転機械において、潤滑部の電気抵抗やインピーダンス変化などの電氣的兆候の分析に基づく状態診断。
- (4) 画像処理による回転機械の状態診断。

などの四つの方法に大別される。特に工場現場では、振動や音響などの機械的兆候の解析、すなわち振動および音響信号の平均値、実効値といった有次元特徴パラメータや波形率、歪み度、尖り度などといった無次元特徴パラメータによる状態診断方法が広く使われている。

しかし、この有次元特徴パラメータによる状態診断方法では、

- (1) 測定値が負荷や使用条件の変化と共に大きくばらつくため、異常の早期検出が困難である。
- (2) 測定値のばらつきにより、設備が正常であるにもかかわらず異常と診断してしまう場合がある。

(3) 複数の同一機器に対して、同一の測定点での測定が困難となる場合があり、こうした場合にはそれぞれの機器に判定基準を設定する必要がある。

(4) 機械の仕様が異なると、振動や音響のレベルも異なるため、統一的な判定基準の設定は不可能である。

などの問題点があり、また、有次元特徴パラメータおよび無次元特徴パラメータによるいずれの状態診断対しても、

(1) 特徴パラメータは振動信号や音響信号の持つ情報の一部を定量化したものであり、得られた情報を有効に活用することができない。

(2) 診断の高精度化には、振動や音響、AEなどの二つ以上の信号が同時に用いられることが望ましいが、これまでに、二つ以上の信号から統合的に設備状態を診断する方法は確立されていない。

などの問題点がある[1-3]。

1.2 情報理論による状態診断の必要性

有次元特徴パラメータによる状態診断では、機械設備から測定した信号の「大きさ」情報のみを利用している。このため、機械設備の運転状態、環境、負荷などの条件が変わると、設備の状態が正常であるにもかかわらず、測定した信号が変わることが多いため、誤診される可能性が高い。したがって、いかに機械設備の情報を獲得し、処理し、活用するかが本研究の焦点となる。

機械設備から測定した振動信号、音響信号や AE 信号の波形は状態が異なると時系列波形とそのパワースペクトラムの「形」も異なる。このため、測定した信号の「大きさ」と「形」両方の情報を利用することができ、さらに機械設備の「個性」情報を考慮することができる。ロバストな診断技術の研究開発は重要な課題となっている。従来の診断方法の欠点を克服するため、この診断技術では、

(1) 機械設備から測定した正常状態と点検状態の状態量の「差」の情報を定量化できる。

(2) 測定した状態量の情報を1つのパラメータに帰着できる。

(3) 機械の「個性」情報を考慮できる。

(4) 統一的な判定基準を設定できる。

(5) 二つ以上の信号から統合的に設備異常を診断できる。

(6) 異常検出感度と識別能力が高い。

などの内容は必須である。

以上の内容を達成するため、本研究では、情報理論による機械設備の状態診断方法を提案する。機械設備状態を総合的に反映する振動波形の振幅およびそのパワースペクトラムの確率密度分布に着目して、分布間の情報を効率的に抽出する情報量であるインフォメー

ションダイバージェンス (Information Divergence: ID) およびカルバック-ライブラー情報量 (Kullback-Leibler Information: KI) を用いる。また、多変量カルバック-ライブラー情報量 (Multivariate Kullback-Leibler Information: MKI) を用いて、多変量 KI による状態診断方法を確立する[4-6]。

1.3 本研究の目的

一般に設備状態が変化すると、その振動波形や音響波形などとそれらのパワースペクトラムの確率密度関数も変化するため、二つ確率密度関数の相違、すなわち、「距離」を表すために KI がよく用いられる[7-10]。そこで、本研究では KI を用いる状態診断方法について述べる。

また、KI はテスト分布と参照分布の情報量の差の期待値を参照分布を用いて求めるため、参照分布値が小さい領域では、情報の欠落が生じる欠点があり、KI による状態診断では異常の早期検出が困難となる場合がある[11]。このため、本研究では、上記の両分布における情報量の差の期待値を両分布の差を用いて求める ID を導入し、この ID を用いる状態診断方法を提案し、より高感度な異常検出と正確な異常識別が可能なることを理論と実験により検証する。状態診断においては参照分布の絶対値よりも分布の差が本質的な意味を持つため、両分布の差を用いて期待値を求める ID がより優れた異常検出精度を持つことが期待される。

さらに、同時に測定した振動や音響信号、AE 信号の情報を統合的に利用する多変量 KI による設備状態診断方法を提案する。

本研究の目的は、

- (1) カルバック-ライブラー情報量 (Kullback-Leibler Information : KI) とインフォメーションダイバージェンス (Information Divergence : ID) により、振動信号、音響信号および AE 信号などの確率密度関数を求めることができる状態量の特徴抽出が可能であることを理論解析により示す。
- (2) ID の異常検出感度と異常識別能力が KI と比較して優れていることを理論解析により示す
- (3) ID と KI による状態診断の統一的な判定基準を設定し、機械設備の簡易診断方法を確立する。
- (4) 時間領域においてパターン認識、周波数領域において技術情報量を用いる機械設備の精密診断方法を確立する。
- (5) 多変量 KI による機械設備の状態診断方法を確立する。
- (6) 歯車装置と軸受の状態診断に対して ID と KI による状態診断方法が有効であることおよび ID が優れた状態診断能力を持つことを実験により確認する。

- (7) 情報理論による設備劣化傾向管理方法を確立し、シミュレーションにより本方法の有効性を検証する。
 - (8) 現場のデータにより本状態診断方法の実用性を検証する。
- の 8 項である。

1.4 本研究の進め方

前節で述べた本研究の目的を達成するために、本研究では、

- (1) 機械設備の状態診断のための情報理論を導入し、ID と KI の識別感度を検討する。また、KI、ID および MKI の判定基準を設定する。
- (2) 時系列信号およびそのパワースペクトラムの確率密度関数の情報量の抽出方法を示し、時間領域と周波数領域の簡易診断および精密診断アルゴリズムを確立する。また、歯車装置と軸受の状態診断に対して ID が優れた性能を示すことおよび本診断方法が有効であることを実験により確認する。
- (3) 1 変量の KI による状態診断方法を複数の信号による状態診断に拡張した、多変量カルバック-ライブラー情報量 (Multivariate Kullback-Leibler Information:MKI) による状態診断方法を提案する。まず、多変量状態診断のため、MKI 理論を導入する。また、MKI による状態診断の統一的な判定基準を設定し、診断アルゴリズムを確立する。さらに、多変量情報理論による状態診断方法の有効性を実験により検証する。
- (4) 情報理論による状態診断方法の応用として、情報理論による回転機械の劣化傾向管理方法を確立する。また、この情報理論による設備劣化傾向管理方法が有効であることをシミュレーションにより検証する。
- (5) 情報理論による状態診断方法の実用性の検証するため、静止機械である抗菌フィルタの寿命判定と回転機械であるボイラ給水ポンプの状態診断を行う。実際の工場現場で測定されたデータに対して、情報理論による状態診断方法を適用し、本方法の有効性を確認する。

のように進める。論文の構成を図 1.1 に示す。

1.5 本研究の成果

本研究では、機械工学分野に情報理論を導入し、機械設備の状態識別および状態診断に対して、系統的に研究を行った。主な研究成果は

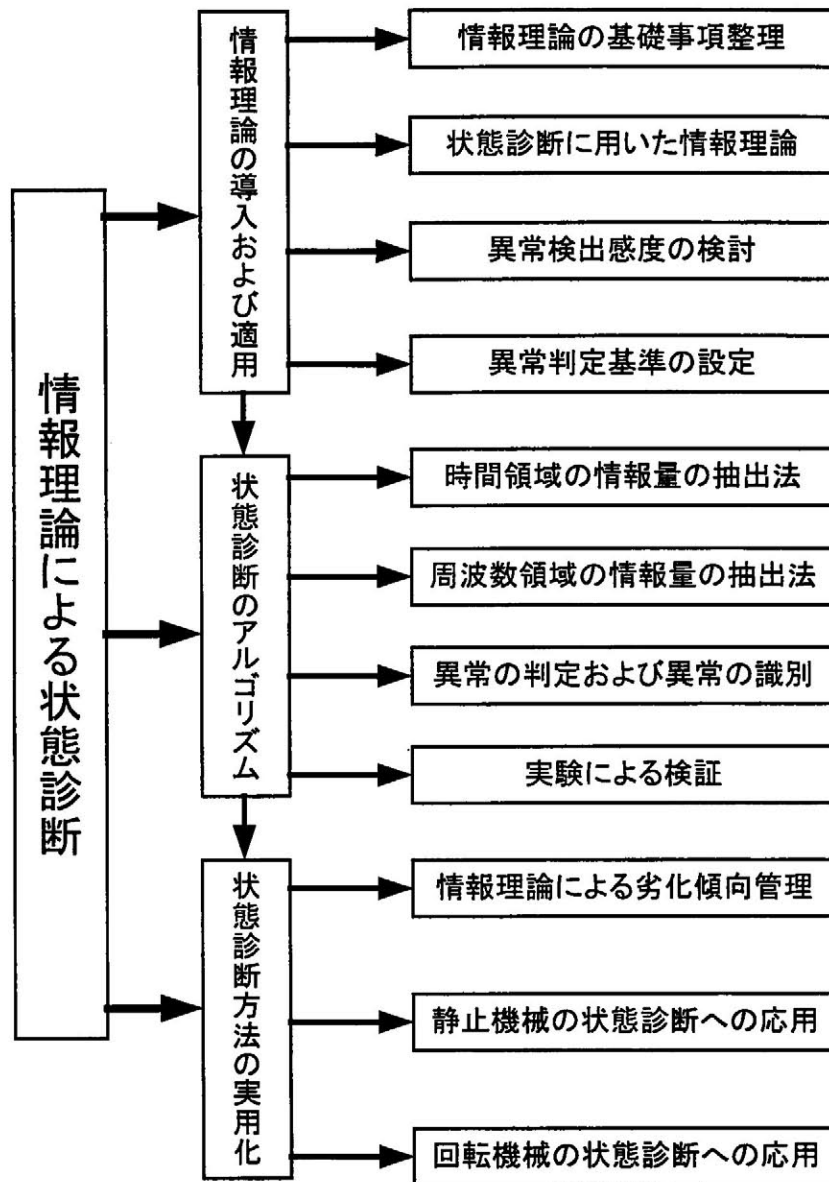


図 1.1 論文の構成

- (1) KI と ID により振動信号, 音響信号および AE 信号などの状態量の特徴抽出が可能であることを理論解析により示した.
 - (2) ID の異常検出感度と異常識別能力が KI と比較して優れていることを理論解析により示した.
 - (3) 情報検定理論に基づいて, ID および KI に対し状態診断のための統一的な判定基準を設定した.
 - (4) 時間領域と周波数領域において, 情報理論による機械設備の簡易診断方法と精密診断方法を確立した.
 - (5) 多変量情報理論 (MKI) による多変量状態診断方法を提案し, 二つ以上の信号を用いた状態診断を実現した.
 - (6) 情報理論による機械設備の劣化傾向管理方法を提案した.
- の 6 項である.

第2章 情報理論による状態診断理論

2.1 はじめに

振動波形の有次元特徴パラメータによる設備状態診断方法は広く実用化されている。しかし、1つの信号の有次元特徴パラメータはその信号の持つ情報の一部、すなわち、測定時点の状態量の「大きさ」だけを定量化したものであり、信号の「形」情報や生産設備の個性情報が考慮されていない。したがって、有次元特徴パラメータは得られた情報を有効に活用しているとは言えず、このため、有次元特徴パラメータによる状態診断では

- (1) 機械の負荷と運転状況が変わると、振動の大きさも変わるため、設備が正常であるにもかかわらず異常と診断してしまう場合がある
- (2) 機械の仕様が異なると、振動や音響のレベルも異なるため、統一的な判定基準の設定は不可能である。
- (3) 特徴パラメータは振動信号の持つ情報の一部を定量化したものであり、得られた情報を有効に活用することができない。

などといった問題点がある。このため、これらの欠点を克服するためには、生産設備から測定した信号の「大きさ」情報や「形」情報および生産設備の個性情報を併せて抽出することができる新しい診断理論が必要となる。

そこで、本章では、設備状態情報を総合的に反映する振動、音響や AE 信号などの波形の振幅確率密度分布に着目し、分布間の情報を効率的に抽出するカルバック-ライブラー情報量 (Kullback-Leibler Information: KI) およびインフォメーションダイバージェンス (Information Divergence: ID) を用いた、新しい診断理論を提案する。この診断理論は、生産設備の点検時の「テスト状態」と生産設備の正常状態、あるいは「参照状態」との「距離」測度を情報理論に基づいて測ることにより、生産設備の異常の判定と識別を行う。主な内容は、

- (1) 情報理論による状態診断で必要となる情報理論をまとめるとともに、設備状態の定量化のための情報測度について述べる。

- (2) カルバック-ライブラー情報量 (Kullback-Leibler Information: KI) とインフォメーションダイバージェンス (Information Divergence: ID) による, 振動信号, 音響信号および AE 信号などの確率密度関数の特徴抽出方法を示す.
 - (3) 正規分布に従う信号に対し, ID の異常検出感度と識別能力が KI と比較して優れていることを理論解析により明らかにする.
 - (4) 点検時の「テスト状態」が正常か否かを判定するため, 情報検定理論に基づいて判定基準を設定する.
 - (5) 多変量信号解析のため, 多変量情報理論 (Multivariate Kullback-Leibler Information: MKI) を導入し, また, 異常検出のための判定基準を設定する.
- の 5 項である.

2.2 情報理論の要点

2.2.1 情報量とエントロピー

確率 p の事象 E ($P(E) = p$) が実際に生じたことを知らせる情報に含まれている情報量 $I(E)$ は

$$\begin{aligned}
 I(E) &= \log_2 \frac{1}{p} \\
 &= -\log_2 p \quad (\text{bits})
 \end{aligned} \tag{2-1}$$

と定義される. データ通信, 情報処理の分野では, 2 元符号が用いられることが多いため, 底として '2' を採用するのが一般的であるが, 本研究では, 自然対数 e を底として取り扱う.

また, 情報を与えるという過程は, いくつかの生起する可能性の中から 1 つを選択するという操作であり, この操作によってある事象が選択された結果から得られる情報量は式 (2-1) で与えられる. いま, 事象 E_1, E_2, \dots, E_n からなる事象系 E があり, そのうちの 1 つの事象が選択されるような選択操作を考える. 第 1 事象の選択される確率を $P(E_1)$, 一般に第 i 番目の事象の選択される確率を $P(E_i)$ とすると, 第 i 番目の事象が実際に選択されたとき得られる情報量は $I(E_i) = -\log P(E_i)$ であり, このようなことが起こる確率は $P(E_i)$ であるから, この選択によってわれわれの得る情報量の期待値, すなわち, 平均情報量は

$$\begin{aligned}
 H(E) &= \sum_{i=1}^n P(E_i) I(E_i) \\
 &= -\sum_{i=1}^n P(E_i) \log P(E_i)
 \end{aligned} \tag{2-2}$$

となる. この $H(E)$ は情報源 E のエントロピー (entropy) といわれる.

次にエントロピーの持つ性質について考えてみる。いま、 n 個の事象が互いに独立に発生する独立生起情報源があり、それぞれの事象の生起する確率を p_1, p_2, \dots, p_n ($\sum_{i=1}^n p_i = 1$) とする。また、この独立生起情報源のエントロピーを

$$H(p_1, p_2, \dots, p_n) = -\sum_{i=1}^n p_i \log p_i \quad (2-3)$$

で表すことにする。この $H(p_1, p_2, \dots, p_n)$ はエントロピー関数 (entropy function) と呼ばれる。このときエントロピー関数 H はつぎのような性質を持つ[6]。

(1) 連続性：エントロピー関数 H は $p_i (i=1, 2, \dots, n)$ に関して連続関数である。

(2) 非負性： $H(p_1, p_2, \dots, p_n) \geq 0$

エントロピーの最大値：エントロピーの最大値は $\log n$ である。すなわち

$$H(p_1, p_2, \dots, p_n) \leq \log n \quad (2-4)$$

となる。なお上式において等号が成立するのはすべての p_i が

$$p_i = \frac{1}{n} \quad (i=1, 2, \dots, n) \quad (2-5)$$

のときである。

(3) 加法性：ある事象 i がさらに二つの事象 i_1 および i_2 に分割される場合には、次の関係が成立する (ただし、 $p_i = p_{i1} + p_{i2}$)。

$$\begin{aligned} H(p_1, p_2, \dots, p_{i-1}, p_{i1}, p_{i2}, p_{i+1}, \dots, p_n) \\ = H(p_1, p_2, \dots, p_{i-1}, p_i, p_{i+1}, \dots, p_n) + p_i H\left(\frac{p_{i1}}{p_i}, \frac{p_{i2}}{p_i}\right) \end{aligned} \quad (2-6)$$

(4) 対称性：変数 p_1, p_2, \dots, p_n の任意順列に対して、不変である。

$$H(p_1, p_2, \dots, p_n) = H(p_{k(1)}, p_{k(2)}, \dots, p_{k(n)}) \quad (2-7)$$

が成立する。

2.2.2 情報測度

機械設備から測定した振動や音響データなどの状態変数が持つ情報量やデータとデータとの間の相違の情報量は、機械設備の状態識別、状態診断に対して有効である。そこで、以下に、種々の情報量をまとめる。

(A) フィッシャー (R. A. Fisher) 情報量

情報量 (Amount of information) の概念を導入したフィッシャーが定義した、統計理論において最も有名な情報量である[7]。標本 X が密度関数 $f(x, \theta)$ を持つ確率分布に従う確率変数、ただし、 θ が未知母数 (定数) とするとき、 X の θ に関するフィッシャー情報量 $FI(\theta)$ は

$$\begin{aligned}
FI(\theta) &= E \left\{ \frac{\partial}{\partial \theta} \log f(x, \theta) \right\}^2 \\
&= -E \left\{ \frac{\partial^2}{\partial \theta^2} \log f(x, \theta) \right\}
\end{aligned} \tag{2-8}$$

と定義される。この量は統計的推測の理論において種々の意味を持つ。

フィッシャーの情報量 $FI(\theta)$ は母数 θ の関数であり、 $FI(\theta_0)$ は $\theta = \theta_0$ のとき、標本 X が θ の他の値に対して θ_0 をどの程度はっきりと指示するかを示す量と考えることができる。いま、 θ の二つの値 θ_0 と θ_1 を固定すると、この二つの値が X によってどの程度はっきりと区別されるかは、 $\theta = \theta_0$ のときと $\theta = \theta_1$ のときの X の分布の相違によって、すなわち、二つの密度関数 $f(x, \theta_0)$ と $f(x, \theta_1)$ の違いの大きさによって決まる。逆にいえば X の持つ情報の大きさは、二つの分布の相違の程度、すなわち、その「距離」によって表すことができる。

(B) 分布間の「距離」測度

二つの分布の密度関数を $f_1(x)$ 、 $f_2(x)$ とするとき、その間の「距離」を表す測度は以下のように定義することができる[16].

(1) コルモゴロフ (Kolmogorov) 変動距離

$$K_\alpha = \left[\int |f_1(x) - f_2(x)|^\alpha dx \right]^{1/\alpha} \tag{2-9}$$

(2) F-ダイバージェンス (F-Divergence)

$$H_f = \int F \left(\frac{f_1(x)}{f_2(x)} \right) f_1(x) dx \tag{2-10}$$

ここで、 F は実数値関数かつ、区間 $[0, +\infty]$ で凸状の関数である。

(3) チェルノフ (Chernoff) 距離

$$C_\alpha = -\log \int f_1(x)^{1-\alpha} f_2(x)^\alpha dx \tag{2-11}$$

ここで、 $0 < \alpha < 1$ 、 $\alpha = \frac{1}{2}$ のとき、式(2-11)はブハタチャルヤ (Bhattacharyya) 距離という。

(4) カルバック-ライブラー (Kullback-Leibler) 情報量

$$KI(f_1 : f_2) = \int f_1(x) \log \frac{f_1(x)}{f_2(x)} dx \tag{2-12}$$

2.3 診断用情報測度の導入

2.3.1 KI の定義と性質

真の離散分布 $p = [p_1, p_2, \dots, p_n]$ ($\sum_{i=1}^n p_i = 1$) と離散分布モデル $q = [q_1, q_2, \dots, q_n]$ ($\sum_{i=1}^n q_i = 1$) があるとき、事象 ω_i が起こる情報量は、それぞれ、 $-\log p_i$ と $-\log q_i$ である。

情報量 $-\log q_i$ と $-\log p_i$ の差のエントロピー、あるいは $\log \frac{p_i}{q_i}$ という値をとる確率変数

$\log \frac{p}{q}$ の期待値

$$\begin{aligned} KI(p:q) &= E \log \frac{p}{q} \\ &= \sum_{i=1}^n p_i \log \frac{p_i}{q_i} \end{aligned} \quad (2-13)$$

はモデルの離散分布 q に関する真の離散分布 p のカルバック-ライブラー情報量 (Kullback-Leibler Information: KI) と呼ばれる[4][7]。この KI を二つの分布の近さを測る基準として採用する。すなわち、 $KI(p:q)$ の値が小さく 0 に近いほどモデルの分布 q は真の分布 p に近いと見なすことができる。

確率論的な観点から、KI は二つの確率密度関数の‘距離’を表す指標として用いることができることがわかったが、さらに機械工学分野に KI を扱うための議論を進める。推論上の便利のため、連続分布のカルバック-ライブラー情報量 (Kullback-Leibler Information: KI) の定義を述べる。

標本空間 X に対し、参照分布と識別しようとするテスト分布をそれぞれ $f_1(x), f_2(x)$ とする。テスト分布に対する参照分布の KI は

$$\begin{aligned} KI(f_1:f_2) &= E_x \log \frac{f_1(x)}{f_2(x)} = \int_{-\infty}^{\infty} f_1(x) \log \frac{f_1(x)}{f_2(x)} dx \\ &= \int_{-\infty}^{\infty} f_1(x) \{ \log f_1(x) - \log f_2(x) \} dx \end{aligned} \quad (2-14)$$

と定義される。この KI は幾何学的な距離と異なり、一般に非負性、非対称性などといった性質を持つ。

次に、この KI の設備異常の検出感度について述べる。KI の定義式を書き換えると

$$KI(f_1:f_2) = \int_{-\infty}^{\infty} f_1(x) \left\{ \log \frac{1}{f_2(x)} - \log \frac{1}{f_1(x)} \right\} dx \quad (2-15)$$

