



ファジィ・サポートベクターマシンによる 回転機械の複合異常状態の逐次診断法

Sequential Diagnosis Method for Multi-faults State of Rotating Machinery
Using Fuzzy Support Vector Machine

三重大学大学院	薛 紅涛	Hongtao XUE	
三重大学大学院	陳山 鵬	Peng CHEN	Member
三重大学大学院	神 豊	Yutaka JIN	
日本保全学会	宮 健三	Kenzo MIYA	Member

Abstract: When multi-faults state occurred in a plant rotating machine, because the relationship between fault types and vibration signals measured for the diagnosis are much more complex than the case of single fault, moreover, the condition diagnosis information from vibration signals is ambiguous, especially at early stage, the diagnosis for the multi-faults is more difficult. In order to resolve the problem, this paper proposes a new precise diagnosis method for rotating machinery using support vector machine (SVM) and fuzzy theory. Firstly, the optimal classification-line for distinguishing two states can be obtained using two SPs and SVM. Then the synthetic symptom parameter (SSP), that has higher sensitivity for the diagnosis, can be obtained according to the optimal line of classification. Finally a fuzzy diagnosis method is proposed to discriminate states of rotating machinery using the ambiguous diagnosis information. The practical diagnosis examples of bearing with multi-faults are provided to verify the effectiveness of the proposed method.

Keywords: sequential diagnosis, support vector machine, multi-faults state, optimal classification-line, synthetic symptom parameter.

1. はじめに

回転機械設備の診断を行う場合、複数の異常種類が同時に発生している状態を検知したケースはしばしば生じる。ここで、複数の異常種類が同時に発生している状態を「複合異常状態 (multi-faults state)」と言う。しかし、異常の部位から遠く離れた場所で測定した振動信号はノイズに強く影響され、特に早期段階における異常信号成分が比較的微小である^[1]。そのため、複合異常の特徴を反映する診断情報はあいまいであり、一般的に用いられている診断用の特徴パラメータ (symptom parameter: SP) の異常識別率は低い。また、複数の異常が互いの特徴を覆う場合や償う場合があるので、複合異常状態の診断は、

単一の異常状態の識別より困難である^[2]。

本研究では、あいまいな診断情報をもつ複合異常に対処するために、①複数の無次元特徴パラメータの中から異常識別率が上位のものを2つ選出し、サポートベクターマシン (support vector machine: SVM) により構成される最適な分類線に基づいて、高い識別率をもつ複合特徴パラメータ (Synthetic Symptom Parameter: SSP) を自動生成する方法を提案する。②あいまいな診断情報にも対処できるために可能性理論を用いたファジィ診断法を導入する。③多くの異常種類 (設備状態) を効率よく精密診断するために、各異常種類を逐次的に判定・識別する「逐次診断法」を提案する。また、回転機械の衝撃系異常の診断に適用する事例により、提案した諸方法の有効性を検証する。図1は提案した異常診断法の流れである。

連絡先: 陳山 鵬、〒514-8507 住所: 三重県津市栗真町屋町 1577 番地、所属先: 三重大学大学院、E-mail: chen@bio.mie-u.ac.jp

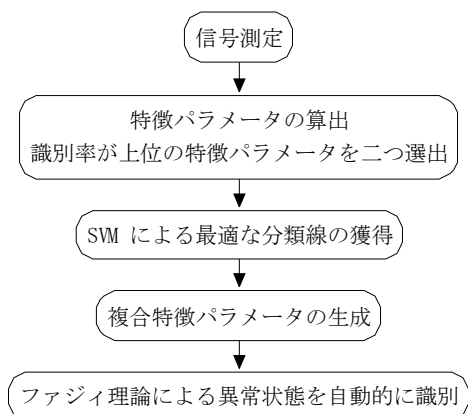


図1. 診断の流れ

2. 衝撃系異常振動信号の測定と無次元特徴パラメータ

2.1 正常状態と衝撃系異常状態の振動信号の測定

本研究で設備各状態診断のために使用した回転機械の機構図を図2に示す。右側の軸受（型番：NU204）台座に振動加速度センサー（Type: PCB MA352A60; Sensitivity: 10mV/g; Frequency: 5-60000Hz）を設置し、3軸（水平、垂直、軸方向）の振動加速度信号を測定、記録した。本報では垂直方向の信号のみを用いた。




