



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 —回転機械の構造系異常診断への応用—

Condition Diagnosis Method Based on Symptom Parameters in Time Domain and Support Vector Machine and Application to Diagnose Structural Faults of Rotating Machinery

三重大学大学院 薛 紅涛 Hongtao XUE
三重大学大学院 陳山 鵬 Ho JINYAMA Member

Abstract: Many intelligent diagnosis methods, such as neural networks, genetic algorithms, etc., have been proposed in the field of mechanical fault diagnosis. These methods require a large number of training data and highly sensitive symptom parameters (SPs). However, in many cases of condition diagnosis for rotating machinery, because the training data cannot be easily acquired in a real plant, and SPs are not highly sensitive, the intelligent methods, namely neural networks, genetic algorithms, etc., often cannot converge when learning. In order to solve these problems, this paper proposes a new intelligent method by which the fault of rotating machinery can be sensitively detected and diagnosed by using Support Vector Machine (SVM) and symptom parameters in time domain. We have used the method to diagnose structural faults of rotating machinery, and the efficiency of the proposed method is verified by practical examples of the condition diagnosis.

Keywords: support vector machine, condition diagnosis, rotating machine, symptom parameter.

1. はじめに

回転機械設備の異常状態の内、アンバランス、緩み、ミスアライメントなどが最も発生しやすい異常種類であり、これらの異常は低周波数領域に異常振動の特徴をもち、「構造系異常」と言われている^[1]。構造系異常は設備性能や製品品質に直接的な悪影響を与えるだけでなく、軸受や歯車などの周辺部品にも過度のストレスを与え、二次故障を引き起こす原因ともなるため、構造系異常の早期診断は極めて重要な課題である。生産現場で回転機械診断を行うときには、診断のために測定した振動信号がノイズや運転条件の影響を受けるため、従来の特徴パラメータやスペクトルなどを用いた診断方法では構造系異常を検出・識別しにくいケースがしばしば生じる^[1]。また、従来のニューラルネットワーク (neural network: NN) による構造系異常の自動検出法では多量の学習データを必要とするが、現場で学習に満足できる十分な学習データを得ることが困難である^{[2][3]}。さらに、ノイズなどの影響により学習データが曖昧性をもつため、ニューラルネットワークの学習が常に収束することも保証できず、実用的な診断システムの構築が困難な場合が多い^{[2][3]}。

従って、本論文では、回転機械設備状態を診断するために振動加速度信号を測定し、設備状態 (振動信号の特徴) を反映する時間領域の特徴パラメータを用いて、サポートベクターマシン (support vector machine : SVM) により複数の特徴パラメータを統合することにより設備異常を自動的に検出・識別する方法を提案する。また、多くの異常種類を効率よく精密診断するために、各異常種類 (設備状態) を逐次的に判定・識別する「逐次診断法」も提案し、回転機械の構造系異常 (アンバランス、ミスアライメント、緩み) の診断に適用し、実際の診断例で提案した方法の有効性を検証する。

2. 時間領域の特徴パラメータ及びその診断感度の評価法

知的診断システム (あるいは、自動診断システム) を構築するときには診断信号の特徴 (設備状態) を反映する特徴パラメータ (symptom parameter: SP) が欠かせない。特徴パラメータは時系列データで計算される時間領域の特徴パラメータと、スペクトルから算出される周波数領域の特徴パラメータに分けられる^[4]。本研究では、診断対象が回転軸の構造系異常であるため、構造系異常波形

の特徴を比較的敏感に反映し、計算式が比較的簡単な時間領域の特徴パラメータ（以下の5つ）を用いる。測定した離散の時系列データを $x_i (i=1\sim N)$ とする。5つの特徴パラメータの計算式は次に示す。

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

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。

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

$$\text{波高率: } p_3 = \frac{\sum_{i=1}^{N_p} |x_i|_p}{\sigma \cdot N_p} \quad (3)$$