となる。この式はテスト分布と参照分布の情報量の差の期待値を参照分布で取るものであるが、設備状態診断に対しては、参照分布に表れない、すなわち $f_1(x)$ の 0 に近い部分の情報を表せないため、情報の欠落が生じる。また、KI の定義の $f_1(x)$ と $f_2(x)$ を入れ換えた

$$\begin{aligned} KI(f_2 : f_1) &= E_x \log \frac{f_2(x)}{f_1(x)} = \int_{-\infty}^{\infty} f_1(x) \log \frac{f_2(x)}{f_1(x)} dx \\ &= \int_{-\infty}^{\infty} f_2(x) \left\{ \log \frac{1}{f_1(x)} - \log \frac{1}{f_2(x)} \right\} dx \end{aligned} \quad (2-16)$$

は参照分布とテスト分布の情報量の差の期待値をテスト分布で取るものであるが、設備状態診断に対しては、テスト分布は強調されるが、 $f_2(x)$ の 0 に近い部分の参照分布の情報を表せないため情報の欠落が生じるといった欠点がある。

2.3.2 ID の定義と性質

診断では、正常分布と異常分布の差が重要である。前節の検討により、KI は参照分布とテスト分布の情報量の差の期待値を参照分布を用いて求めるため情報の欠落が生じる。この欠点を克服するために、両分布における情報量の差の期待値を両分布の差を用いて求めるインフォメーションダイバージェンス (Information Divergence: ID) を導入する。これは

$$\begin{aligned} ID(f_1 : f_2) &= E_x \log \frac{f_1(x)}{f_2(x)} + E_x \log \frac{f_2(x)}{f_1(x)} \\ &= \int_{-\infty}^{\infty} f_1(x) \log \frac{f_1(x)}{f_2(x)} dx + \int_{-\infty}^{\infty} f_2(x) \log \frac{f_2(x)}{f_1(x)} dx \\ &= \int_{-\infty}^{\infty} (f_1(x) - f_2(x)) \log \frac{f_1(x)}{f_2(x)} dx \\ &= \int_{-\infty}^{\infty} (f_1(x) - f_2(x)) \left\{ \log \frac{1}{f_2(x)} - \log \frac{1}{f_1(x)} \right\} dx \end{aligned} \quad (2-17)$$

と定義される[3]。この ID は非負性、対称性などといった性質を持つ。

2.3.3 多変量 KI および多変量 ID

これまで、1 変量の確率密度関数を識別するための KI と ID を定義したが、ここでは、変量が 2 つ以上の確率密度関数の識別のための多変量カルバック-ライブラー情報量 (Multivariate Kullback-Leibler Information: MKI) を定義する。 k 変量の参照分布と k 変量のテスト分布を、それぞれ $f_1(x_1, x_2, \dots, x_k)$ 、 $f_2(x_1, x_2, \dots, x_k)$ とすると、MKI は

$$\begin{aligned}
MKI(f_1 : f_2) &= E_x \log \frac{f_1(x_1, x_2, \dots, x_k)}{f_2(x_1, x_2, \dots, x_k)} \\
&= \int_{-\infty}^{\infty} f_1(x_1, x_2, \dots, x_k) \log \frac{f_1(x_1, x_2, \dots, x_k)}{f_2(x_1, x_2, \dots, x_k)} dx_1 dx_2 \dots dx_k \quad (2-18)
\end{aligned}$$

と定義される。この MKI は KI と同様に、一般に、非負性、非対称性などといった性質を持つ。

また、多変量インフォメーションダイバージェンス (Multivariate Information Divergence: MID) は

$$\begin{aligned}
MID(f_1 : f_2) &= E_x \log \frac{f_1(x_1, x_2, \dots, x_k)}{f_2(x_1, x_2, \dots, x_k)} + E_x \log \frac{f_2(x_1, x_2, \dots, x_k)}{f_1(x_1, x_2, \dots, x_k)} \\
&= \int_{-\infty}^{\infty} (f_1(x_1, x_2, \dots, x_k) - f_2(x_1, x_2, \dots, x_k)) \log \frac{f_1(x_1, x_2, \dots, x_k)}{f_2(x_1, x_2, \dots, x_k)} dx_1 dx_2 \dots dx_k \quad (2-19)
\end{aligned}$$

と定義される。この MID は ID と同様に、一般に、非負性、対称性などといった性質を持つ[3]。しかし、情報検定理論により、MID の推定値は漸近的に非心 χ^2 分布に従うため、判定基準の設定が複雑となり、状態診断への実用が困難である。このため、多変量の情報量を用いた診断には多変量カルバック-ライブラー情報量 MKI についてのみ述べる。

2.4 ID と KI の感度の検討

ID と KI は、いずれも二つの分布の推定と識別に用いられるが、ここでは、最も一般的な分布である正規分布に対する ID と KI の識別感度を検討する。

2.4.1 正規分布の KI と ID

はじめに、正規分布の KI と ID を平均 μ および分散 σ を用いて表す。参照状態の確率密度分布 (分布 1) およびテスト状態の確率密度分布 (分布 2) が正規分布に従うと仮定する。両分布 $f_i(x)$ を $N(\mu_i, \sigma_i^2)$ 、ただし、 $i=1, 2$ 、すなわち

$$f_i(x) = \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-(x-\mu_i)^2/2\sigma_i^2} \quad (2-20)$$

とすると、両分布の KI は式 (2-15) により

$$KI(f_1 : f_2) = \int_{-\infty}^{\infty} f_1(x) \log f_1(x) dx - \int_{-\infty}^{\infty} f_1(x) \log f_2(x) dx \quad (2-21)$$

となる。ここで、 X の二次モーメント $E_X(X - \mu_2)^2 = \sigma_1^2 + (\mu_1 - \mu_2)^2$ を使うと、

$$\begin{aligned}\int_{-\infty}^{\infty} f_2(x) \log f_1(x) dx &= \int_{-\infty}^{\infty} \left\{ -\frac{1}{2} \log 2\pi\sigma_2^2 - \frac{(x-\mu_2)^2}{2\sigma_2^2} \right\} \frac{1}{\sqrt{2\pi\sigma_1^2}} e^{-(x-\mu_1)^2/2\sigma_1^2} dx \\ &= -\frac{1}{2} \log 2\pi\sigma_2^2 - \frac{\sigma_1^2 + (\mu_1 - \mu_2)^2}{2\sigma_2^2}\end{aligned}$$

となり，特に， $\sigma_1^2 = \sigma_2^2, \mu_1 = \mu_2$ とおくと，

$$\int_{-\infty}^{\infty} f_1(x) \log f_1(x) dx = -\frac{1}{2} \log 2\pi\sigma_1^2 - \frac{1}{2} \quad (2-22)$$

が得られる。したがって式 (2-21) は式(2-22)より，

$$KI(f_1 : f_2) = \frac{1}{2} \left\{ \log \frac{\sigma_2^2}{\sigma_1^2} + \frac{\sigma_1^2 + (\mu_1 - \mu_2)^2}{\sigma_2^2} - 1 \right\} \quad (2-23)$$

となる。

特に，参照分布とテスト分布の分散が等しい，すなわち， $\sigma_1^2 = \sigma_2^2 = \sigma^2$ と仮定すると，式 (2-24) は

$$KI(f_1 : f_2; \mu) = \frac{1}{2} \frac{(\mu_1 - \mu_2)^2}{\sigma^2} \quad (2-24)$$

となる。参照分布とテスト分布の平均が等しい，すなわち， $\mu_1 = \mu_2 = \mu$ と仮定すると，式 (2-24) は

$$KI(f_1 : f_2; \sigma^2) = \frac{1}{2} \log \frac{\sigma_2^2}{\sigma_1^2} + \frac{1}{2} \frac{\sigma_1^2}{\sigma_2^2} - \frac{1}{2} \quad (2-25)$$

となる。このため， $KI(f_1 : f_2)$ は式 (2-25) と式 (2-26) より

$$KI(f_1 : f_2) = KI(f_1 : f_2; \mu) + KI(f_1 : f_2; \sigma^2) \quad (2-26)$$

となる。さらに，参照分布が標準正規分布，すなわち $\mu_1 = 0, \sigma_1^2 = 1$ とすると， KI は

$$KI(f_1 : f_2) = \frac{1}{2} \left(\log \sigma_2^2 + \frac{1 + \mu_2^2}{\sigma_2^2} - 1 \right) \quad (2-27)$$

より求められる。

また，参照分布とテスト分布の ID は式 (2-17) により

$$ID(f_1 : f_2) = KI(f_1 : f_2) + KI(f_2 : f_1)$$

$$\begin{aligned}&= \frac{1}{2} \left\{ \log \frac{\sigma_2^2}{\sigma_1^2} + \frac{\sigma_1^2 + (\mu_1 - \mu_2)^2}{\sigma_2^2} - 1 \right\} + \frac{1}{2} \left\{ \log \frac{\sigma_1^2}{\sigma_2^2} + \frac{\sigma_2^2 + (\mu_2 - \mu_1)^2}{\sigma_1^2} - 1 \right\} \\ &= \frac{1}{2} \left\{ \frac{\sigma_1^2 + (\mu_1 - \mu_2)^2}{\sigma_2^2} + \frac{\sigma_2^2 + (\mu_1 - \mu_2)^2}{\sigma_1^2} - 2 \right\}\end{aligned} \quad (2-28)$$

となる。

特に、参照分布とテスト分布の分散が等しい、すなわち、 $\sigma_1^2 = \sigma_2^2 = \sigma^2$ と仮定すると、式 (2-28) は

$$ID(f_1 : f_2; \sigma^2) = \frac{(\mu_1 - \mu_2)^2}{\sigma^2} \quad (2-29)$$

となる。参照分布とテスト分布の平均が等しい、すなわち、 $\mu_1 = \mu_2 = \mu$ と仮定すると、式 (2-28) は

$$ID(f_1 : f_2) = \frac{1}{2} \left\{ \frac{\sigma_1^2}{\sigma_2^2} + \frac{\sigma_2^2}{\sigma_1^2} - 2 \right\} \quad (2-30)$$

となる。このため、 $ID(f_1 : f_2)$ は式 (2-29) と式 (2-30) より

$$ID(f_1 : f_2) = ID(f_1 : f_2; \mu) + ID(f_1 : f_2; \sigma^2) \quad (2-31)$$

となる。さらに、参照分布が標準正規分布、すなわち $\mu_1 = 0, \sigma_1^2 = 1$ とすると、ID は

$$ID(f_1 : f_2) = \frac{1}{2} \left\{ \frac{1 + \mu_2^2}{\sigma_2^2} + \sigma_2^2 + \mu_2^2 - 2 \right\} \quad (2-32)$$

より求められる。

2.4.2 識別感度の検討

KI と ID の識別感度を検討する便ため、式 (2-23)、式 (2-28) を整理する必要がある。ここで、

$$k = \frac{\sigma_2^2}{\sigma_1^2}$$

$$l^2 = \frac{(\mu_1 - \mu_2)^2}{\sigma_1^2}$$

とすると、式 (2-23)、式 (2-28) は

$$KI(f_1 : f_2) = \frac{1}{2} \left\{ \log k + \frac{l^2 - k + 1}{k} \right\} \quad (2-33)$$

$$ID(f_1 : f_2) = \frac{1}{2} \left\{ \frac{(k-1)^2 + l^2(k+1)}{k} \right\} \quad (2-34)$$

となる。ここで、 k は二つの分布のそれぞれの分散の比であり、二つの分布の分散の変化を表す指標である。また、 l は二つの分布の平均差変動率であり、参照分布の標準偏差に対して、二つの分布の平均値の差の変化を表す指標である。なお、参照分布を標準正規分布とすると、これらは、それぞれ、 $k = \sigma_2^2$ 、 $l = \mu_2$ となる。

二つの情報量の分散の比 k および平均差変動率 l に対する感度を検討する。式 (2-33)、式 (2-35) を、 k と l に対して偏微分すると、

$$\begin{aligned} dKI(k,l) &= \frac{\partial KI}{\partial k} dk + \frac{\partial KI}{\partial l} dl \\ &= \frac{(k-l^2-1)}{2k^2} dk + \frac{l}{k} dl \end{aligned} \quad (2-35)$$

$$\begin{aligned} dID(k,l) &= \frac{\partial ID}{\partial k} dk + \frac{\partial ID}{\partial l} dl \\ &= \frac{(k^2-l^2-1)}{2k^2} dk + \frac{(k+1)}{k} l dl \end{aligned} \quad (2-36)$$

となる。本研究ではこれら dKI, dID を、それぞれ ID と KI の全感度と定義する。また、式 (2-33)、式 (2-34) をそれぞれ、 k と l に対して偏微分すると、

$$KI_k = \frac{\partial KI}{\partial k} = \frac{(k-l^2-1)}{2k^2} \quad (2-37)$$

$$ID_k = \frac{\partial ID}{\partial k} = \frac{(k^2-l^2-1)}{2k^2} \quad (2-38)$$

$$KI_l = \frac{\partial KI}{\partial l} = \frac{l}{k} \quad (2-39)$$

$$ID_l = \frac{\partial ID}{\partial l} = \frac{k+1}{k} l \quad (2-40)$$

となる。本研究では、 KI_k, ID_k をそれぞれ k に対する ID と KI の感度、 KI_l, ID_l を l に対する ID と KI の感度と定義する。これら式 (2-37) ~ 式 (2-40) より、 k, l に対する KI と ID の二つの情報量の感度比として

$$A_k = \frac{ID_k}{KI_k} = \frac{k^2-l^2-1}{k-l^2-1} \quad (2-41)$$

$$A_l = \frac{ID_l}{KI_l} = k+1 \quad (2-42)$$

が得られる。

KI_k, ID_k の k に対する変化を図 2.1 に示す。図 2.1 の横軸は分散の比 k であり、縦軸は ID と KI の k に対する感度 (KI_k, ID_k) である。また、 KI_l, ID_l の l に対する変化を図 2.2 に示す。同図の横軸は平均差変動率 l であり、縦軸は ID と KI の l に対する感度 (KI_l, ID_l) である。

図 2.1 に示すように $k > 1$ のとき、すなわち $\sigma_2^2 > \sigma_1^2$ の場合には、 $A_k > 1$ となり、ID の k に対する感度 ID_k は KI_k より高い。また、図 2.2 に示すように $A_l > 1$ が常に成り立つため $ID_l > KI_l$ である。このため、分散一定の場合あるいは $\sigma_2^2 > \sigma_1^2$ の場合には、つねに $dID > dKI$ が成り立ち ID の分布変動に対する感度が高いことがわかる。さらに、回転機械

の異常状態では、一般に $\sigma_2^2 > \sigma_1^2$ となるため、ID の異常検出感度は KI の感度よりも高いといえる。

以上では、ID と KI との異常検出感度を理論的に説明する手法を示すために、信号波形の確率密度分布を正規分布と仮定して検討した。しかし、信号波形が正規分布とならない場合においても、その分布の数式を与えられれば、同様な手法で異常検出感度を理論的に検討することができる。

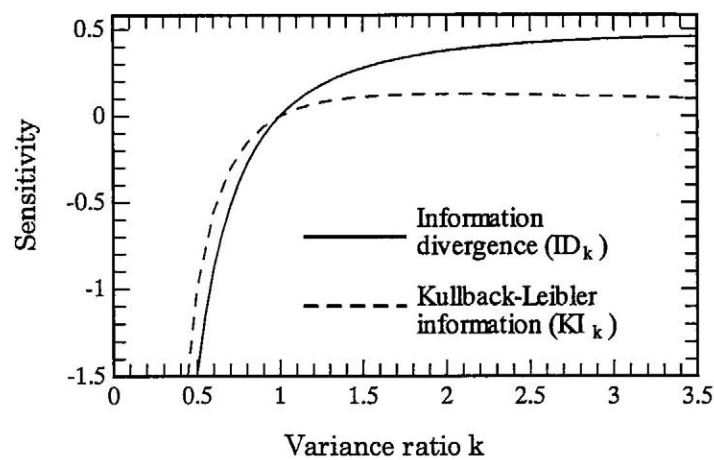


図 2.1 KI と ID の分散比 k に対する検出感度




図 2.2 KI と ID の平均差変動率 l に対する検出感度

2.5 KI と ID の判定基準

正規分布間の KI, ID は, それぞれ式 (2-23), 式 (2-28) により求める. ID と KI の定義および性質により, 二つの確率密度分布が全く同一の場合, すなわち, $f_1(x) = f_2(x)$ とすると, $ID = 0, KI = 0$ となる. また, $f_1(x)$ と $f_2(x)$ の偏移が大きくなると, ID, KI も大きくなる. 二つの分布 $f_1(x), f_2(x)$ が異なる分布であるとみなせる ID および KI は近似的に情報検定理論により決定できる.

n 回の独立観測より得た標本空間を X とし, X を互いに交差しない集合 E_0 と E_1 に分割, すなわち, $E_0 \cap E_1 = 0, X = E_0 \cup E_1$ とする. あるサンプル点を x とすると,

帰無仮説 $H_0: x \in E_0$

対立仮説 $H_1: x \in E_1$

に対して, 第 1 種のエラー α を $\text{Prob}(x \in E_1 | H_0)$, 第 2 種のエラー β を $\text{Prob}(x \in E_0 | H_1)$ とする.

KI に対して,

$$\begin{aligned} KI(f_1: f_2; O_n) &\geq R_{KI}(\alpha, \beta) \\ &= \beta \log \frac{\beta}{1-\alpha} + (1-\beta) \log \frac{1-\beta}{\alpha} \end{aligned} \quad (2-43)$$

であれば, H_1 を採択する. ここで, O_n は n 回独立観測の 1 つの標本を表し, $R_{KI}(\alpha, \beta)$ を KI の判定基準という.

また, ID に対して,

$$\begin{aligned} ID(f_1: f_2; O_n) &\geq R_{ID}(\alpha, \beta) \\ &= 2 \left[\frac{\alpha + \beta}{2} \log \frac{(\alpha + \beta)/2}{1 - (\alpha + \beta)/2} + \left(1 - \frac{\alpha + \beta}{2}\right) \log \frac{1 - (\alpha + \beta)/2}{(\alpha + \beta)/2} \right] \end{aligned} \quad (2-44)$$

であれば, H_1 を採択する[3]. この $R_{ID}(\alpha, \beta)$ を ID の判定基準という.

$R_{KI}(\alpha, \beta)$ と $R_{ID}(\alpha, \beta)$ の α に対する変化を図 2.3, β に対する変化を図 2.4 に示す. $\alpha \geq 1 - \beta$ のとき, $R_{KI}(\alpha, \beta)$ と $R_{ID}(\alpha, \beta)$ は単調減少関数であり, また, $\alpha < 1 - \beta$ のときには, $R_{KI}(\alpha, \beta)$ と $R_{ID}(\alpha, \beta)$ は単調増加関数である. 図 2.3 のように, β を一定として α が大きくなると, $R_{KI}(\alpha, \beta), R_{ID}(\alpha, \beta)$ は小さくなり, 判定基準が厳しくなる. また, 図 2.4 のように, α を一定として β が大きくなると, $R_{KI}(\alpha, \beta), R_{ID}(\alpha, \beta)$ が小さくなるため, 判定基準が厳しくなる.




図 2.3 ID と KI の判定基準値の第 1 種のエラー α に対する変化

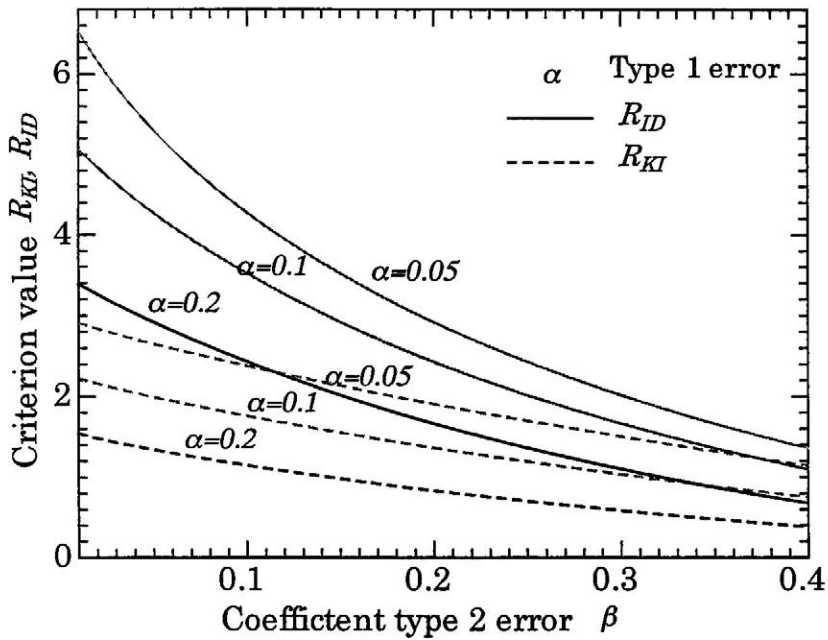


図 2.4 ID と KI の判定基準値の第 2 種のエラー β に対する変化

2.6 正規分布の MKI および判定基準

診断精度の向上のためには、振動、音響や AE などの複数の測定データに基づいて異常を検出することが望ましい。このためには、複数の状態変数の情報を統合した状態診断方法、すなわち、多変量状態診断方法が必要となる。そこで、本節では多変量正規分布の MKI およびその判定基準について述べる。

2.6.1 正規分布の MKI

k 変量の参照分布（分布 1）と k 変量のテスト分布（分布 2）がそれぞれ正規分布に従うと仮定し、両分布 $f_i(x_1, x_2, \dots, x_k)$, $i=1, 2$ を $N(\mu_i, \Sigma_i)$ とすると、

$$f_i(x_1, x_2, \dots, x_k) = \frac{1}{|2\pi\Sigma_i|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu_i)' \Sigma_i^{-1} (x - \mu_i)\right) \quad (2-45)$$

となる。ここで、 $\mu_i' = (\mu_{i1}, \mu_{i2}, \dots, \mu_{ik})$ は k 変量の平均値のベクトル、 $\Sigma_i = (\sigma_{ijs})$, $(j, s=1, 2, \dots, k)$ は k 変量の共分散マトリクスである。ここで、

$$\log \frac{f_1(x_1, x_2, \dots, x_n)}{f_2(x_1, x_2, \dots, x_n)} = \frac{1}{2} \log \frac{|\Sigma_2|}{|\Sigma_1|} - \frac{1}{2} \text{tr} \Sigma_1^{-1} (x - \mu_1)(x - \mu_1)' + \frac{1}{2} \text{tr} \Sigma_2^{-1} (x - \mu_2)(x - \mu_2)'$$