図2. 診断対象の回転機械の機構図

また、衝撃系異常を早期に検出できるか否かを検討するために、軸受傷状態（広さ約0.3mmと深さ約0.05mmの傷）を放電ワイヤカットにより人工的に作成した。図3に示すように、外輪傷（O）、内輪傷（I）、転動体傷（E）の3種類に加え、外輪傷と転動体傷の複合異常（OE=O+E）、内輪傷と転動体傷の複合異常（IE=I+E）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100kHz、測定時間を20s、実験時の軸回転数を500rpmとして信号を測定した。カットオフ周波数を10kHzに設定したときに、各状態の振動加速度信号のスペクトルを図4に示し、また、図4には振動レベルを反映する実行値（RMS）も示している。



図3. 衝撃系異常状態の装置の写真

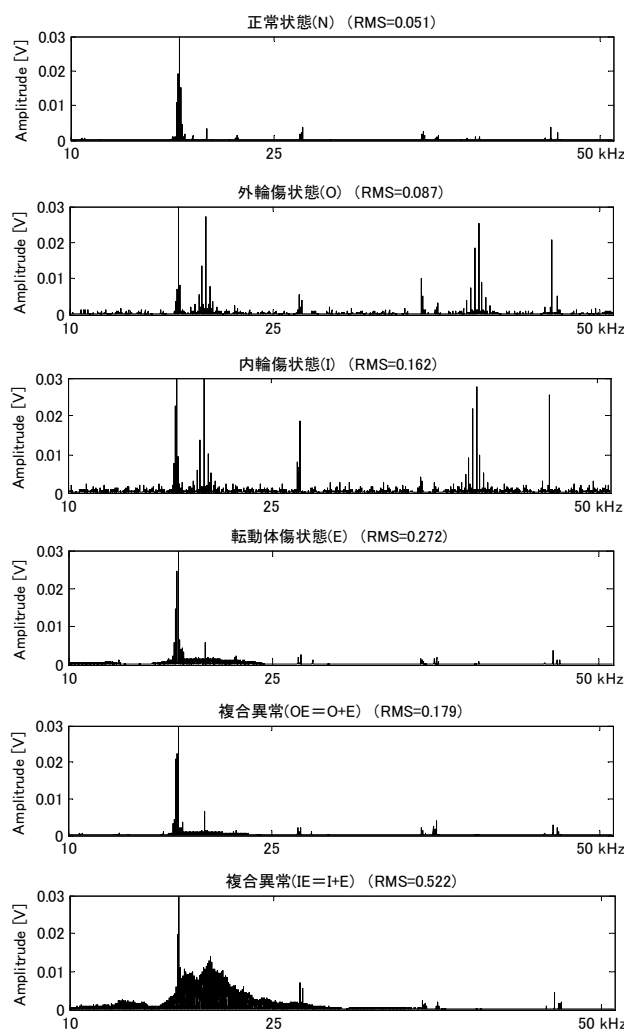


図4. 各状態の振動加速度信号のスペクトルおよび実効値RMS

図4を見れば分かるように、この軸受に傷が生じたときに、正常状態のスペクトルに比べ、約15kHzと40kHzの処に傷によるスペクトル成分が大きくなっている。なお、使用した振動加速度センサーは測定個所に接着剤で