ここで、 $|x_i|_p$ は信号の絶対値のピーク値（極大値）であり、 N_p は信号の絶対値ピーク値の総数である。なお、本研究では、20個の最大ピーク値（ $N_p = 20$ ）を用いて、 p_3 を算出した。

$$\text{極大値の歪度: } p_4 = \frac{\sum_{i=1}^{N_{pp}} (x_{pi} - \bar{x}_p)^3}{N_p \cdot \sigma_p^3} \quad (4)$$

$$\text{極大値の尖度: } p_5 = \frac{\sum_{i=1}^{N_{pp}} (x_{pi} - \bar{x}_p)^4}{N_p \cdot \sigma_p^4} \quad (5)$$

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_{pp} はピーク値の総数である。

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^[5]。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。

$$DR = 1 - \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{-DI} \exp\left(-\frac{z^2}{2}\right) dz \quad (6)$$

$$DI = \frac{|\mu_2 - \mu_1|}{\sqrt{\sigma_1^2 + \sigma_2^2}} \quad (7)$$

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]。

3. サポートベクターマシン (SVM) による自動診断法

3.1 サポートベクターマシン (SVM) について

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り、カーネルトリックと呼ばれる方法を用いて、最適な識別関数を構成し、特徴空間で分離超平面（線）を探して、未学習データに対して高い識別性能を実現することができる。SVMで分類問題を解決するために重要なことは、最適な分離超平面（線）を探索・構成することである^{[6][7]}。

最適な分離超平面（線）とは2種類のデータ同士の距離（これをマージンと呼ぶ）が最大になるような分離超平面（線）が、最も汎化能力の高い唯一の超平面（線）になるということである。この分離超平面（線）は未学習のデータを分類する基準である^[8]。SVMは、一方で式(8)のように2次計画問題に帰着することを利用することによって、最適な分類問題では唯一の最適解を求めることができ、局所的最適解に陥る心配がない。他方で分類面が線形で無い場合は、カーネルトリック $K(x_i, x_j)$ と呼ばれる手法を用いて入力空間をより高次の特徴空間に写像し、そこで線形分離を行う。

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (8)$$

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。

最適な分離超平面(線)は式(9)で表せる、未学習データの診断結果は式(10)のように判別関数を用いて計算した数字 Y_i で表せる。

$$f(x) = \omega \cdot x + b = \sum_{i=1}^N \omega_i \cdot x_i + b = 0 \quad (9)$$

$$Y_i = \text{sign}(f(x)) = \text{sign}(\omega \cdot x + b) \quad (10)$$

ここで、 $\omega_i (\in \omega)$ 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。また、関数 $\text{sign}(u)$ は、 $u > 0$ のとき1をとり、 $u < 0$ のとき-1をとる符号関数である。

SVMの仕組はFig.1に示すようなモデル図でも説明で

きる。すなわち、入力層（診断情報）から出力層（診断結果）への結合荷重を学習により適応的に求め、あらかじめ中間層に多くのユニットを適切に用意することで、識別すべき様々なパターンに適した非線形写像（識別関数）を構成することができる。




Fig.1 SVM's model

3.2 SVMによる設備診断法

SVMによる設備異常を自動的に検出・識別するために、本論文では、Fig.2のようなSVMによる自動診断法を提案する。診断のために測定した振動信号から複数の特徴パラメータを算出し、識別率の高い特徴パラメータを選出した後、診断用のSVMを構成するための学習データ（各状態における特徴パラメータの値）を獲得する。SVMで2状態を線形識別できれば、できるだけ線形分類を利用し、分離超平面（線）を構成する。線形識別できなければ、適切なカーネルトリックを選んだ後、最適な分離超平面（線）を構成する。なぜならば、カーネルトリックを用いて、高次の特徴空間への写像を行うと、次元の増加に伴い汎化能力が落ちるだけでなく、膨大な計算量が必要となるからである。構成した分離超平面（線）によって、未学習データを自動分類し、状態を判定する。