を使うと、二つの k 変量分布の MKI は式 (2-18) により、

$$\begin{aligned} MKI(f_1 : f_2) &= \int f_1(x_1, x_2, \dots, x_k) \log \frac{f_1(x_1, x_2, \dots, x_k)}{f_2(x_1, x_2, \dots, x_n)} dx_1 dx_2 \dots dx_k \\ &= \frac{1}{2} \log \frac{|\Sigma_1|}{|\Sigma_2|} + \frac{1}{2} \text{tr} \Sigma_2 (\Sigma_1^{-1} - \Sigma_2^{-1}) + \frac{1}{2} \text{tr} \Sigma_1^{-1} (\mu_2 - \mu_1)(\mu_2 - \mu_1)' \end{aligned} \quad (2-46)$$

となる。ここで、 tr はマトリクスのトレース（対角和）である。

k 変量参照分布と k 変量テスト分布の共分散マトリクスが等しいと仮定し、 $\Sigma_1 = \Sigma_2 = \Sigma$ とすると、式 (2-46) は

$$\begin{aligned} MKI(f_1 : f_2; \mu) &= \frac{1}{2} \text{tr} \Sigma^{-1} (\mu_1 - \mu_2)(\mu_1 - \mu_2)' \\ &= \frac{1}{2} \text{tr} \Sigma^{-1} \delta \delta' = \frac{1}{2} \delta' \Sigma^{-1} \delta \end{aligned} \quad (2-47)$$

となる。ここで、 $\delta = \mu_1 - \mu_2$ である。式(2-47)に定数 $2k$ を掛けると、

$$MH = 2kKI(f_1 : f_2; \mu) = k\delta' \Sigma^{-1} \delta \quad (2-48)$$

となる。この MH は多変量解析の判別関数としてよく使われているマハラノビス汎距離である。このため、マハラノビス汎距離は MKI の特例であることがわかる。マハラノビス汎距離には前提条件 $\Sigma_1 = \Sigma_2 = \Sigma$ が必要となるが、この条件を必要としない、すなわち、分布形に依存しないため、MKI は機械設備の状態識別あるいは状態診断方法に有効である。

k 変量参照分布と k 変量テスト分布の平均ベクトルが等しいと仮定し、 $\mu_1 = \mu_2, \delta = \mu_2 - \mu_1 = 0$ とすると、式 (2-46) は

$$\begin{aligned} MKI(f_1 : f_2; \Sigma) &= \frac{1}{2} \log \frac{|\Sigma_2|}{|\Sigma_1|} + \frac{1}{2} \text{tr} \Sigma_1 (\Sigma_1^{-1} - \Sigma_2^{-1}) \\ &= \frac{1}{2} \log \frac{|\Sigma_2|}{|\Sigma_1|} - \frac{k}{2} + \frac{1}{2} \text{tr} \Sigma_1 \Sigma_2^{-1} \end{aligned} \quad (2-49)$$

となる。この式 (2-49) から、2 分布の平均ベクトルが等しい場合に、MKI は分布の平均と無関係であることがわかる。

2.6.2 情報量の構成要素 (Components)

独立かつランダム変量に対する $MKI(f_1 : f_2)$ の加法性より、 n 回観測のランダムサンプル O_n に対して、 $MKI(f_1 : f_2; O_n) = nMKI(f_1 : f_2)$ となる。この $MKI(f_1 : f_2)$ は式 (2-46) と等しい。

ある多変量正規分布母体 $N(\mu, \Sigma)$ からの標本 O_n の平均、分散と共分散は異なる分布に従うことが知られている。平均は正規分布 $N(\mu, \frac{1}{n}\Sigma)$ に従い、分散、共分散はウィシャット (Wishart) 分布に従う。平均に関する情報量は式 (2-47) より

$$MKI(f_1 : f_2; \bar{x}) = \frac{1}{2} \log \frac{|\Sigma_2|}{|\Sigma_1|} + \frac{1}{2} \text{tr} \Sigma_1 (\Sigma_2^{-1} - \Sigma_1^{-1}) + \frac{n}{2} \text{tr} \Sigma_2^{-1} \delta \delta' \quad (2-50)$$

となる。式 (2-50) において、サンプルサイズは定数として出るのは平均成分だけ異なるからである。

ウィシャット分布は

$$W(s_{11}, s_{22}, \dots, s_{kk}) = \frac{\left(\frac{1}{2}\right)^{kN/2} |S|^{(N-k-1)} \exp\left(-\frac{1}{2} \text{tr} NS \Sigma^{-1}\right)}{\pi^{k(k-1)/4} |\Sigma|^{N/2} \prod_{\alpha=1}^k \Gamma(N+1-\alpha)/2}$$

である。それで、

$$\log \frac{W_1(s_{11}, s_{22}, \dots, s_{kk})}{W_2(s_{11}, s_{22}, \dots, s_{kk})} = \frac{N}{2} \log \frac{|\Sigma_2|}{|\Sigma_1|} - \frac{N}{2} \text{tr} \Sigma_1^{-1} S + \frac{N}{2} \text{tr} \Sigma_2^{-1} S,$$

より、

$$MKI(f_1 : f_2; S) = \frac{N}{2} \left(\log \frac{|\Sigma_2|}{|\Sigma_1|} + \text{tr} \Sigma_1 (\Sigma_2^{-1} - \Sigma_1^{-1}) \right) \quad (2-51)$$

が得られる。ここで、 S は標本共分散マトリクスの不偏推定値、 $N = n - 1$ は自由度である。式 (2-46)、式 (2-47) を見ると、

$$MKI(f_1 : f_2; O_n) = nMKI(f_1 : f_2) = MKI(f_1 : f_2; \bar{x}) + MKI(f_1 : f_2; S)$$

が成立する。

2.6.3 MKI の判定基準

MKI の定義により、二つの k 変量正規分布が全く同一の場合、すなわち、 $f_1(x_1, x_2, \dots, x_k) = f_2(x_1, x_2, \dots, x_k)$ では、 $MKI(f_1 : f_2) = 0$ となり、また、 $f_1(x_1, x_2, \dots, x_k)$ と $f_2(x_1, x_2, \dots, x_k)$ の偏移が大きくなると MKI も大きくなる。これら二つの k 変量正規分布 $f_1(x_1, x_2, \dots, x_k)$ と $f_2(x_1, x_2, \dots, x_k)$ が異なる分布であるとみなせる MKI は以下の検定により決定できる。

一般化漸近理論により、 $MKI(f_1 : f_2)$ の推定値を $M\hat{K}I(f_1 : f_2)$ とすると、 $2M\hat{K}I(f_1 : f_2)$ は漸近的に自由度 $k + k(k+1)/2$ の χ^2 分布に従う [3]。すなわち、

$$\begin{aligned} \text{帰無仮説 } H_0 : f_1(x_1, x_2, \dots, x_k) &= f_2(x_1, x_2, \dots, x_k) \\ \text{対立仮説 } H_1 : f_1(x_1, x_2, \dots, x_k) &\neq f_2(x_1, x_2, \dots, x_k) \end{aligned}$$

に対して、有意水準を α とすると、

$$2M\hat{K}I(f_1 : f_2) \geq 2R_k(\alpha) = \chi^2\left(\alpha, k + \frac{k(k+1)}{2}\right) \quad (2-52)$$

であれば H_1 を採択する。この $R_k(\alpha)$ を k 変量 MKI の判定基準という。

状態診断では、測定した k 種類の信号、あるいは振動信号より求めた k 種類の特徴パラメータを

$$S = \begin{bmatrix} a_{11} & a_{21} & \cdots & a_{k1} \\ a_{12} & a_{22} & & a_{k2} \\ \vdots & & \ddots & \vdots \\ a_{1n} & a_{2n} & \cdots & a_{kn} \end{bmatrix} \quad (2-53)$$

と表す。この S から求めた平均ベクトルと共分散マトリクスは、それぞれ

$$\mu'_i = (\mu_{i1}, \mu_{i2}, \dots, \mu_{ik}) \quad (2-54)$$

$$\Sigma_i = \begin{bmatrix} \sigma_{i11} & \sigma_{i12} & \cdots & \sigma_{i1k} \\ \sigma_{i21} & \sigma_{i22} & \cdots & \sigma_{i2k} \\ \vdots & & \ddots & \vdots \\ \sigma_{ik1} & \sigma_{ik2} & \cdots & \sigma_{ikk} \end{bmatrix} \quad (2-55)$$

となる。ここで、 $i=1, 2$ はそれぞれ、参照分布とテスト分布を表す。これら参照分布とテスト分布の平均ベクトルと共分散マトリクスと式 (2-46) により $M\hat{K}I(f_1 : f_2)$ を計算することができる。ここで、変量数を 3、有意水準 α を 0.05 とすると、式 (2-52) から判定基準 $R_k(\alpha)$ は

$$R_3(0.05) = \frac{1}{2} \chi^2(0.05, 9) = 8.46 \quad (2-56)$$

となる。すなわち、3 変量の場合では、

$$MK\hat{I}(f_t : f_r) \geq R_3(0.05) = 8.46 \quad (2-57)$$

となると, $f_1(x_1, x_2, \dots, x_k)$ と $f_2(x_1, x_2, \dots, x_k)$ は違う分布であると判定できる. このため, 参照分布が正常状態であれば, テスト分布の状態は異常状態と判定できる.

2.7 まとめ

本章では, 情報理論の設備状態診断への適用に関して,

- (1) KI と ID により, 振動信号, 音響信号および AE 信号などの確率密度関数を求めることができる状態量の特徴抽出が可能であることを理論解析により示した.
- (2) 正規分布に従う信号に対して, ID の異常検出感度と識別能力が KI と比較して優れていることを理論解析により示した.
- (3) 情報検定理論に基づいて, 確率密度分布の情報量による判定基準を設定した.
- (4) 多変量状態診断のため多変量情報理論を導入し, また, 多変量正規分布の情報量による判定基準を設定した.

第3章 時系列信号の振幅確率密度情報量を用いた状態診断

3.1 はじめに

振動信号や音響信号，AE 信号の特徴パラメータによる機械設備状態診断は広く実用化されている。しかし，この特徴パラメータは信号波形の持つ情報の一部を定量化したものであり，得られた情報を有効に活用しているとは言えない。本章では，測定した信号の持つ情報の一部を定量化した特徴パラメータよりも，設備状態を総合的に反映する信号波形の確率密度関数に着目し，正常状態とテスト状態などの二つの確率密度関数の相違，すなわち‘距離’を測ることにより機械設備の状態識別，状態診断を行う。本章では，前章の理論解析に基づいて，分布間の情報を効率的に抽出する情報量である ID および KI による機械設備の状態診断方法を提案する。

本章の目的は

- (1) 情報検定理論に基づいて ID と KI に統一的な判定基準を設定し，時間領域の簡易診断方法を確立する。
- (2) パターン認識の手法を用いた時間領域の精密診断方法を確立する
- (3) ID の異常検出感度と異常識別能力が KI と比較して優れていることを実験により確認する。
- (4) 歯車装置と軸受の状態診断に対して，本方法の有効性を実験により検証する。

の 4 項である。

3.2 振幅確率密度関数の情報量の抽出

機械設備の状態識別，状態診断では，実測した振動信号や音響信号，AE 信号などに基づいて設備状態の正常・異常を判定し，さらに，異常の場合には異常種類の識別を行う。

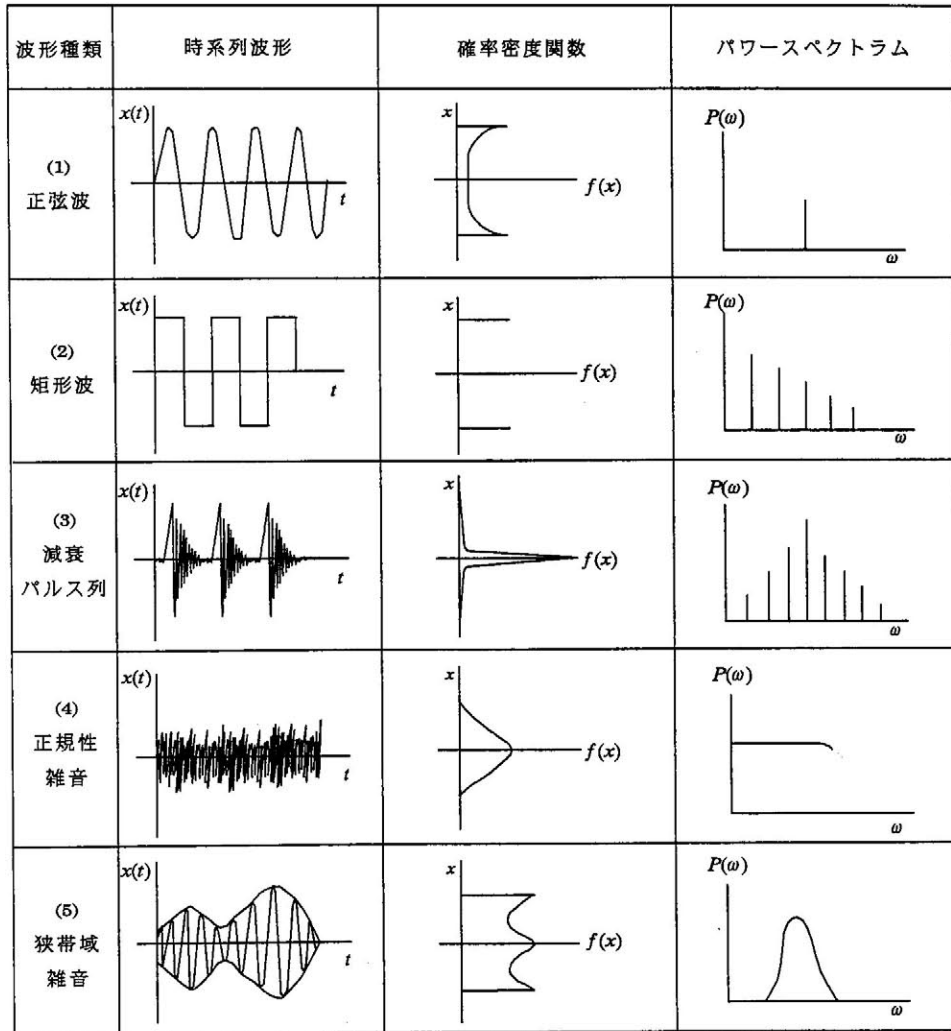


図 3.1 信号の確率密度関数とパワースペクトラム[2]

一般に機械設備の状態が変化すると、その振動信号や音響信号、AE 信号の波形の振幅確率密度関数も変化する。代表的な時系列信号とその確率密度関数およびパワースペクトラムを図 3.1 に示す。同図に示されるような時系列信号の種類に伴って変化する確率密度関数の情報量を用いて状態診断を行う。

3.2.1 時系列信号の振幅確率密度関数

一般に時間領域において、信号波形の統計的性質は、その確率密度関数から得ることができる。図 3.2 に示す信号波形において、振動の振幅が x と $x + \Delta x$ の間に存在する確率は

$$P(x) = \frac{\Delta t_1 + \Delta t_2 + \dots + \Delta t_n}{T}$$

となる。この $P(x)$ は時間率と呼ばれる。

正規性の定常不規則信号の場合には、観測時間を十分大きく取り、振幅の区間 Δx を小さくすると、 $P(x)$ は一定値に近づき、

$$f(x) = \lim_{\substack{T \rightarrow \infty \\ \Delta x \rightarrow 0}} \frac{\Delta t_1 + \Delta t_2 + \dots + \Delta t_n}{T} \times \frac{1}{\Delta x} = \lim \frac{\sum \Delta t_i}{T \Delta x} \quad (3-1)$$

となる。この $f(x)$ は信号波形の振幅確率密度関数と呼ばれる[3]。

この手法は信号波形 x が連続関数である場合の確率密度関数の求め方であるが、実際に測定される信号は離散信号 $x_i, (i=1 \sim N)$ である。このため、信号波形の幅を m 等分し、それぞれの区間 $[x, x + \Delta x]$ における確率密度関数を

$$p(x) = \frac{n_i}{N} \frac{1}{\Delta x} \quad (3-2)$$

より求める。ただし、 n_i は区間 $[x, x + \Delta x]$ におけるサンプル点の存在数であり、この n_i より

度数分布 $\{n_1, n_2, \dots, n_m\}$ $\sum_{i=1}^m n_i = N$ が得られる。等分区間 Δx のなかにサンプル点の存在

する頻度 $p_i = \frac{n_i}{N}$ の全体集合は離散分布 P の近似となる。すなわち、

$$P = \{p_1, p_2, \dots, p_m\} \quad p_i = \frac{n_i}{N}$$

は信号波形の離散分布である。




図 3.2 波形の確率密度関数の求め方




図 3.3 振動信号の確率密度分布

3.2.2 時間領域の ID と KI

機械設備の状態診断のため、図 3.3 に示すように既知の状態で求めた正常および各種異常状態の確率密度関数を「参照分布」、設備点検時に測定した信号から求めた識別しようとする確率密度関数を「テスト分布」と記すと、参照分布とテスト分布との偏移、すなわち、「距離」を測ることにより、設備の異常検出や異常種類の識別が可能となる。

参照分布の密度関数とテスト分布の密度関数をそれぞれ $f_r(x)$, $f_t(x)$ とすると、点検時の情報量は式 (2-14)、式 (2-17) により、それぞれ

$$KI_T(f_r : f_t) = \int_{-\infty}^{\infty} f_r(x) \log \frac{f_r(x)}{f_t(x)} dx \quad (3-3)$$

$$ID_T(f_r : f_t) = \int_{-\infty}^{\infty} (f_r(x) - f_t(x)) \log \frac{f_r(x)}{f_t(x)} dx \quad (3-4)$$

により求められる。

理論解析の場合には、参照分布とテスト分布は連続分布と仮定して議論をする場合が多いが、実際に測定した信号波形から求めた参照分布とテスト分布は離散分布である。このため、測定した信号波形から求めた既知状態の確率密度の離散分布、すなわち参照離散分布を $R = (p_1, p_2, \dots, p_n)$, $\sum_{i=1}^n p_i = 1$ 、点検時の確率密度の離散分布、すなわちテスト離散分布を $T = (q_1, q_2, \dots, q_n)$, $\sum_{i=1}^n q_i = 1$ とすると、式 (2-13) により、離散分布の KI は

$$KI_T(R, T) = \sum_{i=1}^n p_i \log \frac{p_i}{q_i} \quad (3-5)$$

になり、また、同様に離散分布の ID は

$$ID_T(R, T) = \sum_{i=1}^n (p_i - q_i) \log \frac{p_i}{q_i} \quad (3-6)$$

となる。連続分布の KI, ID と離散分布の KI, ID は数学的な表現の形が違っただけで、本質は同じである。

3.2.3 異常検出感度

第 2.4 節では、状態量の確率密度関数が正規分布であるとの仮定に基づいて、ID と KI の異常検出感度について検討した。一般的に、機械設備の状態信号の確率密度分布が正規分布に従うか否かを理論的に証明することが非常に困難である。しかし、回転機械の軸受の場合には、正常状態と異常の初期段階では、その振動波形の確率密度関数は漸近的に正規分布に従うことは D. Dyer らによる実験で示されている[20]。このため、本章で診断対象とした回転軸受に対しては第 2.4 節での解析が直接適用できる。また、一般に、回転機械の異常状態では、その振動信号の実効値は $\sigma_i^2 > \sigma_r^2$ となるため、ID の異常検出感度が KI の感度よりも高いと言える。

なお、機械設備の振動信号や音響信号、AE 信号の振幅確率密度分布が正規分布とならない場合においても、その分布が数式で与えられれば、第 2.4 節に述べた手法により異常検出感度を理論的に検討することができる。また、確率密度分布が式で与えられない場合においても、KI と ID は実測データと式 (3-5)、式 (3-6) によって算出できるため、その感度の確認ができ、状態診断に適用できる。

3.3 状態診断アルゴリズム

3.3.1 異常の検出

稼働中の設備に対する状態診断の第一段階として、測定された振動信号により設備の正常・異常の判定を行う。設備の正常状態（参照状態）と異常状態（テスト状態）の二つの状態の測度としての確率密度関数を $f_r(x)$, $f_t(x)$ とする。これらの二つの確率密度関数を用いた診断における異常判定基準は、状態診断の過検出率と見落し率をそれぞれ α , β とすると、式 (2-43) により、KI に対して判定基準 $R_{KI}(\alpha, \beta)$ は

$$R_{KI}(\alpha, \beta) = \beta \log \frac{\beta}{1-\alpha} + (1-\beta) \log \frac{1-\beta}{\alpha}$$

となる。また、式 (2-44) により ID に対しての判定基準 $R_{ID}(\alpha, \beta)$ は

$$R_{ID}(\alpha, \beta) = 2 \left[\frac{\alpha + \beta}{2} \log \frac{(\alpha + \beta)/2}{1 - (\alpha + \beta)/2} + \left(1 - \frac{\alpha + \beta}{2}\right) \log \frac{1 - (\alpha + \beta)/2}{(\alpha + \beta)/2} \right]$$

となる。

ここで、過検出率 $\alpha = 0.1$ 、見落し率 $\beta = 0.1$ とすると、上式により

$$R_{KI}(\alpha, \beta) = R_{KI}(0.1, 0.1) = 1.758 \quad (3-7)$$

$$R_{ID}(\alpha, \beta) = R_{ID}(0.1, 0.1) = 3.516 \quad (3-8)$$

となる。すなわち、

$$KI(f_r : f_i; O_n) \geq R_{KI}(0.1, 0.1) = 1.758 \quad (3-9)$$

$$ID(f_r : f_i; O_n) \geq R_{ID}(0.1, 0.1) = 3.516 \quad (3-10)$$

となると、 $f_i(x)$ と $f_r(x)$ は完全に違う集合に属するため、テスト分布の状態は異常状態と判定できる。

このため、状態診断では、設備正常時に測定した信号波形から、正常時パターンである参照分布 $f_r(x)$ を求めておき、点検時に測定した信号波形から、点検パターンであるテスト分布 $f_i(x)$ を求め、 $f_i(x)$ と $f_r(x)$ から ID と KI が求まる。さらに、設備の異常検出の要求に従い α, β を設定し、式 (2-43)、式 (2-44) より判定基準値 $R_{KI}(\alpha, \beta), R_{ID}(\alpha, \beta)$ を求め、参照分布とテスト分布間に $ID \geq R_{ID}(\alpha, \beta), KI \geq R_{KI}(\alpha, \beta)$ が成り立てば、設備が異常状態であると判定できる。