固定され、その時の共振周波数が約 50kHz なので、この軸受の異常信号が十分に測れられたことが分かる。

2.2 無次元特徴パラメータ及びその評価法

自動診断システムを構築する時には、設備状態を反映する特徴パラメータが欠かせない^[4]。特徴パラメータは、時間領域、周波数領域におけるパラメータが定義されており、その中で、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。有次元特徴パラメータは、信号の平均値、実効値、ピーク値などのように単位（速度、加速度など）を持ち、信号の振幅の大きさ（量）を表すものである。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、単位を持たず、信号の大きさに関係なく、信号の形状を反映する^[1]。本研究では、診断対象が回転機械の衝撃系異常であり、初期段階での精密診断のために、無次元特徴パラメータ（以下の六つ）を用いる。また、測定した離散時系列のデータを $x_i (i=1 \sim N)$ とし、六つの特徴パラメータの計算式は次に示す。

$$\text{歪度: } p_1 = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{N \cdot \sigma^3} \quad (1)$$

$$\text{尖度: } p_2 = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{N \cdot \sigma^4} \quad (2)$$

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

$$\text{極大値の歪度: } p_3 = \frac{\sum_{i=1}^{N_p} (x_{pi} - \bar{x}_p)^3}{N_p \cdot \sigma_p^3} \quad (3)$$

$$\text{極大値の尖度: } p_4 = \frac{\sum_{i=1}^{N_p} (x_{pi} - \bar{x}_p)^4}{N_p \cdot \sigma_p^4} \quad (4)$$

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。 N_p はピーク値の総数である。

$$\text{極小値の歪度（絶対値）: } P_5 = \frac{\left| \sum_{i=1}^{N_v} (x_{vi} - \bar{x}_v)^3 \right|}{N_v \cdot \sigma_v^3} \quad (5)$$

$$\text{極小値の尖度（絶対値）: } P_6 = \frac{\sum_{i=1}^{N_v} (x_{vi} - \bar{x}_v)^4}{N_v \cdot \sigma_v^4} \quad (6)$$

ここで、 $x_{vi} (i=1 \sim N_v)$ は谷値（極小値）であり、 \bar{x}_v と σ_v はそれぞれ谷値（極小値）の平均値と標準偏差である。

どのパラメータが2状態の識別に適しているかは、識別率DRと識別指標DIによって評価できる^[2]。ここで、状態1と状態2で求めた特徴パラメータの値を x_1 と x_2 とし、 x_1 と x_2 の平均値をそれぞれ μ_1 と μ_2 、標準偏差を σ_1 と σ_2 とすると、識別率DRと識別指標DIは次式で表せる。

$$DR = 1 - \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{-DI} \exp\left(-\frac{z^2}{2}\right) dz \quad (7)$$

$$DI = \frac{|\mu_2 - \mu_1|}{\sqrt{\sigma_1^2 + \sigma_2^2}} \quad (8)$$

このとき、DIが大きければ大きいほどDRも大きいから、DIとDRは特徴パラメータの良否を評価する指標として用いられる^[5]。また、DI値は1.65以上で95%の識別率が得られることが知られている。

表1には各状態間の六つの特徴パラメータのDI値を示す。ここで、表1の中にアンダーライン () が付いているDI値は上位二つのものであるが、任意2状態間の特徴パラメータのDI値はあまり大きくない。そこで、SVMを用いて最適な分類線を探し、識別率の高い複合特徴パラメータを自動生成することによって診断精度を高める手法を提案する。

表1. 特徴パラメータのDI値及び選出

2状態	P_1	P_2	P_3	P_4	P_5	P_6	選出SPs
N, O	0.8	0.8	<u>1.1</u>	0.7	<u>1.2</u>	0.8	P_3, P_5
N, I	0.4	0.4	0.7	<u>1.0</u>	0.5	<u>0.9</u>	P_4, P_6
N, E	0.4	<u>1.1</u>	0.7	<u>1.1</u>	0.3	0.2	P_2, P_4
N, OE	0.3	0.4	<u>0.9</u>	0.4	<u>1.0</u>	0.5	P_3, P_5
N, IE	0.8	0.4	0.5	<u>1.0</u>	0.6	<u>0.8</u>	P_4, P_6
O, I	0.1	0.6	<u>1.0</u>	0.3	0.5	<u>0.8</u>	P_3, P_6
O, E	<u>0.4</u>	0.2	0.2	<u>0.6</u>	0.3	0.1	P_1, P_4
...
OE, IE	0.8	<u>1.0</u>	0.8	<u>1.2</u>	0.4	0.3	P_2, P_4

