

卒業論文

サポートベクターマシンを用いた
複合材料積層板の損傷同定手法の検証

1 ~ 37 ページ完

平成 16 年 2 月 6 日

指導教官 酒井信介教授

20171 佐野 孝浩

目次

第1章 序論	4
1.1 背景	5
1.2 研究目的	5
1.3 本論文の構成	5
第2章 SVM を用いた多群判別分析	7
2.1 緒言	8
2.2 SVM	8
2.2.1 SVM	8
2.2.2 線形2群SVM	8
2.2.2a SVMの原理	8
2.2.2b 問題の定式化	8
2.2.3 ソフトマージン	9
2.2.4 非線形SVM	10
2.2.5 多群判別	11
2.3 マハラノビス距離を用いた判別分析	11
第3章 SVM を用いた複合材料積層板の層間はく離同定	15
3.1 電気抵抗変化法による複合材料積層板の層間はく離同定	16
3.2 解析手法	16
3.3 SVMの複合材料積層板の層間はく離同定への適用	17
3.3.1 はく離同定方法	17
3.3.2 パラメータ最適化	18
3.3.3 SVMによる新規データ損傷同定結果	18
3.3.4 結言	18
第4章 考察	24
4.1 緒言	25
4.2 マハラノビス距離を用いた判別分析のCFPR積層板の損傷同定への適用	25
4.3 SVMによる損傷同定結果のマハラノビス距離を用いた判別分析による同定結果との比較	26

4.4	境界線の形状	26
4.5	データの傾向	27
第5章	結論	35
5.1	結論	36
参考文献		37

第 1 章 序論

1.1 背景

構造物に取り付けたセンサの出力から、構造物に発生した損傷の位置や程度の推定を行う損傷同定の手法として、順問題解析と逆問題解析がある。順問題解析では、構造の物理モデルを作成し、現象に起因する出力を求める手法であるため、詳細な力学解析が必要となり、都市構造物のような、構造・損傷の数理モデル化が困難な複雑な構造物に適用するのは困難であるといえる。一方逆問題解析では、物理的な因果関係を解かずに、入力と出力の関係のシステム同定を行い、求めたシステムにより、逆に出力から入力を求める手法であるため、構造のモデル化を必要とせず、損傷同定手法として適しているといえる。

しかし、現在逆問題解析において多く用いられているニューラルネットワーク等の手法では、繰り返し学習による最適化を行うため、最適な逆問題解析モデルの選定の際に多くの計算コストが要求される。そのため、逆問題解析モデルの最適化が容易な手法の開発が望まれている。

1.2 研究目的

逆問題解析の手法として、統計データ解析を用いた逆問題解析がある。統計データ解析を用いた逆問題解析では、解が決定論的に求められ、繰り返し学習が不要でパラメータの最適化が容易である。そのため、効率的な損傷診断が可能であると考えられる。そこで本研究では、統計データ解析手法を用いた損傷診断手法の確立を目的とし、多変量解析を用いた損傷診断手法としてサポートベクターマシン (Support Vector Machine以下SVMとする)^[1-4]を複合材料積層板の層間はく離同定問題に適用し、SVMの損傷同定手法としての有効性を解析的に検討していく。

1.3 本論文の構成

第1章「序論」では、研究の背景と目的を示した。

第2章「SVMを用いた多群判別分析」では、本研究において損傷同定の手法として用いたSVMについての説明を述べる。

第 3 章「SVM を用いた複合材料積層板の層間はく離同定」では，電気抵抗変化法により SVM を複合材料積層板の層間はく離同定に適用し，得られた結果を示す．

第 4 章「考察」では，一般的な判別分析の手法としてマハラノビス距離を用いた判別分析を用いて損傷同定を行い，SVM での同定結果をマハラノビス距離を用いた判別分析での同定結果と比較し，SVM の有効性を検証する．

第 5 章「結論」では，本研究で得られた結論を述べる．

第 2 章 SVM を用いた多群判別分析

2.1 緒言

本研究では，SVM の損傷同定手法としての有効性を検証することを目的として，複合材料梁に生じるはく離の位置同定および寸法同定を行った．第 2 章では，本研究で損傷同定手法として用いた，SVM による多群判別分析について説明する．