3.3.2 異常種類の識別

異常が発生した時には、その対策のために異常の種類を正確に識別する必要がある。このため、種々の異常状態をあらかじめ設定し、あるいは過去の既知の状態での測定データから参照パターン分布を求める。 n 状態の参照パターン空間 X_r を

$$X_r = [X_{r1} \ X_{r2} \ \dots \ X_{rn}]$$

と表し、状態 i を表す X_{ri} の確率密度分布を $f_{ri}(x)$ ($i = 1, \dots, n$) とする。識別対象のテストパターン X_t の確率密度分布を $f_t(x)$ とすると、参照パターン X_{ri} に対してテストパターン X_t の $KI(f_{ri}, f_t)$ と $ID(f_{ri}, f_t)$ はそれぞれ、式(3-5)、(3-6)で求められる。これら KI と ID をベクトルとして

$$KI = [KI_1 \ KI_2 \ \dots \ KI_n]$$

$$ID = [ID_1 \ ID_2 \ \dots \ ID_n]$$

と表し、 KI, ID の最小値を求めると、

$$KI_i = \min(KI) \quad (3-11)$$

$$ID_i = \min(ID) \quad (3-12)$$

となり、この時、参照パターン X_{ri} の分布とテストパターン X_t の分布との「距離」が最も近いと考えられる。このため、参照パターンのうちのテストパターンの KI と ID が最小となる分布 $f_{ri}(x)$ に対応する状態 i をテストパターンの状態と判定することができる。

設備が正常のとき、テスト分布 $f_t(x)$ は正常状態の分布 $f_r(x)$ との「距離」が最も小さく、この同じ状態の KI と ID も異なる状態の KI と ID に比べて小さいはずである。もし、その KI と ID が変化したら、設備の状態も変化したと判定する。図 3.4 に ID による精密診断の流れを示す。KI による精密診断においてもその手順は図 3.4 と同様である。

3.4 実験による検証

3.4.1 実験方法

本診断方法の有効性を検証するために、図 3.5 に示す歯車装置と軸受装置を用いて実験

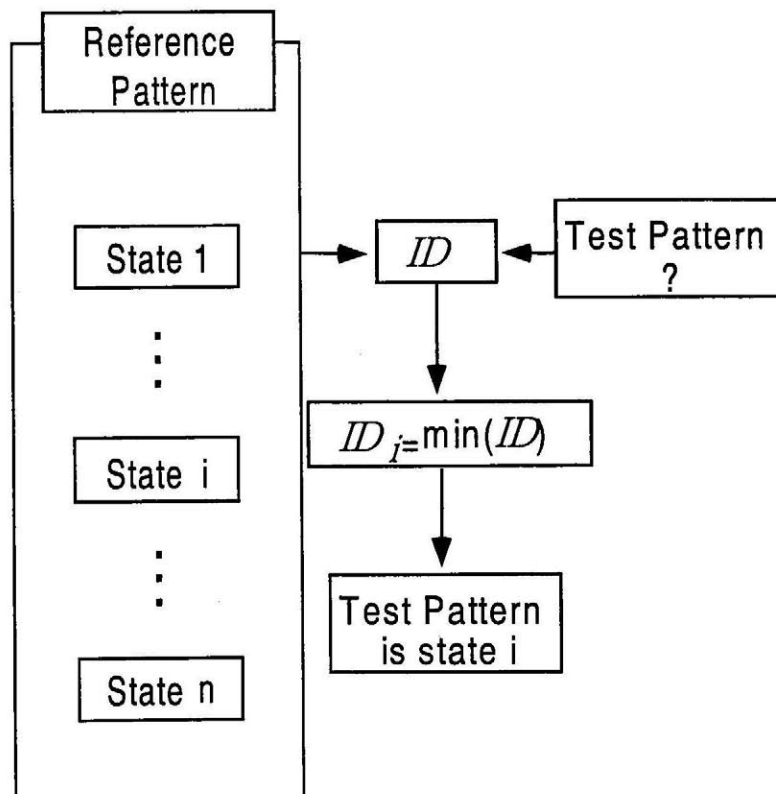


図 3.4 精密診断の流れ

を行う。歯車の診断では、歯車装置を対象とし、回転数を930[rpm]、負荷トルクを3[Nm]とした。また、軸受診断の場合は、図 3.5 の軸受を対象とし、回転数を1700[rpm]、負荷トルクを0とした。なお、どちらの実験においても加速度センサにより振動信号を測定し、アンプ（Anritsu UM-4A）を経て、データレコーダー（TEAC）でアナログ信号を記録した。また、デジタル信号は、FFT アナライザー（小野測器 CF-250）の A/D 変換により得た。




図 3.5 歯車と軸受の実験装置

3.4.2 測定結果

歯車装置の状態としては、正常、偏心、ミスアライメントの3状態を設定した。偏心状態では、駆動歯車の偏心量を0とし、被駆動歯車（ピッチ円半径75[mm]）の回転中心と歯車の中心からの偏心量を0.3[mm]とした。ミスアライメントでは、駆動歯車回転軸と被駆動歯車の回転軸が2軸の中心線による面で 0.15° の角度を持つように設定した。なお、測定時間は2.56[s]、サンプリング周波数は25.6[kHz]とした。

歯車装置で測定された3状態の振動波形を図3.6に示す。

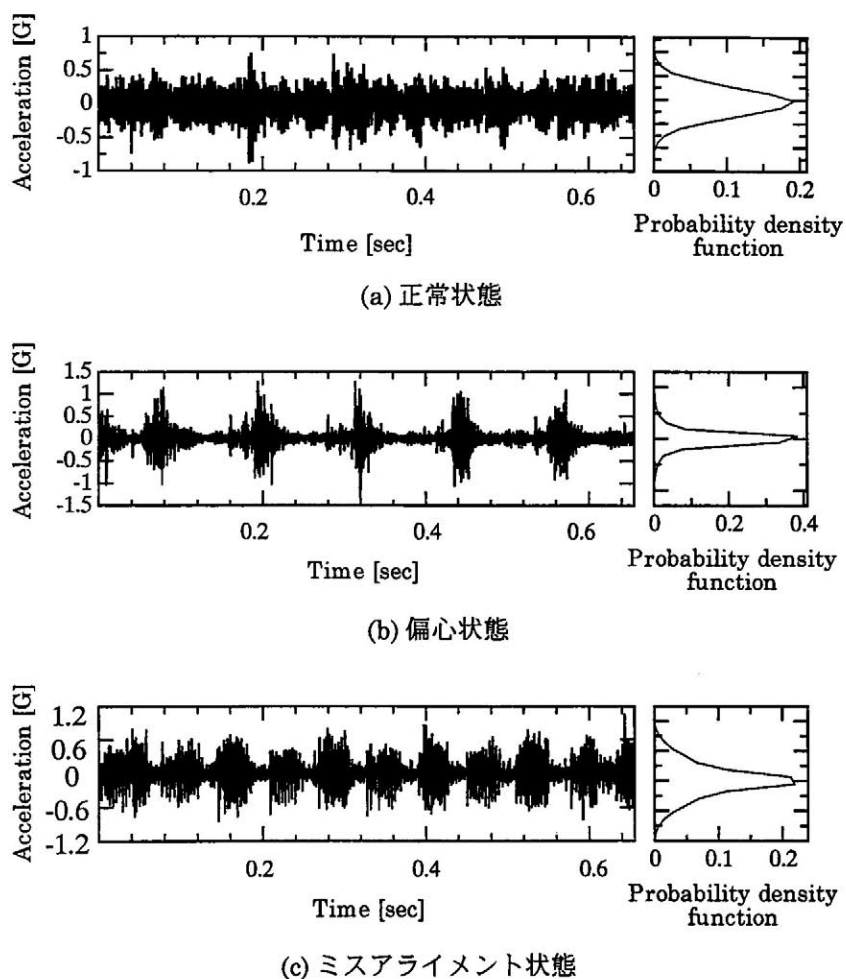


図 3.6 歯車の振動波形

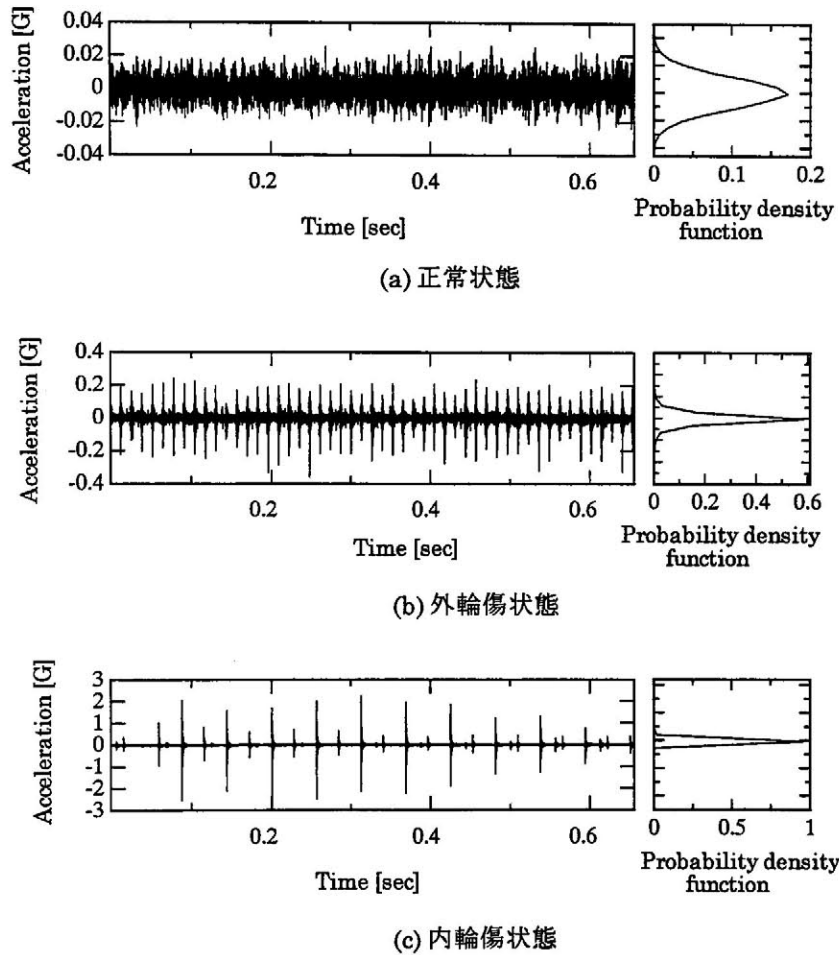


図 3.7 軸受の振動波形

また、軸受装置の状態としては、正常、外輪傷、内輪傷 3 状態を設定した。なお、測定条件は歯車装置と同様に測定時間は 2.56 [s]、サンプリング周波数は 25.6 [kHz]とした。

軸受装置で測定された 3 状態の振動波形を図 3.7 に示す。これらの測定データにより、本診断方法の有効性を検証する。

3.4.3 異常検出感度と検出力の検証

歯車装置の実験結果から求めた 3 タイプの参照パターンに対する 3 タイプのテストパターンの ID および KI を表 3.1 の Information に示す。なお、この表の Normalized には、同じ行の ID と KI をそれぞれ同一な状態の ID と KI の値で割って、参照パターンとテス

トパターンが同じ状態の場合に ID および KI が 1 となるように規格化した値も示している。表 3.1 の規格化した ID および KI から、ID は常に KI よりも大きく、これから ID の感度が KI より常に高いことが確認される。

また、軸受装置の実験結果から求めた ID および KI を表 3.2 に示す。この軸受装置においても、歯車装置と同様に、ID の感度が常に KI よりも高いことがわかる。

表 3.1 歯車の ID と KI

Test		1 Normal condition		2 Eccentricity		3 Misalignment	
		ID	KI	ID	KI	ID	KI
Normal condition	I	0.131	0.059	3.719	1.415	4.172	1.531
	N	1.0	1.0	28.4	24.0	31.8	25.9
Eccentricity	I	3.719	2.203	0.160	0.105	3.284	2.000
	N	23.2	21.0	1.0	1.0	20.5	19.0
Misalignment	I	6.244	4.040	0.653	0.291	0.083	0.055
	N	75.0	73.4	7.9	5.3	1.0	1.0

I:Information, N:Normalized

表 3.2 軸受の ID と KI

Test		1 Normal condition		2 Outer race flaw		3 Inner race flaw	
		ID	KI	ID	KI	ID	KI
Normal condition	I	0.117	0.071	4.574	1.208	6.245	1.669
	N	1.0	1.0	39.1	17.0	53.4	23.5
Outer race flaw	I	4.574	3.110	0.107	0.079	0.653	0.359
	N	42.7	39.4	1.0	1.0	6.1	4.5
Inner race flaw	I	6.245	4.221	0.653	0.291	0.083	0.058
	N	75.2	72.8	7.9	5.0	1.0	1.0

I:Information, N:Normalized

異常検出では、参照パターンとして、正常状態のみをあらかじめ設定する。歯車装置の正常状態の参照パターンに対する正常、偏心、ミスアライメントの 3 状態における ID および KI を図 3.8 に示す。また、同図には、式(3-7)および式(3-8)の判定基準 $R_{KI}(0.1,0.1)$ および $R_{ID}(0.1,0.1)$ も示してある。同図より、KI は異常状態においても異常判定基準 $R_{KI}(0.1,0.1)$ より小さいため、異常を検出することができないことがわかる。しかし、ID は正常状態では異常判定基準 $R_{ID}(\alpha, \beta)$ より小さく、また、異常状態では $R_{ID}(\alpha, \beta)$ よりも大きくなっていることがわかる。したがって、ID により異常検出が可能であることが確認された。

同様に、軸受装置の正常状態の参照パターンに対する、正常、外輪傷、内輪傷の 3 状態における ID および KI を図 3.9 に示す。同図からも、KI は異常状態においても異常判定基準 $R_{KI}(0.1,0.1)$ よりも小さく、異常検出することができないが、ID は正常・異常状態を判定できることがわかる。

3.4.4 異常の識別能力の検証

異常種類の識別の場合には、歯車装置の三つの参照パターンとして、正常、偏心、ミスアライメントを設定した。3 状態の参照パターンに対する 3 状態のテストパターンの ID および KI を表 3.1 に示す。同表と図 3.8 より、テストパターン 2 は偏心の参照パターンとの情報量が一番小さいため、テストパターン 2 は偏心の参照パターンと同じ状態、すなわち偏心状態であると判定できる。同じく、テストパターン 1 と 3 の状態はそれぞれ正常、ミスアライメントと正しく判定できる。

また、軸受装置の三つの参照パターンとして設定した正常、外輪傷、内輪傷の 3 状態の参照パターンに対する三つのテストパターンの ID および KI を表 3.2 に示す。この表 3.2 より、軸受のテストパターン 2 の状態は外輪傷と判定できる。同じく、テストパターン 1 と 3 の状態はそれぞれ正常、内輪傷であると正しく判定できる。

このように、歯車装置と軸受装置の異常種類の識別結果はあらかじめ設定した状態と完全に一致した。したがって、ID は回転機械の精密診断に対して有効であることが確認された。

3.5 まとめ

本章では、従来の振動波形の特徴パラメータによる診断法と KI による診断法の欠点を解決するため、ID による設備状態の簡易診断法と精密診断法を提案した。さらに、ID と KI を用いた異常種類の識別法を示し、実例により本章で提案した方法が有効であることを検証した。主な内容は次のようにまとめられる。

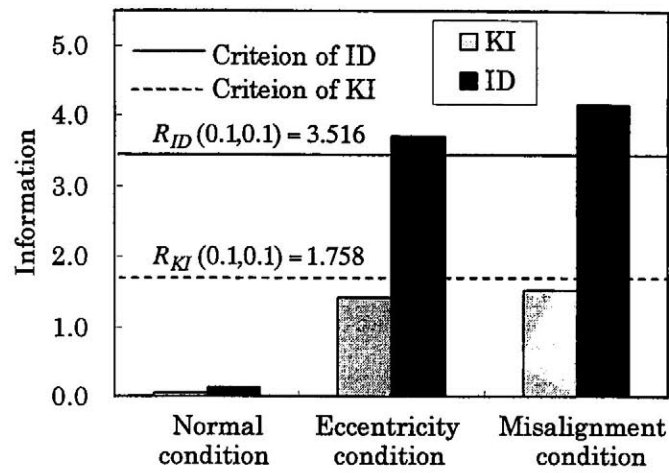


図 3.8 歯車の異常判定




図 3.9 軸受の異常判定

- (1) ID は KI と比較して，異常の検出感度と識別能力が高いことを理論検討により示した。
- (2) 情報検定理論に基づいて回転機械の異常の判定基準を設定し，ID による回転機械の異常識別法を確立した。
- (3) 歯車装置と転がり軸受の実例により，ID による異常検出，すなわち，簡易診断だけでなく，異常種類の識別，すなわち，精密診断も可能なことを検証した。

以上より，本論文で提案した ID による状態診断法は，従来の KI による状態診断方法と比較して，より高感度に異常の検出と識別が可能である。また，1つの手法で簡易診断と精密診断を同時に行うことができる。

第4章 時系列信号のパワースペクトラム情報量を用いた状態診断

4.1 はじめに

一般に、機械設備の簡易診断は時間領域の時系列信号を用いて、また、精密診断は周波数領域のパワースペクトラムを用いて行われる。この周波数領域のパワースペクトラムを用いた状態診断では、時間領域と同様に、周波数領域の特徴パラメータ、あるいはパワースペクトラムの「大きさ」により設備の「よい」、「悪い」を判定する。

パワースペクトラムは、振動に含まれる全ての周波数成分に対してある周波数成分のエネルギーが含まれる確率と解釈することができる。すなわち、高いパワースペクトラム振幅はそれに対応する周波数成分のエネルギーの存在する確率が高いことを意味する。これは回転機械の状態情報を十分に反映するといえる。しかし、従来の診断方法では回転機械の状態と高度に関連する「周波数・パワースペクトラムの振幅」の分布特性、あるいはパワースペクトラムの「形」の持つ情報を無視してしまう。このため、パワースペクトラムの「大きさ」と「形」の両方の情報を活用し、状態診断を行うことが望ましい。

そこで、本章では、情報理論を用いて、周波数領域のパワースペクトラムの持つ情報を十分に活用した診断方法を確立することを目的とする。主な研究内容は

- (1) 情報理論を適用するため、パワースペクトラムの確率密度関数への変換方法を示す。
- (2) 周波数領域のパワースペクトラムから求めた情報量に対して統一的な異常判定基準を設定し、状態診断方法を確立する。
- (3) 回転機械の異常状態に対応した技術情報量を定義し、これを用いた精密診断方法を確立する。
- (4) 軸受の診断例により、本方法の有効性を確認する。

の4項である

4.2 パワースペクトラムのIDとKI

周波数領域における情報理論による状態診断方法を提案する。はじめに、信号のフーリエ変換について述べ、また、パワースペクトラムの確率密度関数への変換方法および周波数領域のKIとIDの求め方を示す。

4.2.1 周波数領域の特徴抽出

周波数領域における信号処理では、フーリエ変換を用いて、時間波形 $x(t)$ を周波数と位相の異なる種々の正弦波成分 $X(\omega)$ に分解する。信号 $x(t)$ のフーリエ変換 $X(\omega)$ は

$$X(\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (4-1)$$

と定義される。ここで、 ω は角速度であり、周波数 f [Hz] とは $\omega = 2\pi f$ の関係がある。式(4-1)に

$$e^{j\omega t} = \cos \omega t + j \sin \omega t \quad (4-2)$$

を代入すると、式(4-1)は

$$\begin{aligned} X(\omega) &= \int_{-\infty}^{\infty} x(t) \cos \omega t dt + j \int_{-\infty}^{\infty} x(t) \sin \omega t dt \\ &= R(\omega) + jI(\omega) \end{aligned} \quad (4-3)$$

となる。これら $R(\omega)$, $I(\omega)$ はそれぞれフーリエ変換の実数部と虚数部と呼ばれる。

フーリエ変換の位相角は

$$\phi(\omega) = \tan^{-1} \frac{I(\omega)}{R(\omega)} \quad (4-4)$$

である。この位相角 $\phi(\omega)$ は、位相スペクトルとも呼ばれる。また、 $X(\omega)$ の絶対値は

$$|X(\omega)| = A(\omega) = \sqrt{R^2(\omega) + I^2(\omega)}$$

であり、この $A(\omega)$ は振幅スペクトルと呼ばれ、周波数成分 ω での振幅強度を表す。この振幅スペクトルを自乗した $X(\omega)^2$ 、すなわち、

$$P(\omega) = |X(\omega)|^2 = R^2(\omega) + I^2(\omega) \quad (4-5)$$

は、パワースペクトルまたはエネルギースペクトルと呼ばれる。この $P(\omega)$ は信号 $x(t)$ のエネルギーの周波数密度分布を意味し、信号 $x(t)$ の位相情報を無視してその周波数分布のみを知りたいときに非常に有効であり、現場における設備診断では最も多用される。

一般に周波数領域における特徴パラメータによる状態診断では

(1) 平均周波数 \bar{f} :

$$\bar{f} = \frac{\sum_{i=1}^n f_i P(f_i)}{\sum_{i=1}^n P(f_i)} \quad (4-6)$$

(2) 等価帯域 f_{BW} :

$$f_{BW} = \sqrt{\frac{\sum_{i=1}^{n/2} (f_i - f_p)^2 \times P(f_i)}{\sum_{i=1}^{n/2} P(f_i)}} \quad (4-7)$$

などのパラメータが使われる。ここで、 n はデータ点数であり、 f_p はパワースペクトラムがピーク値となるときの周波数である。

しかし、これらの特徴パラメータは機械設備の異常の種類と対応する理論的な根拠がなく、また、異常判定の基準の設定もできない。さらに、異常検出の感度が低いため、周波数領域の特徴パラメータを用いた機械設備の状態を完全に識別および同定をすることは困難である。そこで、本研究では情報理論を周波数領域に導入した状態診断アルゴリズムを確立する。

4.2.2 パワースペクトラムの正規化

一般に、時系列信号 $x(t)$ の重要な情報は、その信号のパワースペクトラム $P(f)$ に含まれる。この情報量の抽出方法はいくつかあるが、ここでは、パワースペクトラム全体に着目し、パワースペクトラムの情報理論的な特徴を表すエネルギーの確率分布を求める。

前節の解析により、パワースペクトラムにおいて、それぞれの周波数 f_i に対応する振幅 $P(f_i)$ はパワースペクトラム全体に対して、その周波数の正弦波成分と一致する可能性を示すと見なせる。すなわち、スペクトル振幅は大きいほど、その周波数に対応する正弦波成分の存在する確率が高いことを意味する。この確率は

$$S(f) = \frac{P(f)}{\int P(f)df} \quad (4-8)$$

と表すことができる。ここで、 $S(f)$ はパワースペクトラム $P(f)$ の f に関する確率密度関数である[16]。また、離散的なパワースペクトラムに対しては、

$$S(f_i) = \frac{P(f_i)}{\sum_{i=1}^n P(f_i)} \quad (4-9)$$

となる。この $S(f)$ は確率密度関数であり情報理論が適用できる。

このため、状態診断では正常状態と点検状態から測定した信号波形のフーリエ変換によって得られた参照パワースペクトラム $P_r(f)$ とテストパワースペクトラム $P_t(f)$ を式(4-8)により変換すれば、時間領域の確率密度と同様に、図 4.1 に示す周波数領域の参照分布