3. SVMによる複合特徴パラメータの生成法

3.1 SVMによる最適な分類線の獲得

SVMは、統計的学習理論に基づき、特にパターン認識の能力において、優れた学習・認識モデルの一つである。SVMでは、二次計画問題に帰着することを利用することによって、最適な分類問題を式(9)の最適解に転換する。よって、SVMで分類問題を解決するために重要なことは、

式 (10) のように最適な分類線を探査・構成することである^[5, 6]。

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j x_i x_j \quad (9)$$

$$\omega \cdot x + b = \sum_{i=1}^N \omega_i \cdot x_i + b = 0 \quad (10)$$

ここで、 x_i と x_j は $y_i(=1)$ と $y_j(=-1)$ を用いて表す2種類の学習データであり、 α_i と α_j は対応するLagrange乗数である。 N はデータの総数である。 $\omega_i(\in \omega)$ はシナプス荷重に対応するパラメータであり、 b はしきい値である。

パターン認識の実問題で線形分離可能な場合は稀である。しかし、若干の識別誤差を許容する範囲を設け、最適な分類線探索の制約条件を緩めれば、非線形分離と同様に、SVMを用いて常に最適な線形分類線のみを探査・構成することができる。これはいわゆる「ソフトマージンSVM」と呼ばれるものである。この手法により、最適な分類線とその方程式が得られる。例えば、図5に示すように正常と外輪傷の2状態に対しては、特徴パラメータ P_3 と P_5 を用いて、ソフトマージンSVMによる最適な分類線(H)が構成された。それぞれを識別するための2個の特徴パラメータを用いて、構成した最適な分類線の方程式を表2に示す。




図5. ソフトマージンSVMによる構成した最適な分類線

表2. SVMによる構成した最適な分類線の方程式

2状態	最適な分類線の方程式
N、O	$P_3 + P_5 - 3 = 0$
N、I	$P_4 + P_6 - 32 = 0$
N、E	$P_2 + 3P_4 - 60 = 0$
N、OE	$P_3 + 5P_5 - 15 = 0$
N、IE	$2P_4 - P_6 - 13 = 0$
O、I	$11P_3 + P_6 - 37 = 0$
O、E	$14P_1 + P_4 - 19 = 0$
...	...
OE、IE	$P_2 + P_4 - 964 = 0$

3.2 複合特徴パラメータの生成

従来の原始特徴パラメータ (SPs) では、表1に示すように最大識別指標DIは1.2 (識別率DR=88%)であり、各2状態の識別精度が高くない。そのため、自動診断システムを実現するには、高い識別率の特徴パラメータを探査することは必要である。本研究では、SVMにより求めた最適な分類線を基準にして、新たに特徴パラメータを「複合特徴パラメータ: SSP」と定義する。

原始特徴パラメータ P_i と P_j を用いて、SVMにより求めた最適な分類線が $a \cdot P_i + b \cdot P_j + c = 0$ である場合の複合特徴パラメータ (SSP) の計算式は式 (11) に示す。

$$H = \frac{|a \cdot P_i + b \cdot P_j + c|}{\sqrt{a^2 + b^2}} \cdot \text{sign}(a \cdot P_i + b \cdot P_j + c) \quad (11)$$

ここで、 a, b, c は最適な分類線の方程式の係数である。また、関数 $\text{sign}(x)$ は、 $x > 0$ のとき1をとり、 $x = 0$ のとき0をとり、 $x < 0$ のとき-1をとる符号関数である。

式 (11) により、SSPの実質は、点 $A(P_i, P_j)$ が最適な分類線(L)に垂直な数直線(H)上に投影される点 A_1 の値である。図6に示す、H軸は複合特徴パラメータ(SSP)の座標軸である。