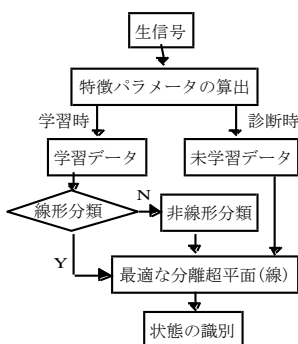


Fig.2 Intelligent diagnosis method based on SVM

多種類の異常を診断するために共通に使える良好な特徴パラメータを見つけることが困難であるから、Fig.3に示すような「逐次診断法」を提案し、SVMによる自動診断に応用する。たとえば、Fig.3に示す3種類の構造系異常（アンバランス、ミスアライメント、緩み）を診断するために、診断プロセスは3ステップに分けられる。第1、2、3ステップではそれぞれ正常か異常かの診断、アンバランスか、ミスアライメントあるいは緩みかの診断である。なお、第3ステップの診断においては、ミスアライメントあるいは緩みでなければ、他の異常が発生していると判定される。

このように、各診断ステップにおいて2状態を識別すればよいから、特徴パラメータの選出およびSVMによる自動診断システムの構築が容易になる。

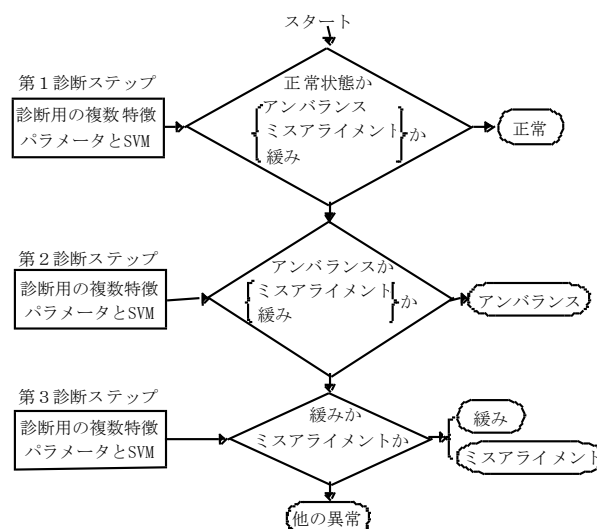


Fig.3 Sequential diagnosis based on SPs and SVM

4. 実験への適用

4.1 正常状態と構造系異常状態の信号の測定

Fig.4は回転軸に動・静負荷が加えられる回転機械シミュレータである。左、右側の軸受台座に3軸（水平、垂直、軸方向）の振動加速度信号を測定、記録したが、本報では右側の軸受台座の垂直方向の信号のみを用いた。





Fig.4 Experimental equipment for fault diagnosis

また、Fig.5に示すように、アンバランス (U)、緩み (L)、ミスアライメント (M) の構造系異常状態を人工的に設定し、正常状態 (N) と合わせて 4 状態の振動加速度信号を測定した。なお、異常を早期に検出できるか否かを検討するために、Fig.5 のように比較的軽微な各異常状態を設定した。実験時の軸回転数は 1500rpm とした。



(A) Unbalance (B) Looseness (C) Misalignment

Fig.5 abnormal states of structural fault

Fig.6 は、軸の鉛直方向に 150kg の負荷を加えた時に測定した各状態の振動加速度信号の 1 秒間の時系列波形を示す。データを測定した時のサンプリング周波数は 5kHz であった。データは 20 秒測定し、16 分割した。構造系異常は低周波数領域に異常振動の特徴を持つので、500Hz のローパスフィルタをかけてノイズ等を除去した後、(1)~(5)式に示す 5 つの特徴パラメータの値を計算した。