図 4.1 パワースペクトラムの確率密度関数

$S_r(f)$ とテスト分布 $S_t(f)$ を得られる。

4.2.3 パワースペクトラムの ID と KI

正常状態の $P_r(f)$ から変換した $S_r(f)$ と点検時の $P_t(f)$ から変換した $S_t(f)$ および式 (2-14), 式 (2-17) により, 点検時の情報量をそれぞれ

$$KI_F(S_r : S_t) = \int_0^{\infty} S_r(f) \log \frac{S_r(f)}{S_t(f)} df \quad (4-10)$$

$$ID_F(S_r : S_t) = \int_0^{\infty} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-11)$$

により求める。また, 離散分布に対しては, 点検時の情報量は式 (3-5), 式 (3-6) により

$$KI_F(S_r : S_t) = \sum_{i=1}^n S_r(f_i) \log \frac{S_r(f_i)}{S_t(f_i)} \quad (4-12)$$

$$ID_F(S_r : S_t) = \sum_{i=1}^n (S_r(f_i) - S_t(f_i)) \log \frac{S_r(f_i)}{S_t(f_i)} \quad (4-13)$$

により求められる。ここで, n は周波数の分割点数である。この KI_F と ID_F はパワースペクトル全体の持つ情報量であり, 回転機械の簡易診断に対して有効な指標と考えられる。

4.3 技術情報量

4.3.1 周波数帯域と回転機械の諸異常

現在, 機械設備の異常検出・予知技術において最も研究開発が進み, 実用されているのが振動・音響法である。これは機械内部になんらかの異常が発生したとき, それに伴って

生じる振動や音響，あるいは本来持っている振動の大きさや性質に変化をもたらすことに着目して異常検知を行う方法である。

第 4.2 節で述べたように時間波形，たとえば振動波形 $x(t)$ を周波数 ω の正弦波 $X(\omega)$ に分解できれば，回転機械の異常を推定することが可能となる。一般の回転機械は，ある一定の回転速度 N [rpm] で回転しているため，この回転周波数 f_r ($f_r = N/60$ [Hz]) とその高調波成分 nf_r ($n=1,2,\dots$) の強さは，回転要素の異常と対応している。このため，図 4.2 に示すように，信号波形の顕著な周波数成分と帯域のパワースペクトラムの情報を調べることで，回転機械の異常の判定と識別が可能である[1]。

第 4.2 節で述べた $S(f)$ は

$$\int_0^{f_{\max}} S(f) df = 1$$

となるため，この $S(f)$ は周波数成分に関する信号のエネルギー確率密度関数と見なすことができる。ここで，積分区間はパワースペクトラムの性質により $[0, f_{\max}]$ を使う。




図 4.2 振動波形の周波数成分と回転機械の異常の関係[1]

ある異常を事象 E とし、そのエネルギーの顕著な周波数区間を $[f_1, f_2]$ とすると、この異常のエネルギーの出る確率 $\mu(E)$ は

$$\mu(E) = \int_{f_1}^{f_2} S(f) df \quad (4-14)$$

となる。この区間で参照分布とテスト分布の $ID_F(S_r : S_t; E)$, $KI_F(S_r : S_t; E)$ を算出することにより、異常判定と異常識別ができる。本論文では、これら $ID_F(S_r : S_t; E)$, $KI_F(S_r : S_t; E)$ を技術情報量と呼ぶ。この技術情報量の定義により、全区域の平均情報量 $ID_F(S_r : S_t)$, $KI_F(S_r : S_t)$ よりも、 $ID_F(S_r : S_t; E)$, $KI_F(S_r : S_t; E)$ はノイズの影響を避けることができる。

4.3.2 診断用の技術情報量

(A) 帯域情報量

振動・音響解析による回転機械の診断においては、図 4.2 に示したように信号の周波数帯域を（数 Hz～1KHz）、中間周波（1KHz～10KHz）、高周波（10KHz 以上）の 3 チャンネルに分けて信号処理する場合が多い。これと対応して、パワースペクトラムの低、中、高周波技術情報量をそれぞれ

$$LID = \int_0^{1000} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-15)$$

$$MID = \int_{1000}^{10000} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-16)$$

$$HID = \int_{10000}^{f_{\max}} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-17)$$

と定義する。状態診断の実務においては、現場の回転機械の仕様により、適切な低、中、高周波帯域区間を選定する必要がある。これらの情報量は図 4.2 の異常の種類と対応し、異常により生じた振動の帯域の特定に有効である。

(B) 回転情報量

回転情報量と回転高調波情報量をそれぞれ

$$RID = \int_{f_r - \Delta f}^{f_r + \Delta f} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-18)$$

$$TID = \sum_{i=1}^k \int_{if_r - \Delta f}^{if_r + \Delta f} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-19)$$

と定義する。ここで、 f_r は回転周波数であり、また、高調波の次数 k と周波数変動範囲 Δf は回転機械の仕様と現場の状況により決める。この RID と TID は回転周波数成分に関

する情報量であり、回転機械のアンバランスやミスアライメント、ガタなどの診断に対して有効である。

(C) 軸受診断用の技術情報量

一般に転がり軸受は、外輪、内輪、転動体、保持器とオイルシールなどの小部品から構成されている。図 4.3 に代表的な転がり軸受の構成と精密診断に必要な転がり軸受の諸元を示す。

転がり軸受の部品に欠陥が生じると、転動体と欠陥の周期的な衝突により、外輪の固有振動数に近い周波数の衝撃パルスが発生する。この周波数をリンク周波数、発生する衝撃パルスをリンク振動という。また、転動体は周期的に欠陥上を通過するため、周期性のパルス列を発生する。このパルス列の繰り返し周波数をパス周波数という。なお、特徴（パス）周波数は以下の式により求められる[2]。

(1) 内輪に欠陥があるときの特徴（パス）周波数

$$f_i = \frac{Zf_r}{2} \left(1 + \frac{d}{D} \cos \alpha \right) \quad (4-20)$$

(2) 外輪に欠陥があるときの特徴（パス）周波数

$$f_o = \frac{Zf_r}{2} \left(1 - \frac{d}{D} \cos \alpha \right) \quad (4-21)$$

(3) 転動体に欠陥があるときの特徴（パス）周波数

$$f_b = \frac{f_r D}{d} \left(1 - \frac{d^2}{D^2} \cos^2 \alpha \right) \quad (4-22)$$




図 4.3 転がり軸受の主要寸法

(4) 保持器に欠陥があるときの特徴 (パス) 周波数

$$f_c = \frac{f_r}{2} \left(1 - \frac{d}{D} \cos \alpha \right) \quad (4-23)$$

ここで, f_r は軸受の回転周波数 [Hz], D は軸受のピッチ円直径, d は転動体直径, α は接触角 [rad], Z は転動体の数である.

以上の軸受のパス周波数により, 軸受診断用の技術情報量をそれぞれ

(1) 外輪傷情報量

$$OID = \int_{f_o - \Delta f}^{f_o + \Delta f} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-24)$$

(2) 内輪傷情報量

$$IID = \int_{f_i - \Delta f}^{f_i + \Delta f} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-25)$$

(4) 転動体傷情報量

$$BID = \int_{f_b - \Delta f}^{f_b + \Delta f} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-26)$$

(4) 保持器欠陥情報量

$$CID = \int_{f_c - \Delta f}^{f_c + \Delta f} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-27)$$

と定義する. ここで, Δf は周波数変動範囲であり, 機械設備の状況により選定する必要がある.

(D) 歯車診断用の技術情報量

回転周波数と噛み合い周波数は, 歯車装置の周波数領域における状態診断において重要な周波数であり, この周波数近傍での情報量も重要な意味を持つ. 歯車状態診断用の主な技術情報量をそれぞれ

(1) 噛み合い情報量

$$AID = \int_{f_a - \Delta f}^{f_a + \Delta f} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-28)$$

(2) 側帯波情報量

$$SID = \int_{f_s - \Delta f}^{f_s + \Delta f} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (4-29)$$

と定義する. ここで, f_a は噛み合い周波数, f_s は側帯周波数であり, 歯車の歯数を Z , 回転速度を N [rpm] とすると

$$\begin{aligned} f_a &= \frac{N}{60} Z \\ f_s &= f_a + f_r \end{aligned} \quad (4-30)$$

である。

以上のように、回転機械の重要な部品である軸受と歯車の診断のための技術情報量を定義したが、状態診断の実務上では、回転機械の仕様と状況により、さらに、適切な技術情報量を定義する必要がある。

4.4 状態診断アルゴリズム

4.4.1 異常の判定

稼働中の回転機械に対する状態診断の第一歩として、測定された振動信号により設備の正常・異常の判定を行う。周波数領域において、回転機械の正常状態（参照状態）の集合を E_r 、テスト状態の集合を E_t とし、二つの集合の測度としての確率密度関数を $S_r(f), S_t(f)$ とする。また、状態診断の過検出率および見落とし率をそれぞれ α, β とすると、式 (2-43)、式 (2-44) により、KI と ID の判定基準 $R_{KI}(\alpha, \beta)$ 、 $R_{ID}(\alpha, \beta)$ はそれぞれ

$$R_{KI}(\alpha, \beta) = \beta \log \frac{\beta}{1-\alpha} + (1-\beta) \log \frac{1-\beta}{\alpha}$$

$$R_{ID}(\alpha, \beta) = 2 \left[\frac{\alpha + \beta}{2} \log \frac{(\alpha + \beta)/2}{1 - (\alpha + \beta)/2} + \left(1 - \frac{\alpha + \beta}{2}\right) \log \frac{1 - (\alpha + \beta)/2}{(\alpha + \beta)/2} \right]$$

となる。

ここで、過検出率 $\alpha = 0.1$ 、見落とし率 $\beta = 0.1$ とすると、

$$R_{KI}(\alpha, \beta) = R_{KI}(0.1, 0.1) = 1.758 \quad (4-31)$$

$$R_{ID}(\alpha, \beta) = R_{ID}(0.1, 0.1) = 3.516 \quad (4-32)$$

となる。すなわち、 $S_r(f), S_t(f)$ をそれぞれ設備が正常状態の分布と未知状態の分布とするとき、

$$KI_F(S_r : S_t; O_n) \geq R_{KI}(0.1, 0.1) = 1.758 \quad (4-33)$$

$$ID_F(S_r : S_t; O_n) \geq R_{ID}(0.1, 0.1) = 3.516 \quad (4-34)$$

となると、 $S_t(f)$ と $S_r(f)$ は完全に違う集合に属するため、テスト分布の状態は異常状態と判定できる。

このため、状態診断では回転機械が正常な時に測定した信号のパワースペクトラムから、正常時パターンである参照分布 $S_r(f)$ を求めておき、点検時に測定した信号のパワースペクトラムから、点検パターンであるテスト分布 $S_t(f)$ を求め、 $S_t(f)$ と $S_r(f)$ から ID_F と KI_F が求まる。また、回転機械の異常検出の要求に従って α, β を設定し、式 (2-43)、式 (2-44) より判定基準値 $R_{KI}(\alpha, \beta), R_{ID}(\alpha, \beta)$ を計算する。これらの値を用いて参照分布

とテスト分布間に $ID_F \geq R_{ID}(\alpha, \beta)$, $KI_F \geq R_{KI}(\alpha, \beta)$ が成り立てば、回転機械が異常状態であると判定できる。

4.4.2 状態識別

(A) 簡易識別

異常が発生した時には、その対策のために異常種類を正確に識別する必要がある。簡易識別とは異常の周波数帯域を同定することである。式 (4-15) ~ 式 (4-17) により、低、中、高周波帯域の技術情報量を求め

$$ID = [LID, MID, HID]$$

とあらわす。この ID の中で最大値となる周波数帯域は異常周波数帯域と判定できる。たとえば、最大値を MID とすると、この時、参照パターンの分布 $S_r(f)$ とテストパターンの分布 $S_t(f)$ との「距離」は中間周波数の帯域で最も遠くなり、このため、衝撃力による異常、または、共振による異常などが生じている可能性が高いと判定できる。この簡易識別により回転機械の異常をおおまかに把握することができる。

(B) 精密識別

ここでは、軸受を例とした異常の精密識別方法について述べる。この方法は軸受だけでなく、他の回転機械部品の診断へも適用できる。

はじめに、診断対象である軸受の規格により、式 (4-20) ~ 式 (4-23) から軸受の特徴周波数 f_i , f_o , f_b , f_c を計算する。次に、適切な Δf を設定し、式 (4-24) ~ 式 (4-27) により軸受の外輪傷情報量 OID, 内輪傷情報量 IID, 転動体傷情報量 BID および保持器欠陥情報量 CID を求め、

$$ID = [OID, IID, BID, CID]$$

とあらわす。この ID の中で最大値となる技術情報量により傷の種類を判定することができる。たとえば、最大値を OID とすると、この時、参照パターンの分布 $S_r(f)$ とテストパターンの分布 $S_t(f)$ との「距離」は周波数区間 $[f_o - \Delta f, f_o + \Delta f]$ で最も遠いと考えられる。すなわち、正常パターンと比較して、テストパターンは周波数区間 $[f_o - \Delta f, f_o + \Delta f]$ 、すなわち、外輪傷の特徴周波数近傍において、振動エネルギーが一番強いため、軸受の状態は外輪傷状態と判定できる。

4.4.3 周波数領域における状態診断の流れ

周波数領域における情報理論による回転機械の状態診断では、まず、測定した信号を包絡線、フィルタにより全処理し、FFT 変換によりパワースペクトラムに変換する。次に、

このパワースペクトラムを確率密度関数に変換し、これまでに述べた全情報量による簡易診断方法と技術情報量による精密診断方法により診断を行う。診断の流れを図 4.4 に示す。

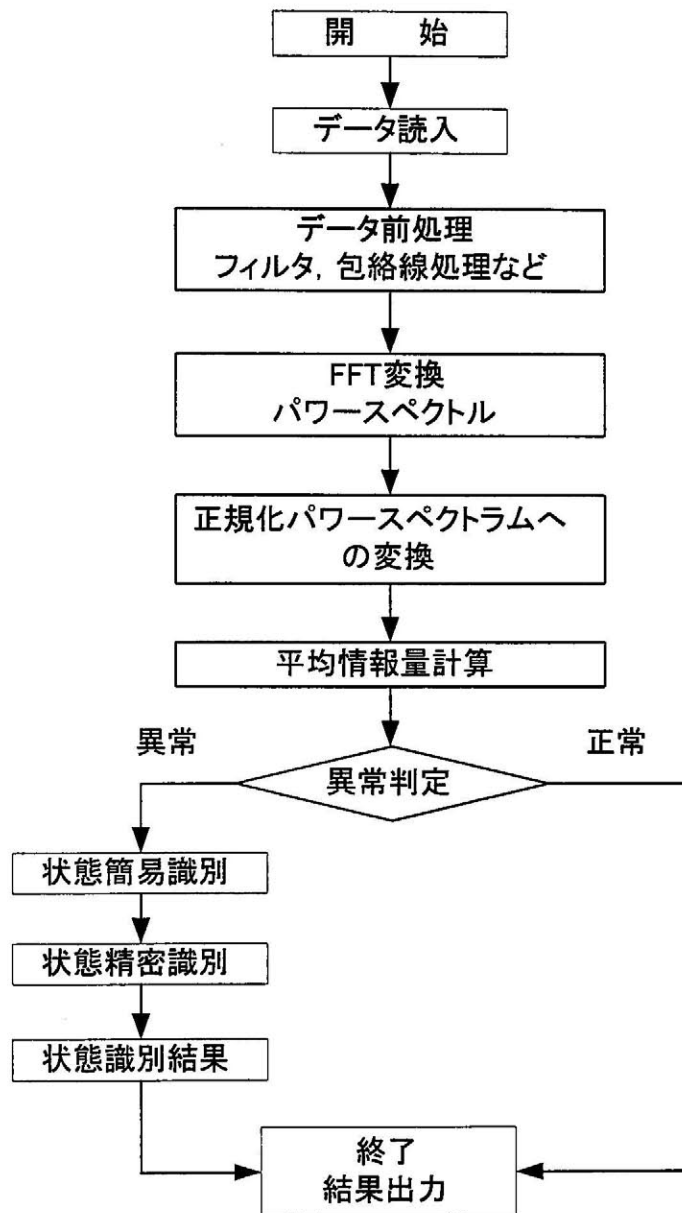


図 4.4 周波数領域における状態診断の流れ

4.5 実験による検証

4.5.1 実験方法と測定結果

本診断方法の有効性を検証するために、軸受装置の状態診断を行う。時間領域と同様に、小型回転シミュレータ（図 3.5）の軸受を対象とし、回転数を1700 [rpm]、負荷トルクを0とした。本実験においても加速度センサにより振動信号を測定し、アンプ（Anritsu UM-4A）を経て、データレコーダー（TEAC）でアナログ信号を記録した。診断に必要なデジタル信号はFFTアナライザー（小野測器 CF-250）のA/D変換およびGP-IB機能を用いて得た。

軸受装置の状態としては、正常、外輪傷、内輪傷、転動体傷の4状態を設定した。各状態において、測定時間は2.56 [s]、サンプリング周波数は25.6 [kHz]とした。測定した4状態振動波形およびそのパワースペクトラムをそれぞれ図 4.5、図 4.6 に示す。これらのパワースペクトラムを用いて状態診断を行う。


4.5.2 異常の検出感度の検証

異常検出では、あらかじめ設定した正常状態の軸受で収集した振動信号のパワースペクトルから参照パターン分布を求める。また、軸受の正常、外輪傷、内輪傷、転動体傷状態で測定した振動信号のパワースペクトルから4状態のテストパターン分布を求める。次に、これらの参照パターン分布とテストパターン分布から式(4-10)式(4-11)を用いて、4状態の ID_F と KI_F を算出する。


軸受装置の正常状態の参照パターンに対する、正常、外輪傷、内輪傷および転動状態における ID_F および KI_F を図 4.7 に示す。同図には、式(4-31)および式(4-32)の判定基準 $R_{KI}(0.1,0.1)$ および $R_{ID}(0.1,0.1)$ も示してある。同図より、正常状態の ID_F と KI_F は判定基準以下にあり、設定状態と一致したことがわかる。また、外輪傷、内輪傷および転動体傷状態の ID_F と KI_F は、いずれも、判定基準値の $R_{KI}(0.1,0.1)$ と $R_{ID}(0.1,0.1)$ より大きくなっているため、異常状態と正しく判定できていることがわかる。したがって、周波数領域の ID_F と KI_F により異常検出が可能であることが確認された。

4.5.3 異常の識別能力の検証


前節で異常と判定された3状態の異常状態の軸受に対して異常種類の識別を行う。周波数領域の情報量を用いた異常種類の識別の場合には、時間領域とは異なり、異常の参照パターンをあらかじめ設定する必要はなく、第 4.3 節に述べた技術情報量を用いる。はじめに、図 4.5 に示した正常、外輪傷、内輪傷および転動体傷の4状態のデータに対して前処




(a) 正常状態



(b) 外輪傷状態




(c) 内輪傷状態




(d) 転動体傷状態


図 4.5 軸受の振動波形




(a) 正常状態



(b) 外輪傷状態



(c) 内輪傷状態



(d) 転動体傷状態

図 4.6 振動波形のパワースペクトラム

理を行う。まず、バンドパスフィルターによってリンク周波数近傍の成分だけを抽出する。次に、その波形に対して包絡線処理を行い、その波形のFFT解析により、図4.8のようなパワースペクトラムを得る。これらのパワースペクトラムと式(4-24)～式(4-26)により正常状態の参照パターンに対する3状態のテストパターンの技術情報量は表4.1となる。この表4.1より、3状態の技術情報量が最大値となるのは、外輪傷状態ではOID、内輪傷状態ではIID、転動体傷状態ではBIDとなり、軸受の状態はそれぞれ、外輪傷、内輪傷および転動体傷と判定することができる。

以上に述べたように軸受装置の異常種類の識別結果は前もって設定した状態と完全に一致した。従って、IDは周波数領域における回転機械の精密診断に対して有効であることが確認された。






図4.7 ID_F と KI_F による異常判定

表4.1 技術情報量


技術情報量 状態	OID	IID	BID
Outer race	56.89	5.32	11.41
Inner race	13.83	46.55	12.11
Ball element	8.66	5.50	16.97




(a) 正常状態



(b) 外輪傷状態



(c) 内輪傷状態



(d) 転動体傷状態

図 4.8 前処理したパワースペクトラム

4.6 まとめ

本章では、周波数領域における情報理論による回転機械の状態診断方法を提案した。本方法は従来の周波数領域の特徴パラメータによる状態診断方法と異なり、全情報量による異常の検出と技術情報量による異常の識別が可能であることを転がり軸受の実例により検証した。本章で提案した診断方法は軸受だけでなく、回転機械の他の部品の異常検出と異常識別に対して有効であると考え、主な内容を以下にまとめる。

- (1) 情報理論を周波数領域に適用するため、パワースペクトラムの確率密度関数への変換方法を示した。
- (2) ID_F と KI_F による異常検出方法と技術情報量を用いる精密診断方法を確立した。
- (3) 軸受の診断例により、本方法の有効性を検証した。

第5章 多変量情報理論による状態診断

5.1 はじめに

稼働中の機械には、さまざまな異常が発生する可能性がある。設備状態のモニタリングおよび状態診断のためのセンシング量、およびそのセンシング量で検出できる機械の主な異常種類を表 5.1 に示す。センシング量として振動、音響および超音波域の AE (Acoustic Emission : 材料内部の亀裂、転位、点欠陥などに応力が集中し、弾性エネルギーが貯えられ、放出された弾性波) や、温度、応力、圧力、変位、歪、速度、回転速度、電流、電圧などの物理的状態量と化学的状態量がある。これらの異常検知のための状態量は、異常発生を最も感度よく検知できるものを選択すべきであり、また、異常と状態量の変化の関係がよく知られていることが望ましい。さらに、異常の兆候量を有効に検出できるセンサが開発・実用化されていることが重要である。

工場現場では、状態診断の信頼性を高めるために、異常種類に対応する状態量を適切なセンサにより測定し、また、その検出信号の大きさや特徴の変化から異常を検出する。この測定された複数の状態量による状態診断では、複数の信号の関連性を考慮することや複数の信号の持つ情報を有効に活用することが望ましい。このため、複数の状態変数の情報を統合した状態診断方法あるいは、多変量状態診断方法が必要となる。しかし、従来の設備状態診断方法では、振動、音響や電流などの一種類の信号を用い、さらに、その信号の持つ情報の一部を定量化した特徴パラメータによって診断を行うため、異常検出感度が低く、異常の早期検出が困難である。すなわち、従来の状態診断方法では、