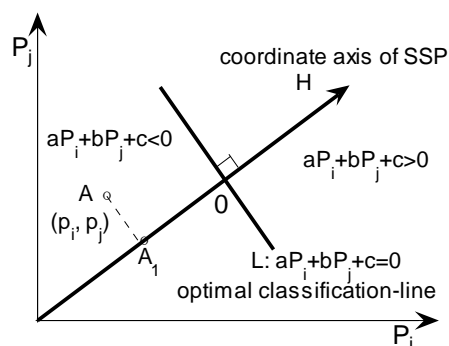


図6. 複合特徴パラメータの生成例法の説明図

表3. 複合特徴パラメータ (SSPs) のDI値

2状態	選出のSPs	SPsのDI値	SSPのDI値
N、O	P_3, P_5	1.1, 1.2	1.6
N、I	P_4, P_6	1.0, 0.9	1.7
N、E	P_2, P_4	1.1, 1.1	1.8
N、OE	P_3, P_5	0.9, 1.0	1.6
N、IE	P_4, P_6	1.0, 0.8	1.5
O、I	P_3, P_6	1.0, 0.8	1.4
O、E	P_1, P_4	0.4, 0.6	0.9
...
OE、IE	P_2, P_4	1.0, 1.2	1.6

表3は、任意の2状態における選出したSPsを用いて、SSPsを生成し、そのDI値を計算した。結果は、SPsのDI値よりSSPsのDI値の方が大きくなっており、SSPsを新たに生成することによって識別の精度が向上したことがわかる。

4. ファジィ理論による逐次診断

4.1 ファジィ理論

特徴パラメータ x の確率密度関数を最大値1とした可能性分布関数に変換する^[3, 8, 9]。可能性分布関数は

$$p(x_i) = \sum_{k=1}^N \min\{\lambda_i, \lambda_k\} \quad (12)$$

により求められる。ここで、

$$\lambda_i = \int_{x_{i-1}}^{x_i} \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{(x-\bar{x})^2}{2\sigma^2}\right\} dx \quad (13)$$

$$\lambda_k = \int_{x_{k-1}}^{x_k} \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{(x-\bar{x})^2}{2\sigma^2}\right\} dx \quad (14)$$

である。ただし、 \bar{x} と σ はその平均値と標準偏差であり、 $x \in (\bar{x} - 3\sigma, \bar{x} + 3\sigma)$ である。 N は x が定義される区間を N 等分する意味である。図7は複合特徴パラメータ x の確率密度関数 $f(x)$ を最大値1とした可能性分布関数 $p(x)$ に変換する例である。




図7. 可能性分布関数の変換例

実際に状態の識別を行う時に、モデルとなる可能性分布関数 $p_{ni}(x)$ と識別したい状態の可能性分布関数 $p_t(x)$ のマッチングにより得られる診断の可能性結果は

$$w_i = p_{ni}(x) \wedge p_t(x) \Big|_{x=\bar{x}_i} \quad (15)$$

から求められる。 i はモデルの種類を表す。 \bar{x}_i は診断用の複合特徴パラメータ x の平均値である。図8のように簡易診断の例による可能性分布関数を用いたファジィ理論法を説明すると、 $p_{n1}(x)$ と $p_{n2}(x)$ はモデルとして正常と正常以外、つまり異常状態の可能性分布関数を表す。 $p_t(x)$ は識

別したい状態の可能性分布関数を表す。 $p_{n1}(x)$ と $p_t(\bar{x}_i)$ が交わる点 A の値 w_1 は、診断対象が正常状態である可能性である。それと同様に、 $p_{n2}(x)$ と $p_t(\bar{x}_i)$ が交わる点 B の値 w_2 は、診断対象が異常状態である可能性である。正常状態の可能性 w_1 が異常状態の可能性 w_2 よりも大きくなれば、正常であると簡易診断することができる。