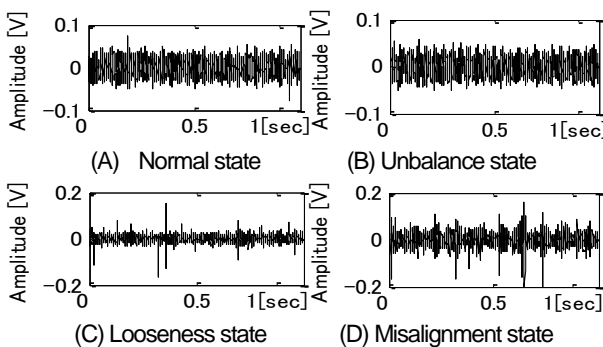


Fig.6 Vibration signals in each state

Table 1 The DI and DR value of SPs

States	Value	P ₁	P ₂	P ₃	P ₄	P ₅
N vs. UN	DI	0.96	1.18	0.49	0.69	0.44
	DR	83%	88%	69%	75%	67%
U vs. LM	DI	0.71	1.19	0.69	0.67	0.65
	DR	76%	88%	75%	74%	73%
L vs. M	DI	1.32	1.09	0.58	0.90	0.91
	DR	91%	86%	72%	82%	82%

Table 1 には各状態間の DI 値と DR 値を示している。Table 1 の中には、「N vs. UN」、「U vs. LM」および「L vs. M」は、それぞれ Fig.3 の各診断ステップに対応する「正常状態 (N) と異常状態 (UN=U+L+M)」、「アンバランス (U) とアンバランスでない (L, M)」および「緩み (L) とミスアライメント (M)」を意味するものである。よって、DI 値が比較的大きい特徴パラメータ P₁、P₂ を用いて、各ステップの状態の識別を行っていく。

4.2 SVM による最適な分離超平面 (線) の獲得

Fig.3 に示すように第 1 診断ステップでは、正常 (N) と異常 (UN) という 2 状態を識別する時に、Y_n(y_i=1、-1) という記号を用いて、正常と異常の状態を表し、様々な状態の特徴パラメータ P₁ と P₂ の中から 8 個を任意に選定し、Table 2 に示す学習データを構成した。

Table 2 Training data of normal and abnormal

P1	P2	Y _n	State
1.02	17.59	1	N
...
0.28	18.51	1	N
0.47	10.86	-1	UN
...
0.12	9.53	-1	UN

最適な分離超平面 (線) を探す問題は Lagrange 乗数を導入することにより双対問題に変形できる。

$$\text{Minimize: } -\sum_{i=1}^N \alpha_i + \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i \cdot x_j) \quad (11)$$

$$\text{Subject to: } \alpha_i \geq 0, i = 1, \Delta, N \quad (12)$$

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (13)$$

Table 2 の学習データに基づき、式(12)、(13)を用いて計

算した Lagrange 乗数 α の値は Table 3 に表す。

Table 3 Lagrange coefficient

State	the value of α corresponding with X_n			
N	3.1E+09	<u>3E-15</u>	3E+09	<u>2E-15</u>
	<u>3E-15</u>	8.4E+09	<u>5E-15</u>	3.4E+09
UN	<u>1E-15</u>	2.1E+09	<u>1E-15</u>	<u>2E-15</u>
	<u>1E-15</u>	1.6E+10	<u>1E-15</u>	<u>1E-15</u>

このとき Karush-Kuhn-Tucker 条件

$$\alpha_i [y_i (\omega \cdot x_i + b) - 1] = 0 \quad (14)$$


が要求されるために、 $y_i (\omega \cdot x_i + b) = 1$ に対応する解 α_i だけは 0 でない。即ち、 $\alpha_i > 0$ に対応する学習データ x_i は超平面(線)を構成する要素であり、サポートベクター (SV) と呼ばれる。 α ($\alpha_i > 0$) は最適解 α^* と呼ばれる。Table 3 の中にアンダーライン () が付いている数値がほぼゼロであるので、ゼロでない最適解 α^* ($\alpha_i > 0$) が 6 個ある。これらの最適解 α^* を用いて、

$$\omega = \sum \alpha^* y_i x_i (x_i \in SV) \quad (15)$$

$$b = y_i - \omega \cdot x_i (x_i \in SV) \quad (16)$$

と求めることができる。これにより、式(10)に示した判別関数が求められ、Fig.7(A)に示すように分離超線も獲得できる。これは線形分類と呼ばれる。

線形分類は取り扱うデータ数が多い場合、あるいはデータに曖昧性がある場合は精度の高い分類が困難である。そこで、線形分類の効果が良くないときには非線形分類が行える。Table2に示したデータの例に対して多項式カーネルとガウスRBFカーネルを選択し、元空間で求めた分離曲線はFig.7(B), (C)に示す。学習した結果は良好であり、訓練時間、マージン、SV数はTable 4に示す。