- (1) 信号や特徴パラメータにあらわれない異常の検出が困難である。
- (2) 測定された二つ以上の信号間の関連性、また、1つの信号の異なるパラメータの関連性が考慮されていない。
- (3) 機械の仕様が異なると、振動や音響のレベルも異なるため、統一的な判定基準の設定が困難である。

などの問題点がある。

表 5.1 機械の異常種類と検出信号[4]

要素	異常の主なもの	受動的検出法での 主な信号	能動的検出法での 主な信号
機械構造体	材料の劣化 材料の割れ 結合部のゆるみ	AE AE, 振動, 音響 振動, 音響	超音波, X線 超音波, X線 超音波
回転構造体	ミスアライメント アンバランス ガタ 損傷発生	振動, 音響 振動, 音響 振動, 音響 振動, 音響, AE	振動インパルス
機械要素 (軸受) (歯車)	損傷発生 焼付け 潤滑油劣化 潤滑油切れ オイルホイップ	振動, 音響, AE 振動, 音響, 温度 フェログラフィ, SOAP 振動, 音響, AE 振動	
流体機械部 (流体管路) (弁) (圧力容器)	割れ 継手ゆるみ 漏洩 腐蝕 ルーズパーツ シール損傷 キャビテーション 異常圧発生 異常温度発生	振動, AE 振動 音響, AE, 光ファイバ ー信号 振動, 音響 音響, AE AE 圧力, AE 温度, 赤外線	超音波, 渦電流 加圧, 化学試薬 超音波, 渦電流, 磁気, 抵抗 加圧, 化学試薬
電機回路 電子回路	劣化, 断線 部品損傷	赤外線, 部分放電, 電圧, 電流 電圧・電流パターン, 赤 外線	電圧降下試験, 高圧法 テスト信号法

そこで、本章では、1変量 KI による状態診断方法を複数の信号による状態診断に拡張した多変量カルバック-ライブラー情報量 (Multivariate Kullback-Leibler information : MKI) による回転機械の状態診断法を提案する[17][18]。本章の主な内容は

- (1) 多変量状態診断のために MKI 理論を導入する。
 - (2) MKI による状態診断の統一的な判定基準を設定し、状態診断のアルゴリズムを確立する。
 - (3) 多変量情報理論による状態診断方法の有効性を実験により検証する。
- の三項である。

5.2 状態診断のための多変量情報理論

5.2.1 MKI の状態診断への適用

機械から測定された振動，音響，AE などの k 種類の信号を k 個の変量とする。既知の状態で求めた正常および各種異常状態の k 変量確率密度分布関数を「 k 変量参照分布」，点検時に測定した信号から求めた k 変量確率密度分布関数を「 k 変量テスト分布」と記す。また，それぞれの分布が正規分布 $N(\mu, \Sigma)$ に従うと仮定し， k 変量参照分布 $f_r(x_1, x_2, \dots, x_k)$ を $N(\mu_r, \Sigma_r)$ ， k 変量テスト分布 $f_t(x_1, x_2, \dots, x_k)$ を $N(\mu_t, \Sigma_t)$ とすると，

$$f_i(x_1, x_2, \dots, x_k) = \frac{1}{|2\pi\Sigma_i|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu_i)' \Sigma_i^{-1} (x - \mu_i)\right) \quad (5-1)$$

となる。ここで， $i=r, t$ ， $x' = (x_1, x_2, \dots, x_k)$ は k 変量ベクトル， $\mu_i' = (\mu_{i1}, \mu_{i2}, \dots, \mu_{ik})$ は k 変量の平均値のベクトル， $\Sigma_i = (\sigma_{ijs})$ ， $(j, s = 1, 2, \dots, k)$ は k 変量の共分散マトリクスである。なお， x' と μ_i' はそれぞれ x と μ_i の転置である[19][20]。

第 2 章の解析により，1 変量の KI の定義を多変量に拡張すると， k 変量テスト分布に対する k 変量参照分布の多変量情報量 MKI は

$$\begin{aligned} MKI(f_r : f_t) &= \int f_r(x_1, x_2, \dots, x_k) \log \frac{f_r(x_1, x_2, \dots, x_k)}{f_t(x_1, x_2, \dots, x_k)} dx_1 dx_2 \dots dx_k \\ &= \frac{1}{2} \log \frac{|\Sigma_t|}{|\Sigma_r|} + \frac{1}{2} \text{tr} \Sigma_r (\Sigma_t^{-1} - \Sigma_r^{-1}) + \frac{1}{2} \text{tr} \Sigma_t^{-1} (\mu_r - \mu_t) (\mu_r - \mu_t)' \end{aligned} \quad (5-2)$$

となる。ここで， tr はマトリクスのトレース（対角和）である。

式 (5-2) の MKI は二つの部分から構成されていることがわかる。1 つは 2 多変量分布の共分散マトリクスが等しく，平均ベクトルが異なる。もう 1 つの部分は平均ベクトルが等しく，共分散（分散）マトリクスが異なるものである。また，変量数を 1 とすると，すなわち， $k=1$ の場合には，式 (5-2) は

$$MKI(f_r : f_t; \sigma^2) = \frac{1}{2} \log \frac{\sigma_t^2}{\sigma_r^2} - \frac{1}{2} + \frac{1}{2} \frac{\sigma_r^2}{\sigma_t^2} \quad (5-3)$$

$$MKI(f_r : f_t; \mu) = \frac{1}{2} \frac{\delta^2}{\sigma^2} = \frac{1}{2} \frac{(\mu_r - \mu_t)^2}{\sigma^2} \quad (5-4)$$

となる。これは 1 変量の正規分布の KI と同一であり，1 変量の KI は多変量 KI (MKI) の特別なケースともいえる。

5.2.2 MKI の異常判定基準

第 2.6.3 節では二つの多変量正規分布の「近さ」あるいは，「距離」を測る基準を与えた。MKI の定義により二つの k 変量正規分布が全く同一の場合，すなわち，

$f_r(x_1, x_2, \dots, x_k) = f_i(x_1, x_2, \dots, x_k)$ では, $MKI(f_r : f_i) = 0$ となり, また, $f_r(x_1, x_2, \dots, x_k)$ と $f_i(x_1, x_2, \dots, x_k)$ の偏差が大きくなると MKI も大きくなる. これら二つの k 変量正規分布 $f_r(x_1, x_2, \dots, x_k)$ と $f_i(x_1, x_2, \dots, x_k)$ が異なる分布であるとみなせる MKI は以下に記す検定により決定できる.

一般化漸近理論により, $MKI(f_r : f_i)$ の推定値を $MK\hat{I}(f_r : f_i)$ とすると, $2MK\hat{I}(f_r : f_i)$ は漸近的に自由度 $k + k(k+1)/2$ の χ^2 分布

$$f(x) = \begin{cases} \frac{1}{2^{\frac{\nu}{2}} \Gamma\left(\frac{\nu}{2}\right)} x^{\frac{\nu}{2}-1} \exp\left(-\frac{1}{2}x\right) & (x > 0) \\ 0 & (x \leq 0) \end{cases}$$

に従う[3]. ここで, $\nu = k + \frac{k(k+1)}{2}$, Γ はガンマ関数である. このため,

$$\text{帰無仮説 } H_0 : f_i(x_1, x_2, \dots, x_k) = f_r(x_1, x_2, \dots, x_k)$$

$$\text{対立仮説 } H_1 : f_i(x_1, x_2, \dots, x_k) \neq f_r(x_1, x_2, \dots, x_k)$$

に対して, 有意水準を α とすると,

$$2MK\hat{I}(f_r : f_i) \geq \chi^2\left(\alpha, k + \frac{k(k+1)}{2}\right)$$

となれば H_1 を採択する. このため,

$$R_k(\alpha) = \frac{1}{2} \chi^2\left(\alpha, k + \frac{k(k+1)}{2}\right) \quad (5-5)$$

を定義し, この $R_k(\alpha)$ を k 変量 MKI の判定基準とする.

多変量正規分布の確率密度関数を検定するときには, 適切な有意水準 α を選択し, $MK\hat{I}(f_r : f_i) < R_k(\alpha)$ となると, 二つの確率密度分布は近似的に同じ分布と認めることができる. すなわち, 参照分布の状態が正常であれば, テスト分布の状態は正常と判定できる. 逆に $MK\hat{I}(f_r : f_i) \geq R_k(\alpha)$ とすると, 二つの確率密度分布は違う分布と判定することができる. すなわち, 参照分布の状態は正常であれば, テスト分布の状態は異常と判定できる.

5.3 多変量状態診断のアルゴリズム

5.3.1 MKI による異常判定方法

状態診断では, あらかじめ設定した参照パターン(正常状態すなわち既知状態)と, 測定したテストパターン(テスト状態)から参照分布 $f_r(x_1, x_2, \dots, x_k)$ とテスト分布 $f_i(x_1, x_2, \dots, x_k)$

を求め、これらと式 (5-2) により $MKI(f_r : f_t)$ を計算する。ここで、変量数を 3、有意水準 α を 0.05 とすると、式(5-5)から判定基準 $R_k(\alpha)$ は

$$R_3(0.05) = \frac{1}{2} \chi^2(0.05, 9) = 8.46 \quad (5-6)$$

となる。すなわち、3 変量の場合では、

$$MKI(f_r : f_t) \geq R_3(0.05) = 8.46 \quad (5-7)$$

となると、 $f_r(x_1, x_2, \dots, x_k)$ と $f_t(x_1, x_2, \dots, x_k)$ は違う分布であると判定できるため、テスト分布の状態は異常状態と判定できる。逆に、

$$MKI(f_r : f_t) < R_3(0.05) = 8.46$$

となる場合には、 $MKI(f_r : f_t)$ の値 が 0 に近ければ近いほど、機械設備は正常状態と判定することができる。さらに、 $MKI(f_r : f_t)$ の値が判定基準値に近い場合には、機械設備にはなんらかの変化が発生しているため、注意する必要がある。

5.3.2 MKI による状態診断の流れ

以上の理論解析に基づいて、多変量状態診断の手順をまとめると、

- (1) 機械設備の状況により、測定する適切な信号の種類とそれが測定できるセンサを選定して信号を測定する。本研究の診断対象の軸受に対しては、振動信号、音響信号および AE 信号を測定する。
- (2) 測定した信号に包絡線処理、フィルタリングなどの手法によりノイズ除去などの前処理を行う。
- (3) 多変量信号の平均ベクトルと共分散マトリクスを計算する。
- (4) 多変量情報量を計算する。
- (5) 結果を判定する。

ここで、振動、音響および AE などの三種類の信号を用いた場合の多変量状態診断の流れを図 5.1 に示す。

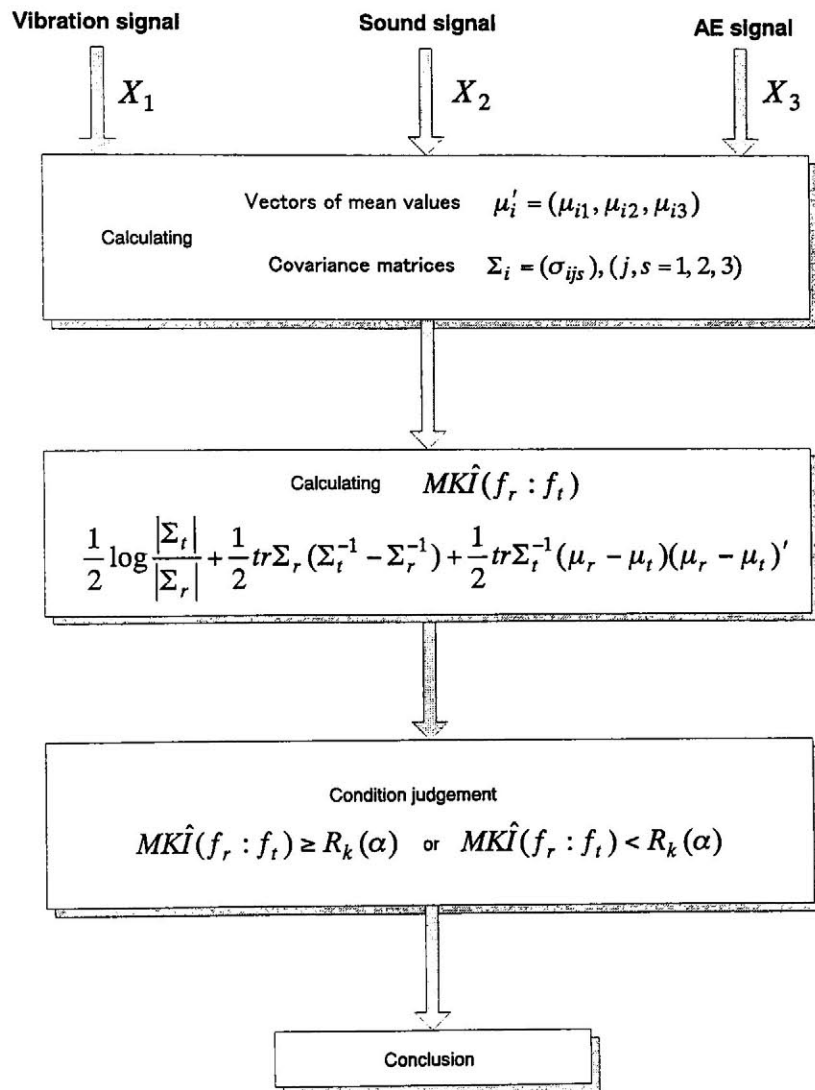


図 5.1 多変量状態診断の流れ

5.4 状態診断への適用例

5.4.1 実験方法と測定結果

多変量情報理論による状態診断方法の有効性を検証するため、軸受の診断を行う。本実験で使用する回転シミュレータを図 5.2 に示す。本実験では、軸受の異常に敏感な振動、音響と AE の三種類のセンシング量を選定し、信号を同時に測定した。図 5.3 にセンサの配置を示す。加速度センサと AE センサは軸受のケーシングの上に設置し、音響センサは軸先端から 50[mm]の位置に設置した。軸受の状態として、正常、外輪傷、内輪傷、転動体傷の 4 状態を設定した。実験に用いたの外輪傷および内輪傷状態の軸受を図 5.4 に示す。

本実験では、機械の回転数を 1200[rpm]、振動信号のサンプリング周波数を 50[kHz]、音響信号と AE 信号のサンプリング周波数を 500[kHz]設定した。データは 1 つの状態で 6 ケース、1 ケースあたり 65000 点を収集した。3 種類の信号は表 5.2 に示した装置より測定した。

実験で得られた正常状態、外輪傷状態、内輪傷状態および転動体傷状態の振動、音響および AE 信号の時系列波形をそれぞれ、図 5.5～図 5.8 に示す。

表 5.2 測定信号と測定装置

信号種類	測定装置	型番
加速度信号	加速度センサ	Anritus B0517
	アンプ	Anritsu UM-4A
	データ収集システム	Keyence NR-350
	テープレコーダ	TEAC RD-101T
音響信号	マイクロホン	RION UC-29
	プリアンプ	RION NH-05
	騒音計ユニット	RION UN-04
	データ収集システム	Keyence NR-350
AE 信号	AE センサ	NF AE900SWB
	プリアンプ	NF AE9902
	ディスクリミレータ	NF AE9922
	データ収集システム	Keyence NR-350




図 5.2 実験用シミュレータ






図 5.3 センサの配置




(a) 外輪傷

(b) 内輪傷


図 5.4 異常状態の軸受



(a) 振動信号




(b) 音響信号




(c) AE 信号


図 5.5 正常状態の振動，音響および AE 信号波形



(a) 振動信号




(b) 音響信号




(c) AE 信号


図 5.6 外輪状態の振動，音響および AE 信号波形



(a) 振動信号




(b) 音響信号




(c) AE 信号


図 5.7 内輪傷状態の振動，音響および AE 信号波形



(a) 振動信号



(b) 音響信号



(c) AE 信号

図 5.8 転動体傷の振動，音響および AE 信号波形

5.4.2 異常検出力の検証

機械が正常状態の場合の振動，音響および AE 信号より求めた多変量分布を多変量参照分布とし，点検時に測定した振動，音響および AE 信号より求めた正常，外輪傷，内輪傷，転動体傷状態の 4 テスト状態の分布を多変量テスト分布とする．この多変量参照分布と多変量テスト分布より求めた多変量情報量 MKI を図 5.9 に示す．同図の正常状態のテスト分布の情報量は判定基準 $R_3(0.05)$ 以下であり，正常状態と正しく判定できる．また，同図の外輪傷，内輪傷，転動体傷状態のテスト分布の情報量はいずれも判定基準 $R_3(0.05)$ を超えたため，異常状態と正しく判定できる．以上のように，診断結果はあらかじめ設定した軸受の状態と完全に一致するため，本方法の有効性が検証された．

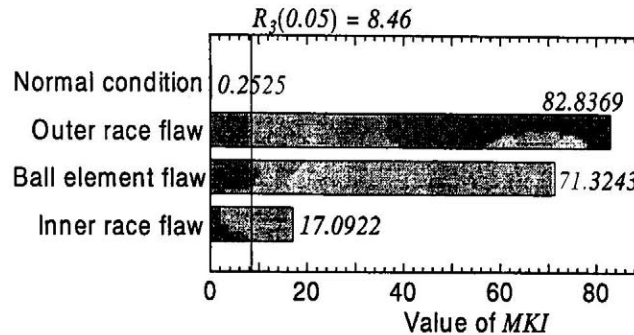


図 5.9 多変量情報量による診断結果

5.5 まとめ

本章では、従来の 1 種類の信号 (1 変量) による設備の状態診断方法の診断精度を向上させるために、2 種類以上の信号を用いる多変量情報量による状態診断方法を提案した。はじめに、多変量解析手法である多変量カルバック情報理論を導入し、これを状態診断に適用した。また、情報検定の漸近的理論により、設備状態診断の統一的な判定基準を設定した。さらに、転がり軸受から振動、音響および AE 信号を同時に測定し、これらの信号を用いて診断を行い、本方法が有効であることを検証した。主な研究内容を以下にまとめる。

- (1) 1 変量の診断理論の欠点を克服するために、多変量カルバック-ライブラー情報量を状態診断へ適用した。
- (2) 多変量カルバック-ライブラー情報量に対して、情報検定理論に基づいて状態診断の判定基準を設定し、異常診断のアルゴリズムを確立した。
- (3) 転がり軸受の実例により、多変量カルバック-ライブラー情報量による回転機械の状態診断が有効であることを検証した。

第6章 シミュレーションと現場実機データ による実用性の検証

6.1 はじめに

近年、各種工業プラントでは、機械の複雑化、大規模化に伴いシステムの保安全管理は極めて重要な課題となってきた。また、生産設備の個々の機械が高度に自動化され、インテリジェント化されているばかりでなく、工場全体がコンピュータシステムにより、1つの有機体のように制御されている。したがって、生産設備のトラブルや突発異常が生産や品質に与える影響も、従来とは比較にならないほど大きくなっている。すなわち、「生産や品質やコストは設備で決まる」時代であり、しかも、設備の信頼性はその保全で決まるため「生産や品質やコストは保全で決まる」ともいえる。

そこで、本研究で提案した情報理論による設備状態診断方法の応用として、工場現場で有効である本診断方法を用いた設備劣化傾向管理方法を提案する[22][23]。これは、設備保全における管理図に相当するものであり、予知保全において最も有効な手法である。

また、生産現場で測定した生データにより、空気清浄用抗菌フィルタ（静止機械）の寿命判定、および、原子力発電所のボイラー給水ポンプ（回転機械）の状態診断を行い、本状態診断方法の実用性についての検証を行う。

6.2 振動信号の情報量による設備の劣化傾向管理

6.2.1 情報理論による劣化傾向管理の必要性

設備の劣化傾向管理は、その設備の劣化の進行状態を定量的に管理することを目的としている。一般に、回転機械の劣化傾向管理は、主として振動信号より求めた兆候パラメー

タによって行なわれている。また、兆候パラメータとしては、振動（変位、速度および加速度）の実効値、平均値といった有次元兆候パラメータが主として用いられている。これらの有次元兆候パラメータを用いた劣化傾向管理では、

- (1) 測定値が異常以外の負荷や使用条件の変化と共に大きくばらつき、値が変化してもそれが異常によるものかばらつきによるものかが判別できないために、異常の早期検出が困難である。
- (2) 測定値のばらつきにより、設備が正常であるにもかかわらず、測定値が変化して正常なものを異常と診断してしまう場合がある。
- (3) 複数の同一機器に対して、同一の測定点での測定が困難となる場合があり、こうした場合にはそれぞれの機器に判定基準を設定する必要がある。
- (4) 機械の仕様が異なると、振動のレベルも異なるため、統一的な判定基準の設定は不可能である。

などの問題点がある。

本研究では、従来の劣化傾向管理の問題点を克服するため、情報理論を用いた設備劣化傾向管理方法を提案する。本劣化傾向管理方法では、設備状態を総合的に反映する振動波形の確率密度分布と周波数領域のパワースペクトラムに着目し、分布間の情報を効率的に抽出する情報量であるインフォメーションダイバージェンス（Information Divergence：ID）およびカルバック-ライブラー情報量（Kullback-Leibler Information：KI）を用いる。

また、振動波形のシミュレーションデータにより本方法の有効性を検証する。すなわち、

- (1) 時間領域と周波数領域の情報量である ID および KI の抽出方法を示す。
- (2) 時間領域と周波数領域における設備劣化傾向管理用の統一的な判定基準(注意レベル、危険レベル)を情報検定理論により設定する。
- (3) 情報理論による設備劣化傾向管理法を確立し、シミュレーションにより本方法の有効性を検証する。

6.2.2 時間領域と周波数領域の情報量および異常の検出

正常状態の設備より測定した振動波形から求めた参照分布を $f_r(x)$ 、点検時に実測した振動波形により求めたテスト分布を $f_t(x)$ とすると、点検時の時間領域の情報量 KI と ID は、それぞれ

$$KI_T(f_r : f_t) = \int_{-\infty}^{\infty} f_r(x) \log \frac{f_r(x)}{f_t(x)} dx \quad (6-1)$$

$$ID_T(f_r, f_t) = \int_{-\infty}^{\infty} (f_r(x) - f_t(x)) \log \frac{f_r(x)}{f_t(x)} dx \quad (6-2)$$

より求める。

また、周波数領域では、通常のパワースペクトラム $P(f)$ はエネルギー密度関数であるから、情報理論の適用ができない。そこで、

$$S(f) = \frac{P(f)}{\int_0^{\infty} P(f)df} \quad (6-3)$$

により正規化すれば、 $S(f)$ を確率密度関数とみなすことができ、情報理論が適用できる。この $S(f)$ を用いると、点検時の周波数領域の情報量はKIとIDは、それぞれ

$$KI_F(S_r, S_t) = \int_0^{\infty} S_r(f) \log \frac{S_r(f)}{S_t(f)} df \quad (6-4)$$

$$ID_F(S_r, S_t) = \int_0^{\infty} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (6-5)$$