図8. ファジィ理論法による簡易診断の例

4.2 逐次診断

SVMにより得られた複合特徴パラメータを用いて、ファジィ理論における診断方法と統合し、逐次的に回転機械の状態を検出・識別する「逐次ファジィ診断法」を提案する。

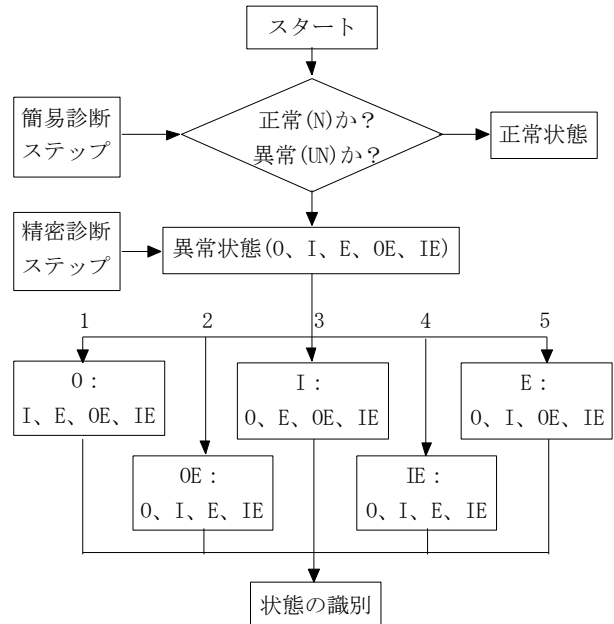


図9. 逐次ファジィ診断法の流れ

図9は衝撃系異常（軸受異常）の診断の流れである。最初の簡易診断ステップでは、正常か異常かを判別する。まず、異常状態を識別するために、それぞれの異常状態を表すファジィ診断のモデルを構成する。次にファジィ理論によって評価を総合して診断する。正常の場合、診

断システムは自動的に停止するが、軸受異常が発生している場合は、診断システムは精密診断ステップへ移行し、異常種類を特定していく。本実験は異常状態5つ設定しているため、精密診断ステップでは、図9のように5つのパターンでファジィ診断を行うことが必要である。

4.3 実験への適用

本手法により生成した各2状態の複合特徴パラメータ (SSPs) を用いて、逐次ファジィ診断システムを構成した。本研究で提案した諸手法の有効性を検証するために、人工的に設定した各既知状態 (N、O、I、E、OE、IE) の振動信号を新たに測定し、同じ処理方法により逐次診断における各2状態のSSPsを算出し、ファジィ理論による各状態の診断を行った。図10は、新たに計測した検証用の信号を用いて、簡易診断ステップで異常状態と判別した後、精密診断ステップの第1パターンで診断を行った例である。

第1パターンは、図8に示すように、外輪傷状態 (O) と他の異常状態 (I、E、OE、IE) とを識別するための診断パターンである。図10の h は各2状態の複合特徴パラメータ (SSPs) を表す。 $p_o(h)$ は外輪傷状態 (O) の可能性分布関数である。また、 $p_i(h)$ 、 $p_e(h)$ 、 $p_{oe}(h)$ 、 $p_{ie}(h)$ はそれぞれ他の異常状態 I、E、OE、IE の可能性分布関数である。 $p_x(h)$ は上記の各状態以外の未知状態の可能性分布関数であり、 $p_t(h)$ は識別したい状態の可能性分布関数である。また、 h_0 は識別したい状態の複合特徴パラメータ (SSP) の平均値であり、 w_o 、 w_i 、 w_e 、 w_{oe} 、 w_{ie} 、 w_x は各状態の可能性 (診断結果) である。

表4は精密診断の第1パターンで識別したい状態の診断結果である。ファジィ理論によりこの状態は外輪傷状態である可能性が96.5%であると判別した。同様に、第2、3、4、5パターンで、この状態は異常状態 I、E、OE、IE での可能性は52.2%、47.8%、72.4%、45.1%であることを判明した。従って、この状態は外輪傷状態であると判定できる。