(A) Linear (B) Polynomial (C) Gaussian RBF

● Normal state (N) ○ Abnormal state (UN)


Fig.7 Hyper-planes corresponding kernel functions

Table 4 Training results corresponding kernel functions

Kernel	Linear	Polynomial	Gaussian RBF
Execution time	0.01	0.012	0.012
Margin	0.001	0.1456	0.21499
SVs	6	4	4

Table 4により多項式カーネルとガウスRBFカーネルの訓練時間とサポートベクター数が同じだが、ガウスRBFカーネルを使用した時のマージンが大きいので、ガウスRBFカーネルを用いて求めた識別関数は比較的良いといえる。従って、Fig.3に示した第1診断ステップでは、Fig.7(C)に示すガウスRBFカーネルを用いて構成した曲線を最適な分離線として診断に適用する。

第1診断ステップにおいて正常か異常かを診断するための最適な分離線の獲得と同様に、第2, 3診断ステップでも、アンバランス状態、緩み状態とミスアライメント状態を診断するために、まず線形分類を用いて識別してみる。線形分類の識別率が100%であれば、それを用いて各異常状態を識別する。そうでなければ、ガウスRBFカーネルを用いて最適な分離超平面(線)を構成する。Fig.8は第2診断ステップにおいてアンバランス(U)とその他の異常状態(LM)を診断するための最適な線形分離線である。Fig.9(A)は第3診断ステップにおいて緩み(L)とミスアライメント(M)を診断するための線形分離線であるが、線形分類の精度が高くないため、ガウスRBFカーネルを用いてFig.9(B)に示す最適な非線形分離曲線を構成した。



● Unbalance (U) ○ Looseness and misalignment (LM)

Fig.8 Optimal hyper-plane of linear

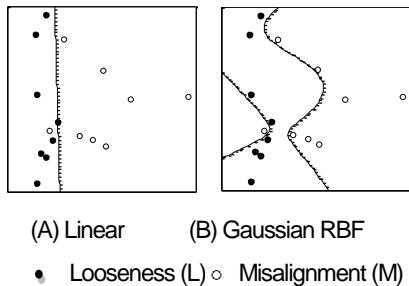


Fig.9 Optimal hyper-planes corresponding kernel functions

4.3 SVMによる自動診断の結果

本論文で提案した諸手法の有効性を検証するために、4.1節で示した実験条件で既知状態(N、U、L、M)の振動信号を新たに測定した。未学習のデータとして特徴パラメータ P_1 、 P_2 を求め、式(10)に基づいて各診断ステップのために構成した最適な分離線 (SVM 分類器の判別関数) を用いて、自動的に診断した結果は、Table5~Table7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。よって、本論文で提案した諸手法は有効であり、また、アンバランス、緩み、ミスアライメント以外の異常状態の診断へ拡張応用することも可能である。

Table 5 Diagnosis results of normal and abnormal

P1	P2	Yt	Judge
1.06	18.57	1	N
1.04	16.72	1	N
...
2.61	37.43	-1	UN
0.2	11.56	-1	UN
...

Table 6 Diagnosis results of unbalance in abnormal

P1	P2	Yt	Judge
2.28	34.09	1	U
1.63	34.42	1	U
...
0.2	11.56	-1	LM
0.12	15.61	-1	LM
...

Table 7 Diagnosis results of looseness and misalignment

P1	P2	Yt	Judge
0.2	11.56	1	L
0.27	14.79	1	L
...
5.61	9.22	-1	M
5.9	7.64	-1	M
...