により求める。

設備の正常状態（参照状態）の集合を E_r 、異常状態（テスト状態）の集合を E_t とすると、二つの集合の測度としての確率密度関数は時間領域で $f_r(x), f_t(x)$ 、周波数領域で $S_r(f), S_t(f)$ となる。状態診断の過検出率と見落し率を、それぞれ、 α, β とし、回転機械に対して、過検出率 α を0.1、見落し率 β を0.1とすると、式(2-43)、式(2-44)により

$$R_{KI}(0.1, 0.1) = 1.708 \quad (6-6)$$

$$R_{ID}(0.1, 0.1) = 3.516 \quad (6-7)$$

となる。すなわち、 $f_r(x), f_t(x)$ を設備が正常状態の分布と未知状態の分布とすると、

$$KI_T(f_r : f_t) \geq R_{KI}(0.1, 0.1) = 1.708 \quad (6-8)$$

$$KI_F(f_r : f_t) \geq R_{KI}(0.1, 0.1) = 1.708 \quad (6-9)$$

$$ID_T(f_r : f_t) \geq R_{ID}(0.1, 0.1) = 3.516 \quad (6-10)$$

$$ID_F(S_r : S_t) \geq R_{ID}(0.1, 0.1) = 3.516 \quad (6-11)$$

となると、 $f_t(x)$ と $f_r(x)$ は完全に違う集合に属するため、テスト分布の状態は異常状態と判定できる。

このため、劣化傾向管理では、設備の正常時に測定した振動波形から、正常時パターンである参照分布 $f_r(x)$ を求めておき、劣化傾向管理のために定期点検時に測定した振動波形から、点検パターンであるテスト分布 $f_t(x)$ を求め、これら $f_t(x)$ と $f_r(x)$ からIDとKIを求める。また、設備の異常検出の要求に従って α, β を設定し、式(2-43)、式(2-44)より判定基準値 $R_{KI}(\alpha, \beta)$ 、 $R_{ID}(\alpha, \beta)$ を計算する。これらから参照分布とテスト分布間で $ID \geq R_{ID}(\alpha, \beta)$ 、 $KI \geq R_{KI}(\alpha, \beta)$ が成り立てば、設備が異常状態であると判定できる。

6.2.3 注意レベルと危険レベルの設定

一般に、設備劣化傾向管理では、注意レベル(または警報レベル)と危険レベル(または保全レベル)を設定する[24]。これらの意味は次のとおりである。

- (1) 注意(警報)レベル：設備になんらかの変化があったことを意味する。運転条件の変化による場合もあり、必ずしも異常とは限らないが、設備管理者に注意をうながすレベルである。

(2) 危険(保全)レベル：設備が危険な状態にあり、緊急の対策が必要なことを意味する。

第2章に述べた判定基準設定により、設備の異常の判定基準 $R_{KI}(\alpha, \beta), R_{ID}(\alpha, \beta)$ は α, β に依存する。また、 α, β がそれぞれ大きくなると判定基準が小さく、すなわち、判定基準が厳しくなる。一般に、 α, β は設備異常時の損害程度により決定する。設備の異常検出力 P_0 は

$$P_0 = 1 - \beta \quad (6-12)$$

と定義され、 β が大きくなると、検出力が低くなる。このため、 β を固定し、 α を変化させて注意レベルと危険レベルを決定することが適切であると考えられる。経験的に α を 0.4、 β を 0.1 とすると、判定基準値は

$$R_{KI}(0.4, 0.1) = 0.551 \quad (6-13)$$

$$R_{ID}(0.4, 0.1) = 1.099 \quad (6-14)$$

となる。定期点検時の ID と KI がこの値を超えたら、異常の可能性があるということができ、設備の状態に注意すべきであるため、 $R_{KI}(0.4, 0.1), R_{ID}(0.4, 0.1)$ を注意レベルとする。また、 α を 0.2、 β を 0.1 とすると、判定基準値は

$$R_{KI}(0.2, 0.1) = 1.146 \quad (6-15)$$

$$R_{ID}(0.2, 0.1) = 2.428 \quad (6-16)$$

となる。定期点検時の ID と KI がこの値を超えたら、異常の可能性が高いということができ、設備はすでに危険な状態と判定できるため、 $R_{KI}(0.2, 0.1), R_{ID}(0.2, 0.1)$ を危険レベルとする。

6.2.4 劣化傾向管理図の作成および劣化傾向管理

劣化傾向管理のため、正常時の設備から測定した振動波形より、正常時パターンである参照分布 $f_r(x)$ を求めておき、定期点検時に測定した振動波形から、点検パターンであるテスト分布 $f_t(x)$ を求め、これらと式(6-1)、(6-2)より ID_T と KI_T を求める。これらの値を、定期点検の時間を横軸とし、点検時の情報量 ID_T と KI_T を縦軸とした劣化傾向管理図にプロットする。なお、点検の周期は設備の重要度により決定する。

周波数領域では、参照パワースペクトラムとテストパワースペクトラムを式(6-3)により変換し、式(6-4)、式(6-5)より周波数領域の ID_F, KI_F を求めて、時間領域と同じ手順で劣化傾向管理図を作成する。

また、この劣化傾向管理図では、ID と KI が $R_{KI}(0.4, 0.1), R_{ID}(0.4, 0.1)$ 以下の場合には、正常状態と判定でき、それ以上になると注意すべきである。もしも、ID と KI が $R_{KI}(0.2, 0.1), R_{ID}(0.2, 0.1)$ 以上となったら、緊急の対策が必要である。さらに、ID と KI が $R_{KI}(0.1, 0.1), R_{ID}(0.1, 0.1)$ を超えたら、設備は完全に異常状態と判定でき、ただちに機器を停止し、修復しなければならない。

6.2.5 シミュレーションと検証

情報理論による設備劣化傾向管理の有効性を検証するために、転がり軸受とアンバランスのシミュレーションによる劣化傾向管理例を示す。

転がり軸受に対し、参照分布として、正常状態における振動波形の分布 $f_r(x)$ が平均 0、分散 1 の正規分布に従うとする。また、異常状態として、外輪傷を想定し、時間の推移に従って、傷が次第に大きくなると仮定した。また、振動波形は外輪傷状態の振動信号の形を近似した

$$y(t) = Ke^{-2\pi\alpha f_n t} \sin(2\pi f_n t) + N(t) \quad (6-17)$$

によりシミュレーションする。ここで、 f_n は軸受のリンク周波数、 α は減衰係数であり、 $N(t)$ は平均 0、分散 1 の正規乱数である。


なお、本研究では、 f_n を 1500[Hz]、 α を 0.1 とし、 K が 1 ヶ月に 0.3 変化すると仮定した。転がり軸受の回転数は 1200[rpm]、サンプリング周波数は 51.2[kHz]、サンプル点は 25600 個、点検の時間間隔は 3 ヶ月とした。

シミュレーションにより作成した正常状態と異常状態のシミュレーション波形およびそのパワースペクトラムの一例をそれぞれ図 6.1、図 6.2 に示す。また、図 6.3 は有次元兆候パラメータの実効値(RMS)の劣化傾向管理図である。なお、同図には、一般的な判定基準も示している。同図より実効値は常に危険レベル以下にあるため、異常の検出ができないことがわかる。図 6.4 は時間領域の ID と KI の劣化傾向管理図である。異常状態にもかかわらず、KI は危険レベル以下にあることがわかる。しかし、その一方で、ID はシミュレーションされた劣化の進行を正しく表していることがわかる。また、図 6.5 は周波数領域の ID と KI の傾向管理図である。ID と KI のいずれもシミュレーションされた劣化の進行を正しく表していることがわかる。このため、時間領域の ID および周波数領域の ID と KI による劣化傾向管理の有効性が検証された。


アンバランスに対して、参照分布として、正常状態における分布 $f_r(x)$ が平均 0、分散 σ^2 に従うとする。ばらつきのデータをとるため、 σ を 1~1.5 の範囲で変化させる。異常状態のアンバランスは時間の推移に従って激しくなる。振動波形はアンバランスの振動信号の形を近似した

$$y(t) = K \sin(2\pi f_r t) + N(t) \quad (6-18)$$

でシミュレーションする。ここで、 f_r は回転周波数、 $N(t)$ は平均 0、分散 σ^2 の正規乱数である。なお、本研究では、アンバランスの振幅 K は 1 ヶ月に 0.2 変化すると仮定した。回転数を 1200[rpm]、サンプリング周波数を 512[Hz]、サンプル点を 4096 個、点検の時間間隔を 3 ヶ月とした。正常状態と異常状態の一例のシミュレーション波形およびパワースペクトラムをそれぞれ図 6.6、図 6.7 に示す。




(a) 正常状態




(b) 外輪傷状態

図 6.1 軸受損傷のシミュレーション波形



(a) 正常状態



(b) 外輪傷状態

図 6.2 軸受損傷のシミュレーションのパワースペクトラム




図 6.3 実効値による劣化傾向管理図 (外輪傷状態)




図 6.4 情報量による時間領域の劣化傾向管理図 (外輪傷状態)






図 6.5 情報量による周波数領域の劣化傾向管理図 (外輪傷状態)




(a) 正常状態




(b) アンバランス状態

図 6.6 アンバランス状態のシミュレーション波形



(a) 正常状態



(b) アンバランス状態

図 6.7 アンバランス状態のシミュレーションのパワースペクトラム

また、実効値、時間領域の ID と KI および周波数領域の ID と KI の劣化傾向管理図をそれぞれ図 6.8～図 6.10 に示す。

アンバランスのシミュレーションデータはばらつきが大きいため、図 6.8 の実効値は注意レベルの上下に激しく変動する。これにより設備の状態を正しく把握することが困難であることがわかる。しかし、図 6.9, 図 6.10 の時間領域の ID および周波数領域の ID と KI ではわずかな変動はあるが、全体的には安定である。いずれも、シミュレーションされた劣化の進行を正しく表していることがわかる。




図 6.8 実効値による劣化傾向管理図（アンバランス状態）




図 6.9 情報理論による時間領域の劣化傾向管理図（アンバランス状態）




図 6.10 情報理論による周波数領域の劣化傾向管理図（アンバランス状態）

6.2.6 まとめ

本節では、従来の振動波形の兆候パラメータによる劣化傾向管理方法の欠点を解決するために、情報理論による設備劣化管理方法を提案した。主な内容は次のようにまとめられる。

- (1) 情報検定理論に基づいて時間領域と周波数領域の ID と KI に対する統一的な判定基準（注意レベルおよび危険レベル）の設定方法を示した。
- (2) シミュレーションにより、情報理論による回転機械の劣化傾向管理が有効であることを検証した。
- (3) 時間領域の ID は KI と比較して、異常の検出感度と識別能力が高いことをシミュレーションにより示した。

6.3 情報理論による抗菌フィルタの寿命判定

6.3.1 抗菌フィルタの診断の必要性

環境問題やエネルギー問題への対応や、製品の品質や安全性確保のためには、生産設備などで使用されるフィルタの信頼性を向上させる必要がある。また、食品メーカーでは、食品の品質基準を厳守、さらに、将来的にはあらゆる食品メーカーが HACCP (Hazard Analysis and Critical Control Point (危害分析・重要管理点) : 食品の安全性を高めるための新しい考え方の食品衛生管理システム) の認定取得を義務付けられることを考慮すると、食品製造工程において多量に使用される圧縮空気の有毒菌や腐敗菌を除去する圧縮空気用フィルタの信頼性の確保は非常に重要な課題となる。

このようにフィルタの信頼性確保、寿命判定は、生産設備の設備管理において重要な管理項目であるが、従来は人の経験と勘、または、差圧信号や温度による管理されていることが多く、いずれも精度上問題が多い。したがって、診断精度が高いフィルタの状態診断・寿命判定方法の確立が必要とされている。

そこで、本研究では、抗菌フィルタから測定される振動信号に対して、カルバック-ライブラー情報量 (Kullback-Leibler Information : KI) およびインフォメーションダイバージェンス (Information Divergence : ID) を用いた抗菌フィルタの寿命判定を行い、本研究で提案する状態診断方法のフィルタに対する有効性および実用性を検討・検証する [25]。本節の主な内容は、

- (1) 抗菌フィルタの寿命判定への情報理論 (KI と ID) を導入する。
- (2) 情報検定理論によるフィルタ寿命判定基準の設定方法を確立する。
- (3) 現場で実測された抗菌フィルタの振動信号を用いた本寿命判定方法の有効性を検証する。

の3項である。

6.3.2 寿命判定のための KI と ID

機械設備の寿命判定では、オンライン監視または点検時に実測した振動、音響、熱などの状態量に基づいて寿命判定を行う。ここで、正常状態において測定した機械の状態量から求めた確率密度関数を「参照分布」、点検時に測定した状態量から求めた確率密度関数を「テスト分布」とする。この時、参照分布とテスト分布の偏移、すなわち、「距離」を測ることにより機械設備の寿命判定ができる。

参照分布とテスト分布をそれぞれ $f_r(x)$ 、 $f_t(x)$ とすると、テスト分布に対する参照分布の KI は

$$\begin{aligned}
KI(f_r : f_t) &= E_x \log \frac{f_r(X)}{f_t(X)} \\
&= \int_{-\infty}^{\infty} f_r(x) \log \frac{f_r(x)}{f_t(x)} dx \\
&= \int_{-\infty}^{\infty} f_r(x) \{\log f_r(x) - \log f_t(x)\} dx
\end{aligned} \tag{6-19}$$

となる。ただし、 E_x は期待値をとる意味である。また、KI を対称化した ID は

$$\begin{aligned}
ID(f_r : f_t) &= E_x \log \frac{f_r(X)}{f_t(X)} + E_x \log \frac{f_t(X)}{f_r(X)} \\
&= \int_{-\infty}^{\infty} f_r(x) \log \frac{f_r(x)}{f_t(x)} dx + \int_{-\infty}^{\infty} f_t(x) \log \frac{f_t(x)}{f_r(x)} dx \\
&= \int_{-\infty}^{\infty} (f_r(x) - f_t(x)) \log \frac{f_r(x)}{f_t(x)} dx
\end{aligned} \tag{6-20}$$

より求められる。

本研究では、圧縮空気清浄用フィルタの寿命判定を周波数領域のパワースペクトラムにより行う。しかし、通常のパワースペクトラム $P(f)$ は信号 $x(t)$ のエネルギーの周波数密度分布であるため、情報理論の適用ができない。そこで、

$$S(f) = \frac{P(f)}{\int_0^{\infty} P(f) df} \tag{6-21}$$

により正規化すれば、 $S(f)$ を確率密度関数とみなすことができ情報理論が適用できる。

点検時の情報量 KI_F 、 ID_F はそれぞれ式 (6-19)、式 (6-20) から、

$$KI_F(S_r : S_t) = \int_0^{\infty} S_r(f) \log \frac{S_r(f)}{S_t(f)} df \tag{6-22}$$

$$ID_F(S_r : S_t) = \int_0^{\infty} (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \tag{6-23}$$

により求められる。

6.3.3 寿命判定方法

使用中のフィルタの交換の必要性を、測定された振動信号により判定する。フィルタの正常状態（参照状態）の集合を E_r と点検状態（テスト状態）の集合を E_t とすると、二つの集合の測度としての確率密度関数は $f_r(x)$ 、 $f_t(x)$ になる。また、寿命判定の過検出率と見落し率をそれぞれ、 α と β とする。この α と β は一般に機械設備の重要度により選定するが、食品の品質保証は非常に重要であるため、フィルタの信頼性を高めるため厳しい寿命判定基準の設定が必要となる。

第 2 章の解析により、過検出率 α が大きくなると判定基準が厳しくなるため、ここで、過検出率 α を 0.2、見落し率 β を 0.1 とすると、式 (2-43)、式 (2-44) により

$$R_{KI}(0.2,0.1) = 1.146 \quad (6-24)$$

$$R_{ID}(0.2,0.1) = 2.428 \quad (6-25)$$

となる。すなわち、 $f_r(x)$ 、 $f_i(x)$ をそれぞれ設備が正常状態の時の分布と未知状態の時の分布とすると、

$$KI(f_r : f_i; O_n) \geq R_{KI}(0.2,0.1) = 1.146 \quad (6-26)$$

$$ID(f_r : f_i; O_n) \geq R_{ID}(0.2,0.1) = 2.428 \quad (6-27)$$

となると、 $f_i(x)$ と $f_r(x)$ は完全に違う集合に属するため、テスト分布の状態は寿命であると判定できる。

このため、寿命判定では、フィルタが正常時に測定した振動波形から、正常時パターンである参照分布 $f_r(x)$ を求めておき、また、点検時に測定した振動波形から、点検パターンであるテスト分布 $f_i(x)$ を求め、これら $f_i(x)$ と $f_r(x)$ からKIとIDを求める。次に、設備の寿命判定の要求に従い α, β を設定し、判定基準値 $R_{KI}(\alpha, \beta)$ 、 $R_{ID}(\alpha, \beta)$ を計算し、参照分布とテスト分布間に $KI \geq R_{KI}(\alpha, \beta)$ 、 $ID \geq R_{ID}(\alpha, \beta)$ が成り立てば、フィルタが寿命であると判定できる。

6.3.4 測定結果

寿命判定の対象とした(株)前田シェルサービス製 3 in 1 マルチ・ドライフィルタ T-150A の構造を図 6.11 に示す。このフィルタにより、圧縮空気中のオイルミストの 99.99%以上を除去し、また、水滴ゼロ、0.01 ミクロン以上の固形粒子を除去した超クリーンなエアが得られる。

実験では、フィルタの新品、中程度汚れ、交換時期超過の 3 状態の振動信号を測定した。測定系の概略を図 6.12 に示す。振動の加速度信号をエア出口の近傍に取り付けた加速度センサにより測定した。測定装置を表 6.1 に示す。FFT アナライザーの設定は、サンプリング周波数を 128[kHz]、サンプリング点数を 4096 点とし、それぞれ、10 ケースのデータを FFT アナライザーに記録した。図 6.13 に 3 状態における振動の生波形を、また、図 6.14 にこの 3 状態におけるパワースペクトラムを示す。

表 6.1 振動信号の測定装置

信号種類	測定装置	型番
加速度信号	加速度センサ	PV-91
	振動計	VM-80
	FFT アナライザー	SA-76




図 6.11 マルチ・ドライフィルタ T-150A の構造




図 6.12 測定系概略図




図 6.13 フィルタの振動波形




図 6.14 フィルタ振動波形のパワースペクトラム

6.3.5 データ処理および判定結果

前節で測定した生データのパワースペクトラムを式 (6-21) により変換し、式 (6-22)、式 (6-23) を用いて、正常状態に対する 3 状態の KI と ID を計算することができる。計算結果を図 6.15 に示す。同図より 3 状態の KI と ID 値はすべて判定基準以下にあるため、寿命とならない誤判定となった。

図 6.14 の 3 状態のパワースペクトラムは、周波数 14[kHz] の付近に高いピークが出る特徴を持つ。これはエアー供給システムのノイズであると考えられる。このため、誤判定の原因として生波形はこのノイズに強く汚染されたと考えられる。しかし、フィルタの使用日時の変化に伴って、45[kHz] 付近にパワースペクトラムの変動が著しいため、生波形に 30~60[kHz] のバンドパスフィルタにより前処理を行う。前処理後の 3 状態の振動波形とパワースペクトラムをそれぞれ図 6.16、図 6.17 に示す。同図より正常状態と異常状態のフィルタの振動波形とパワースペクトラムが大きく異なることがわかる。

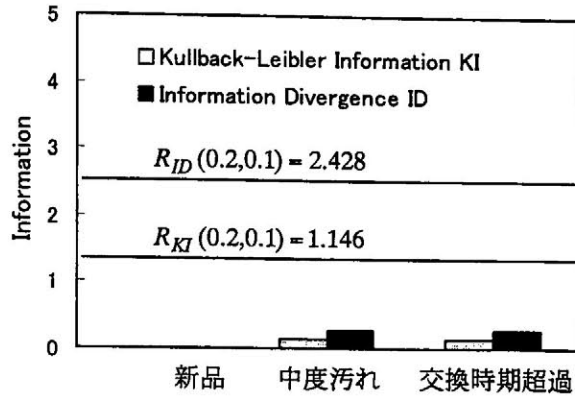


図 6.15 生データのパワースペクトラムの KI と ID

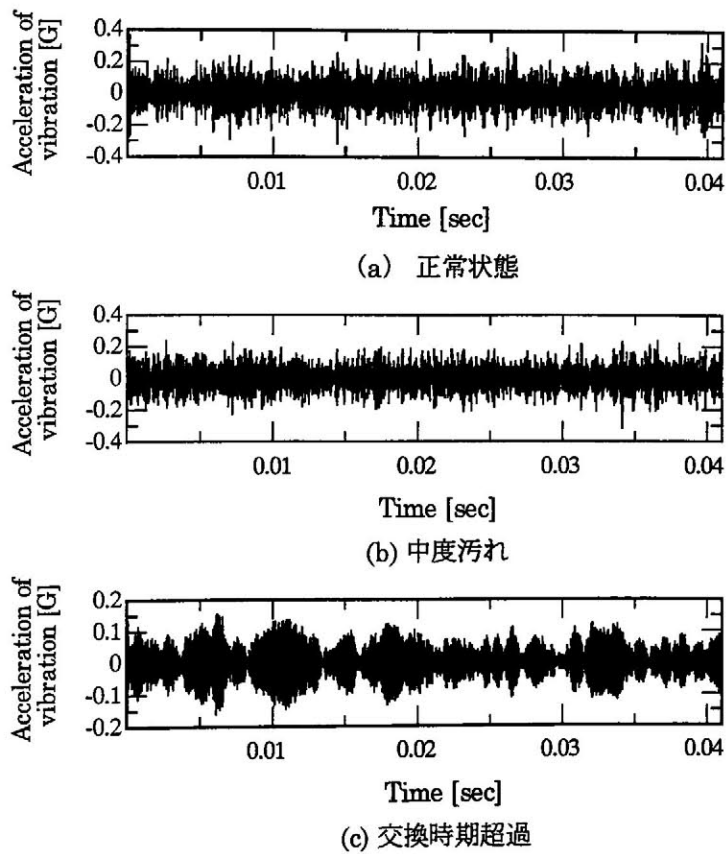


図 6.16 ノイズ除去後の振動波形




図 6.17 ノイズ除去後のパワースペクトラム

この前処理後のデータの KI と ID の計算結果を図 6.18 に示す。同図の交換時期超過の KI と ID の値はそれぞれの判定基準を超え、寿命であるということが正しく判定できる。また、交換時期超過の KI 値は中程度汚れの KI 値の 11.9 倍、交換時期超過の ID 値は中程度汚れの ID 値の 14.9 倍となるため、ID の寿命判定感度が KI より高いことがわかる。