表4. 精密診断の第1パターンで識別したい状態の診断結果

回目	モデルの状態		ファジィ診断の可能性 (%)		
	状態1	状態2	状態1	状態2	未知状態
A	O	I	95.3	47.6	0.3
B	O	E	97.1	35.5	0.1
C	O	OE	96.6	64.7	0.1
D	O	IE	96.9	24.4	0.4

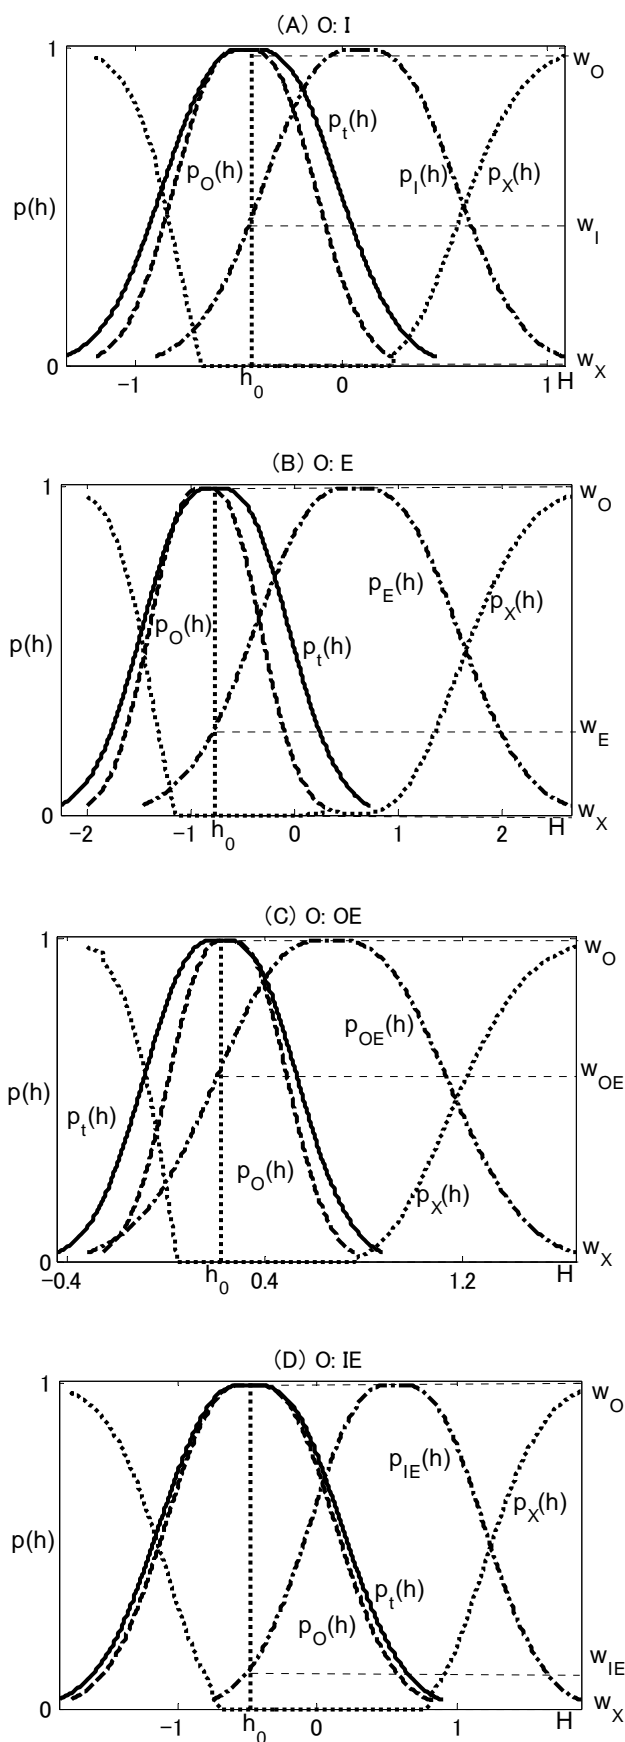


図10. ファジィ理論による第1パターンで逐次診断の一例

同様に、新たに測定した各振動信号を用いて、自動的に診断した結果は、表5に示すように、何れも正しく状態を判定したことがわかる。

表5. ファジィ理論による各状態の診断結果

設 定 状 態	簡易診断ステップ		精密診断ステップ					診 断 結 果
	各状態の可能性 (%)		各状態の可能性 (%)					
	N	UN	O	I	E	OE	IE	
N	92.1	7.9						N
O	23.5	77.5	96.5	52.2	47.8	72.4	45.1	O
I	25.0	75.0	34.2	90.7	10.9	16.9	58.9	I
E	19.8	80.2	18.8	20.1	92.5	47.4	50.2	E
OE	14.3	85.7	50.3	10.2	42.8	89.1	39.5	OE
IE	20.4	79.6	17.4	43.5	49.1	39.8	94.6	IE

5. 結論

本研究では、回転機械の衝撃系異常の早期段階から単一・複合の異常を敏感かつ自動的に検出するために、「SVMによる複合特徴パラメータ (SSPs) の自動生成法」、「ファジィ理論による自動的な逐次診断法」の2つの手法を提案し、実例によりその有効性を検証した。本報で提案・報告した主な内容は次のようにまとめられる。

(1) 任意の2状態に対して SVM により複合特徴パラメータ (SSPs) の生成を行うことができた。また、SSPsの識別率は一般の特徴パラメータ (SPs) の識別率より高いことがわかり、この手法の有効性を示すことができた。

(2) 生成した SSPs を用いて、ファジィ理論によりあいまいな診断情報をもつ異常の早期段階での異常や複合異常を診断できることを示せた。

(3) 本研究で提案した逐次ファジィ診断システムを回転機械の衝撃系早期異常 (単一・複合異常) で検証した結果、正確に診断することができ、システムの有効性が示せた。また、このシステムは他の異常状態の診断へ拡張適用することも可能である。

今後の課題は、本研究で提案した方法を衝撃系 (軸受異常) 以外の異常状態 (複合異常状態を含む) に適用して、診断可能な異常種類と限界を究明し、実際の生産現場の回転機械設備へ応用・検証を行うことである。

参考文献