4.4 NNによる診断結果との比較

SVM とニューラルネットワーク(NN)との性能を比較するために、Fig.3 に示す各診断ステップに対応して、Fig.10のようなニューラルネットワーク(NN)を構成した。それぞれの状態において同じ数の学習データ(8個)を用いて、学習回数を 10^5 として学習させた。第1、2診断ステップ用のNNが収束した(誤差 <0.001)が、第3診断ステップ用のNNの収束が良くなかった(誤差 >0.1)。




Fig. 10 Neural network for the diagnosis

各診断ステップにおいて学習済みのNNを用いて、同じ未学習データ(8個)に対して診断した結果はTable 8に示す。第2診断ステップにおける診断結果が良かったが、第1、3診断ステップでは誤診断が多かった。また、各診断ステップにおける訓練時間を比較すると、SVMでは0.1秒程度であったが、NNでは200秒以上かかった。

Table 8 Diagnosis results of the NN in the three steps

System	State	Accuracy
First step	normal	87.5%
	abnormal	75%
Second step	unbalance	100%
	other abnormal	100%
Third step	looseness	75%
	misalignment	62.5%

なお、ニューラルワークの構造(中間層数と中間層のニューロ数)を変えたり、学習データを増やしたりして学習させることにより診断精度を高める可能性もあるが、あくまで試行錯誤的に行う手段であるから、SVMに比べて、診断システムを構築する効率が悪いことがわかる。

5. 結論

本論文では、回転機械の構造系異常の初期段階から異常を敏感かつ自動的に検出・診断するために、SVMによ

る回転機械診断法を提案し、実例によりその有効性を検証した。本論文で提案・報告した主な内容は次のようにまとめられる。

(1)少量の学習データに対しても高い識別の汎化性能をもつSVMを用いることにより、異常の早期段階や個別特徴パラメータの識別率が低い場合も、SVMによる設備状態の識別結果が良好であった。

(2)SVMによる異常状態の診断法を用いれば、ニューラルネットワークで自動診断システムを構築する時に生じる学習の非収束問題を解決し、線形識別関数と非線形識別関数の選択も可能である。

(3)本論文で提案した方法を回転機械の構造系異常（アンバランス、ミスアライメント、緩み）の診断に適用し、実際の診断例で提案した方法の有効性を検証した。

今後課題としては、以下のように考える。

(1)多くの現場データを用いて提案した諸手法を更に検証すると共に、他の異常状態の診断への適用、

(2)今回の診断対象は定常運転条件における異常状態であるが、可変運転条件における設備（負荷も回転数も変動する設備）の異常診断についての研究、

(3)また、今回の診断対象は単一の異常状態であったが、複合異常診断法についての研究、

(4)SVMの汎化性についての研究、

などを行う予定である。

参考文献

- [1] 陳山鵬：回転機械設備診断の基礎と応用、三恵社出版、2009.4.
- [2] Christopher M. Bishop: Neural Networks for Pattern Recognition, Oxford University Press, 1995.
- [3] B. Samanta and K. R. Al-Balushi, “Artificial neural network based fault diagnostics of rolling element bearings using time-domain features”, Mechanical Systems and Signal Processing, Vol. 17, No. 2, 2003, pp. 317-328.
- [4] 陳山鵬、三笥哲郎、里永憲昭、豊田利夫：時間領域の有・無次元特徴パラメータの統合による回転機械設備の状態診断法、日本設備管理学会誌, Vol.19, No.2, 2007, pp.56-65.
- [5] Peng Chen, Toshio Toyota and Zhengjia He, Automated Function Generation of Symptom Parameters and Application to Fault Diagnosis of Machinery under Variable Operating conditions; IEEE TRANSACTIONS ON SYSTEMS '01. No.6, pp. 775-781.
- [6] Achmad Widodo and Bo-Suk Yang, Application of nonlinear feature extraction and support vector machines for fault diagnosis of induction motors; SCIEDIRECT '07. pp.241-250.
- [7] Yongdang-dong, Nam-gu and Busan, Support vector machine in machine condition monitoring and fault diagnosis. Dec.2006, pp. 608-739.
- [8] Steve R. Gunn, Support Vector Machines for Classification and Regression, May 10th. 1998.

(平成23年2月7日)