6.3.6 まとめ

本研究では、インフォメーションダイバージェンス を用いてフィルタの仕様や環境条件などに影響されない、抗菌フィルタの寿命判定方法を示した。また、従来の寿命判定方法では判定基準の設定が大きな問題となるが、本方法では、情報検定理論に基づいて、フィルタ仕様や運転条件に影響されない判定基準を理論的に設定可能なことを示した。さらに、現場実測データにより、本方法が抗菌フィルタに対して高い検出感度を有し、実用可能であることを検証した。




図 6.18 ノイズ除去後のパワースペクトラムの KI と ID

ここで提案した手法は

- (1) 抗菌フィルタだけでなく、あらゆる空、水、油用フィルタの寿命判定に有効に適用可能である。
- (2) 本研究では振動信号を用いたが、音響信号など他の状態変数を用いた寿命判定にも適用可能である。

6.4 回転機械の状態診断への応用

6.4.1 ボイラ給水ポンプ状態診断の必要性

ポンプは発電所や化学プラントなどの広い分野で重要な役割を担っており、高度な信頼性を要求されている。従来、ポンプでは、その振動信号や音響信号の実効値、歪み度、尖り度などの特徴パラメータによって状態診断を行うことが多い。

しかし、ポンプなどの流体機械は、通常の回転機械に流体现象が加わるため、機械系の振動信号と流体系の振動信号が生じノイズの影響が強い。また、機械系の異常が発生すると共に、流体機械特有の異常現象も発生する可能性がある。このため、流体機械の状態診断は、一般の回転機械の診断よりも困難となる場合が多い[26][27]。

そこで、本研究では、情報理論による状態診断方法を流体機械であるポンプの状態診断に適用する。発電所の現場で測定された生データを用いて、流体機械に対する本状態診断方法の有効性・実用性を検討・検証する。

6.4.2 状態診断方法と異常判定

ボイラ給水ポンプの状態診断の信頼性を高めるために、時間領域と周波数領域で同時に情報量を抽出して診断を行う。ここで、正常状態において測定した機械の状態量から求めた確率密度関数を「参照分布」、点検時に測定した状態量から求めた確率密度関数を「テスト分布」とする。この時、参照分布とテスト分布の偏移、すなわち、「距離」を測ることによりポンプの正常・異常を判定する。

参照分布とテスト分布をそれぞれ $f_r(x)$ 、 $f_t(x)$ とすると、テスト分布に対する参照分布時間領域の KI は

$$KI_T(f_r : f_t) = \int_{-\infty}^{\infty} f_r(x) \log \frac{f_r(x)}{f_t(x)} dx \quad (6-28)$$

時間領域の ID は

$$ID_T(f_r : f_t) = \int_{-\infty}^{\infty} (f_r(x) - f_t(x)) \log \frac{f_r(x)}{f_t(x)} dx \quad (6-29)$$

より求められる。

また、周波数領域の状態診断をパワースペクトラムにより行う。しかし、通常のパワースペクトラム $P(f)$ は信号 $x(t)$ のエネルギーの周波数密度分布であるため、情報理論の適用ができない。そこで、

$$S(f) = \frac{P(f)}{\int_0^{\infty} P(f) df} \quad (6-30)$$

により正規化すれば、 $S(f)$ を確率密度関数とみなすことができ情報理論が適用できる。
点検時の情報量 KI_F , ID_F はそれぞれ式 (6-28), (6-29) から,

$$KI_F(S_r : S_t) = \int_0^\infty S_r(f) \log \frac{S_r(f)}{S_t(f)} df \quad (6-31)$$

$$ID_F(S_r : S_t) = \int_0^\infty (S_r(f) - S_t(f)) \log \frac{S_r(f)}{S_t(f)} df \quad (6-32)$$

により求められる。

運転中の給水ポンプに対して、正常・異常を測定された振動信号により判定する。ポンプの正常状態（参照状態）の集合を E_r と点検状態（テスト状態）の集合を E_t とすると、二つの集合の測度としての確率密度分布は時間領域で $f_r(x)$ と $f_t(x)$ 、周波数領域で $S_r(f)$, $S_t(f)$ となる。また、状態診断の過検出率と見落とし率をそれぞれ、 α, β とする。一般に、 α, β は機械設備の重要度により選定するが、原子力発電所のボイラ給水ポンプは重要な設備であるため、診断の信頼性を高めるため厳しい判定基準設定が必要となる。

第2章の解析により、過検出率 α が大きくなると判定基準が厳しくなるため、ここでは、過検出率 α を 0.2、見落とし率 β を 0.1 とすると、式 (2-43), 式 (2-44) により

$$R_{KI}(0.2, 0.1) = 1.146 \quad (6-33)$$

$$R_{ID}(0.2, 0.1) = 2.428 \quad (6-34)$$

となる。すなわち、 $f_r(x), f_t(x)$ と $S_r(f), S_t(f)$ をそれぞれ設備が正常状態の分布と未知状態の分布とすると、KI に対して

$$KI_T(f_r : f_t) \geq R_{KI}(0.2, 0.1) = 1.146 \quad (6-35)$$

$$KI_F(S_r : S_t) \geq R_{KI}(0.2, 0.1) = 1.146 \quad (6-36)$$

また、ID に対して

$$ID_T(f_r : f_t) \geq R_{ID}(0.2, 0.1) = 2.428 \quad (6-37)$$

$$ID_F(S_r : S_t) \geq R_{ID}(0.2, 0.1) = 2.428 \quad (6-38)$$

となると、 $f_t(x)$ と $f_r(x)$ および $S_r(f), S_t(f)$ はそれぞれ、完全に違う集合に属するため、テスト分布の状態は異常であると判定できる。

このため、状態診断では、ポンプが正常の時に測定した振動波形から、正常時パターンである参照分布 $f_r(x), S_r(f)$ を求めておき、点検時に測定した振動波形から、点検パターンであるテスト分布 $f_t(x), S_t(f)$ を求め、時間領域と周波数領域の 2 分布からそれぞれ KI と ID を求める。次に、設備の寿命判定の要求に従い α, β を設定し、判定基準値 $R_{KI}(\alpha, \beta)$, $R_{ID}(\alpha, \beta)$ を計算し、参照分布とテスト分布間に $KI_T \geq R_{KI}(\alpha, \beta)$, $ID_T \geq R_{ID}(\alpha, \beta)$, $KI_F \geq R_{KI}(\alpha, \beta)$, $ID_F \geq R_{ID}(\alpha, \beta)$ のいずれか 1 つが成り立てば、ポンプが異常であると判定できる。

6.4.3 測定結果

状態診断の対象としたボイラ給水ポンプの概略図を図 6.19 に示す。このポンプは、ボイラに水を補給するために設置されている設備である。

実験では、ポンプのベアリングが正常な状態、フレーキング状態、局所異常状態の 3 状態の振動信号を測定した。測定系の概略を図 6.20 に示す。加速度センサは被診断軸受の近傍に垂直、水平、軸方向の三方向に取り付け、測定した信号を A/D 変換し、コンピュータに保存した。なお、モータの回転数は 1479[rpm]とした。測定装置は表 6.2 に示す。サンプリング周波数は 24[kHz]、サンプリング点数は 6000 点として、それぞれ、20 ケースのデータを記録した。

図 6.21 に 3 状態における振動の生波形を、また、図 6.22 にこの 3 状態のパワースペクトラムを示す。これらのデータを用いて診断を行う。

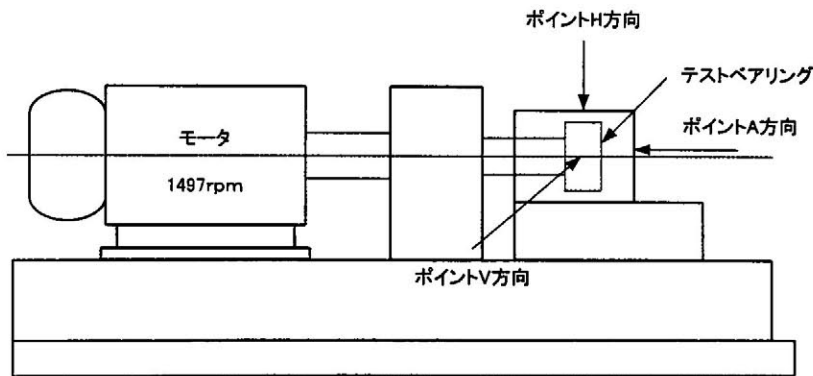


図 6.19 給水ポンプの概略図

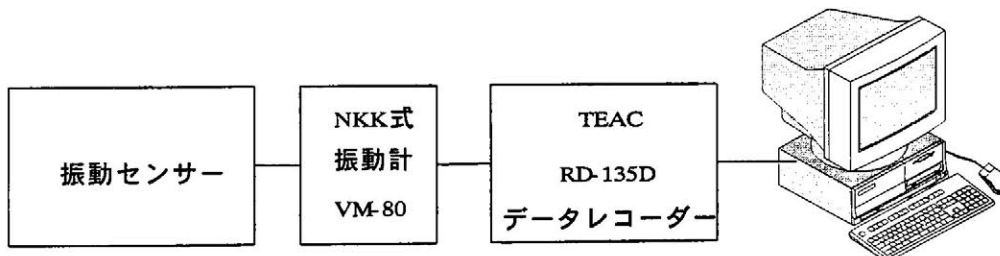





図 6.20 測定系概略図



(a) 正常状態



(b) フレーキング状態



(c) 局所異常状態

図 6.21 給水ポンプの振動波形

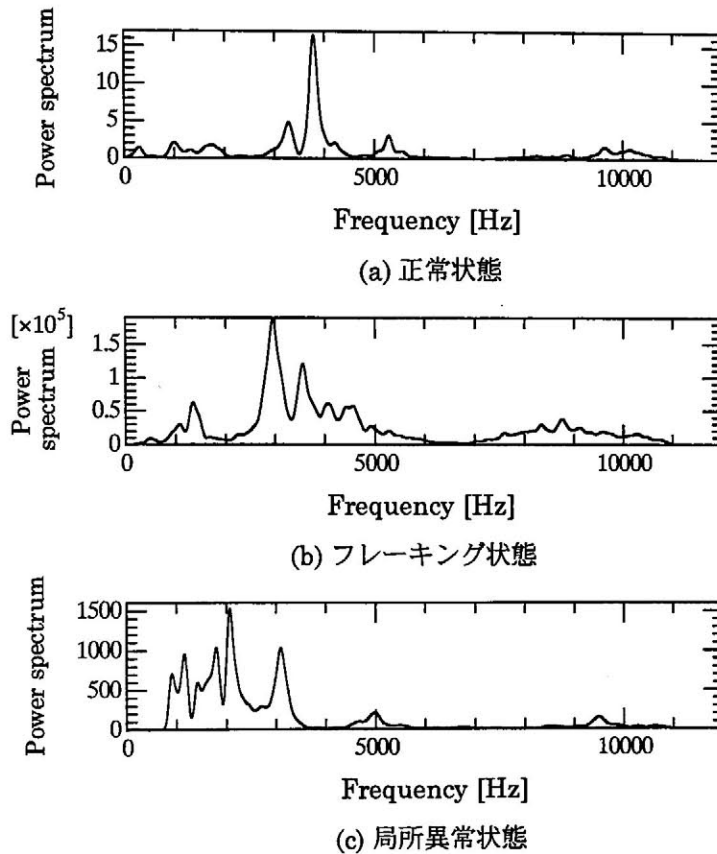


図 6.22 給水ポンプ振動波形のパワースペクトラム

6.4.4 診断結果

前節で測定した時間領域の振動波形の振幅密度分布より式 (6-28), 式 (6-29) を用いて, 正常状態に対する二つのテスト状態の KI_T , ID_T を算出することができる. また, 振動波形のパワースペクトラムを式 (6-30) により変換し, 式 (6-31), (6-32) を用いて, 正常状態に対する二つのテスト状態の KI_F , ID_F を算出することができる. なお, 診断には垂直方向の測定データを使った.

フレーキングと局所異常の 2 状態の計算結果をそれぞれ, 図 6.23, 図 6.24 に示す. 図 6.23 より, KI_T , ID_T 値は判定基準以下にあるため, 正常状態と誤判定になった. しかし, これは, 本実験で用いた軸受のフレーキングが非常に進行した状態であり, この時の振動の振幅密度分布は, 正常状態と同様の正規分布に近づくためである. このため, 初期のフレーキング状態では, 異常を検出できると考えられる. また, KI_F , ID_F 値はすべて判定

基準を超えたため、異常状態と判定できる。さらに、局所異常軸受の場合には、図 6.24 より、 KI_T 、 ID_T 値と KI_F 、 ID_F 値は、いずれも判定基準値を超えたため、この軸受は異常状態と正しく判定できることがわかる。この診断例により、情報理論による状態診断方法は流体機械に対しても、有効かつ実用的であることが確認された。




図 6.23 フレーキング軸受の判定図




図 6.24 局所異常軸受の判定図

6.4.5 まとめ

本節では、流体機械であるボイラ給水ポンプに対して、情報理論による状態診断を行った。流体機械は、機械系の振動信号と流体系の振動信号が生じるため、一般の回転機械よりも診断が困難になるが、まず、判定基準を厳しくし、また、振動信号の時間領域と周波数領域で診断を行い、理想的な結果を得ることができた。主な研究内容を以下にまとめる。

- (1) 重要な流体機械の状態診断に対して、適切な判定基準を設定した。
- (2) 状態診断の信頼性を高めるために、本研究では、振動信号の時間領域と周波数領域を用いて診断を行う方法確立した。
- (3) 発電所現場で測定した振動信号を用いて、正確な診断結果を得たことにより、情報理論による状態診断方法が流体機械に対して有効であることを検証した。

第7章 終章

7.1 本研究の結論

本研究では、情報理論による機械設備の状態診断に関する研究を行い、

- (1) カルバック-ライブラー情報量 (Kullback-Leibler Information : KI) とインフォメーションダイバージェンス (Information Divergence : ID) により、振動信号、音響信号および AE 信号などの確率密度関数を求めることができる状態量の特徴抽出が可能であることを理論解析と実データにより確認した。また、KI と ID の状態診断への適用方法を検討し、その適用アルゴリズムを示した。
- (2) 正規分布に従う信号に対して、ID の異常検出感度と識別能力が KI と比較して優れていることを理論解析により示した。なお、信号の確率密度分布が正規分布とならない場合においても、その分布が数式で与えられれば、同様な手法で異常検出感度を理論的に検討することができる。また、信号の確率密度分布が数式で与えられない場合においても、実測データによって、ID と KI の異常感度を検討することができる。また、本研究では、歯車装置と軸受の状態診断に対して ID が優れた性能を示すことを実験により確認した。
- (3) 時間領域では、機械設備から測定した時系列信号の振幅確率密度分布の測度であるカルバック情報量とインフォメーションダイバージェンスの抽出方法を示し、さらに、ID と KI による状態診断の統一的な判定基準を設定した。また、パターン認識を用いた精密診断方法を提案した。さらに、歯車装置と転がり軸受の状態診断を行い、ID による異常検出すなわち簡易診断だけでなく、異常種類の識別すなわち精密診断も可能なことを検証した。
- (4) 周波数領域では、通常のパワースペクトラムはエネルギー密度関数であるため、情報理論の適用ができないが、本研究では、パワースペクトラムの正規化方法を提案し、周波数領域の情報量の抽出方法を示した。また、異常種類の識別のための技術情報量を定義し、周波数領域の簡易診断方法と精密診断方法を提案した。さらに、転がり軸受の診断実例により、提案した診断方法の有効性を検証した。

- (5) 多変量カルバック-ライブラー情報量 (Multivariate Kullback-Leibler Information : MKI) を状態診断に導入し、機械設備の複数の状態情報を有効に活用した MKI による回転機械の状態診断方法を提案した。はじめに、MKI による状態診断の適用理論を検討し、次に情報検定理論に基づいて多変量状態診断の判定基準を設定し、MKI による状態診断アルゴリズムを確立した。さらに、転がり軸受から同時に測定した振動信号、音響信号および AE 信号を用いて診断を行い、本方法が有効であることを検証した。
- (6) 本研究で提案した情報理論による設備状態診断方法の実用性を検証するため、工場現場で有効である設備の劣化傾向管理に対して本状態診断方法を適用した。また、生産現場で測定された空気清浄用抗菌フィルタ (静止機械) の振動データを用いた寿命判定、および、原子力発電所のボイラー給水ポンプ (回転機械) の振動データを用いた状態診断を行った。いずれの結果も、設備機械の状態を精度良く診断していることが確認され、本研究で提案する情報理論による設備状態診断方法の実用性が検証された。

7.2 今後の展望

本研究の今後の展開に関して

- (1) 正規分布に従わない信号波形に対しての情報理論による多変量状態診断方法を確立する。
- (2) 情報理論による状態診断方法を、機械設備の状態診断だけでなく、人間の健康管理などの分野に広げ、さらに、実用化の研究を進める。

謝辞

本研究を行うにあたり、終始懇切丁寧なご指導、ご鞭撻を賜りますと共に、設備診断全般および他のさまざまな知識をご熱心にご教示いただきました、九州工業大学情報工学部機械システム工学科 豊田利夫 教授に心から謹んで感謝の意を表します。研究の進め方、論文のまとめ方、英語の論文の書き方などについて手取り足取りでご教授いただきました、公私とも行き届いたご関心をいただきました九州工業大学情報工学部機械システム工学科 陳 鵬 助教授に深く謝意を表します。本研究を進めるにあたり、ご意見、ご討論、実験、論文のご校正などあらゆる面でご指導いただきました九州工業大学情報工学部機械システム工学科 二保知也 助手に深く感謝いたします。

また、本論文の調査委員として、論文の構成や内容につき懇切なご指導を賜りました本学情報工学部機械システム工学科 横関俊介 教授、田中博喜 教授、および同制御システム工学科 熊丸耕介 教授に対しまして、この場をかりて深くお礼を申し上げます。

九州工業大学大学院情報工学研究科情報システム専攻平成 11 年度修了千場隆之氏には、研究を進めるにあたり、ご意見、ご討論あるいはご協力いただきました。ここに感謝いたします。また、本研究を進めるにあたり、私の研究生生活を暖かく見守っていただきました豊田研究室、陳山研究室および同期の中国留学生の方々に感謝いたします。

最後に、私の心を支え、常に応援と激励をしてくれた研究の同士、生活の同士である妻の馮 芳氏に感謝します。

参考文献

- (1) 豊田利夫：回転機械診断の進め方，日本プラントメンテナンス協会，1991.
- (2) 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，1996.
- (3) 山崎弘郎：異常の検出と予知，工業調査会，1988.
- (4) S.Kullback：Information Theory and Statistics, John Wiley & Sons, Inc., New York, 1959.
- (5) 坂元慶行，石黒真木夫，北川源四郎：情報量統計学，共立出版株式会社，1993.
- (6) 南 敏：情報理論，産業図書，1997.
- (7) C.R.Rao：Linear Statistical Inference and Its Applications, John Wiley & Sons, Inc.,1973.
- (8) 熊丸耕介，Torsten SÖDERSTRÖM：カルバック識別情報量規範を用いた故障検出とモデル評価，計測自動制御学会論文集，Vol. 22, No. 10, pp. 1058-1065, 1986.
- (9) 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状態診断，日本設備管理学会誌，Vol. 10, No. 3, pp. 22-26, 1998.
- (10) 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，Vol. 58, No. 6, pp. 1041-1046, 1992.
- (11) 劉 信芳，豊田利夫，陳 鵬，二保知也，馮 芳：Information Divergence による回転機械の状態診断，精密工学会誌，Vol. 66, No. 1, pp. 157-162, 2000.
- (12) 田中正吾：一般化尤度比検定法に基づく線形ダイナミック・システムの異常検出，システム/制御/情報，Vol. 35, No. 12, pp. 769-778, 1991.
- (13) 熊丸耕介：ダイナミカルシステム統計的故障診断，システムと制御，Vol. 28, No. 2, pp. 77-86, 1984.
- (14) 状態診断・設備診断技術研究会：故障予知・異常予測，経営開発センター出版部，1981.
- (15) 大森豊明：普及版センサ技術，株式会社フジ・テクノシステム，1986.
- (16) Yi-The Lee：Information-Theoretic Distortion Measures for Speech Recognition, IEEE Transactions on Signal Processing, Vol. 39, No. 2, 330-334, 1991.
- (17) 劉 信芳，豊田利夫，陳 鵬，二保知也，馮 芳：多変量情報理論による回転機械の状態診断，2000年度精密工学会春季大会論文集，p. 100, 2000.
- (18) Xinfang Liu, Toshio Toyota, Peng Chen, Fang Feng：Multivariate Kullback-Leibler Information for Condition Diagnosis of Machinery, 4TH World Multiconference on Systemics, Cybernetics and Informatics, Oolando, U.S.A, 2000.

- (19) 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状態診断 (第 1 報, 振動信号の確率密度分布による摩耗系 (高周波型) 異常の診断), 日本設備管理学会誌, Vol. 11, No. 1, pp. 4-11, 1999.
- (20) D. Dyer and R. M. Stewart : Detection of Rolling Element Bearing Damage by Statistical Vibration Analysis, ASME Design Engineering Technical Conference, Paper No. 77-DET-83, 1977.
- (21) 奥野忠一, 久米 均, 芳賀敏郎, 吉澤 正 : 多変量解析法, 日科技連出版社, 1986.
- (22) 劉 信芳, 豊田利夫, 陳 鵬, 馮 芳, 二保知也 : 情報理論による回転機械の劣化傾向管理に関する研究, 日本信頼性学会誌, Vol. 21, No. 8, pp. 505-514, 1999.
- (23) Xinfang LIU, Toshio TOYOTA, Peng CHEN, Fang FENG, Zhengja HE : Study on Deterioration Trend Control for Rotating Machinery Using Information Divergence, Proc.1999 Int.Con.Advanced Manufacturing Technology, Science Press New York, Ltd., pp. 1041-1045, 1999.
- (24) 豊田利夫 : 予知保全[CBM]の進め方, 日本プラントメンテナンス協会, 1992.
- (25) 劉 信芳, 豊田 利夫, 前田 貞夫, 篠原 勇治, 小村 英智, 山上 洋之 : 情報理論による抗菌フィルタの寿命判定, 日本設備管理学会設備保全シンポジウム論文集, pp. 33-38, 2000.
- (26) 豊田利夫 : 機械システム診断の進め方, 日本プラントメンテナンス協会, 1998.
- (27) 木村芳一 : ポンプ用すべり軸受の選定について, エバラ時報, pp. 70-79, 2000.1.