- [1] B. Liu and S-F. Ling, "On the Selection of Informative Wavelets for Machinery Diagnosis", *Mechanical Systems and Signal Processing*, Vol.13, 1999, pp.145-162;
- [2] 陳山鵬, "回転機械設備診断の基礎と応用", 三恵社出版, 2009.4.
- [3] P. CHEN and T. TOYOTA, "Fuzzy Diagnosis and Fuzzy Navigation for Plant Inspection and Diagnosis Robot", in 1995 Proc. of FUZZ-IEEE/IFES'9, pp.185-193.
- [4] 薛紅濤, 陳山鵬, "時間領域の特徴パラメータとサポートベクターマシンによる設備診断法", *保全学*, Vol.10, No.3, 2011, pp. 51- 57.
- [5] Achmad Widodo and Bo-Suk Yang, "Application of nonlinear feature extraction and support vector machines for fault diagnosis of induction motors", *Expert Systems with Applications*, Vol. 33, Issue 1, 2007, pp. 241-250.
- [6] Achmad Widodo and Bo-Suk Yang, "Support vector machine in machine condition monitoring and fault diagnosis", *Mechanical Systems and Signal Processing*, Vol.21, Issue 6, 2007, pp. 2560-2574.
- [7] Steve R. Gunn, "Support Vector Machines for Classification and Regression", Technical Report, University of Southampton, May, 1998.
- [8] D. Dubois and H.Prade, "Possibility Theory: An Approach to Computerized Processing", Plenum Press, New York, 1988.
- [9] 豊田利夫, P. Chen, "可能性理論と Dempster & Shafer 確率理論による異常検出法", *北九州医工学術者協会誌*, Vol. 9, No. 1, 1998, pp. 1- 4.

(平成 24 年 4 月 19 日)