2.2 SVM

2.2.1 SVM

本研究では，逆問題解析の手法として SVM を用いている．SVM は 2 群の分類問題を解くための学習機械である．SVM は線形の識別器だが，後述するようにカーネルを組み合わせることによって非線形に拡張することができる．また，2 群の識別を複数回行い，それを組み合わせることによって多群の識別に用いることも可能である．SVM は文字認識や画像認識などの分野で利用され，高い識別能力を示している．

2.2.2 線形 2 群 SVM

2.2.2a SVM の原理

まず問題を単純化し，二次元の問題において， C_1, C_2 の 2 群のデータが線形な識別平面によって完全に分離できる場合を考える．このとき図 2.1 のように，一般に識別平面は一意には決まらない．そこで，2 つの群を判別する能力が最も高くなるような平面を識別平面に選ぶことを考える．すなわち，図 2.2 のように，識別平面と各群のデータとの間の距離（マージンと呼ぶ）が最大となる平面を識別平面に選ぶ．このように識別平面を決定したとき，一般に識別平面から最も近くにある学習データは 1 つではない．このようなデータは，識別平面の周りで識別平面をサポートしているようであるため，「サポートベクター」と呼ばれる．

2.2.2b 問題の定式化

この項では，SVM の学習法を定式化し，二次計画問題に帰着することを示す．ここで，学習データを x_1, \dots, x_n で表し，それぞれの群のラベルを y_1, \dots, y_n として， $x_i \in C_1$ ならば $y_i = 1$ ， $x_i \in C_2$ ならば $y_i = -1$ であるとする．

SVM の識別関数は、次のように表される。

$$D(\mathbf{x}_i) = \mathbf{w} \cdot \mathbf{x}_i + b \quad (2 \ 1)$$

ここで、 \mathbf{w} は重みベクトル、 b はバイアスと呼ばれるパラメータである。識別平面は、 $D(\mathbf{x}_i) = 0$ を満たす超平面となる。すると、新規データについて、 $D(\mathbf{x}_i) \geq 0$ ならば群 C_1 に、 $D(\mathbf{x}_i) < 0$ ならば群 C_2 に判別することができる。

また、サポートベクター \mathbf{x}_s は、 $y_s(\mathbf{w} \cdot \mathbf{x}_s) + b = 1$ を満たすものとする、識別平面と学習データの最小距離すなわちマージンの幅は、

$$\frac{1}{\|\mathbf{w}\|} \quad (2 \ 2)$$

と表される。マージンの中には学習データは存在しないため、全ての学習データ \mathbf{x}_i は $y_i(\mathbf{w} \cdot \mathbf{x}_i) + b \geq 1$ を満たすことになるので、マージンを最大化する問題は、制約条件

$$y_i(\mathbf{w} \cdot \mathbf{x}_i) + b \geq 1 \quad (2 \ 3)$$

の下で、目的関数

$$L(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \quad (2 \ 4)$$

を \mathbf{w} について最小化する問題となる。

この問題を、ラグランジュ乗数 α を導入して計算することにより、制約条件

$$\sum_{i=1}^l y_i \alpha_i = 0, \quad \alpha_i \geq 0 \quad (i=1, \dots, l) \quad (2 \ 5)$$

の下で、目的関数

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \quad (2 \ 6)$$

を α について最大化する問題となる。求められた最適な α から、新規データ \mathbf{x} についての識別関数は次のように与えられる。

$$D(\mathbf{x}_i) = \sum_{i \in s} \alpha_i y_i \mathbf{x}_i \cdot \mathbf{x} + b \quad (2 \ 7)$$

$$b = y_s - \sum_{i \in s} \alpha_i y_i \mathbf{x}_i \cdot \mathbf{x}_s \quad (2 \ 8)$$

ここで、添え字 s はサポートベクターであることを表す。

2.2.3 ソフトマージン

線形な平面では分離できない場合の対処法として、ソフトマージンという手法が用いられる。これは、図 2.3 のように、 i 番目のデータが、マージン幅の ξ_i 倍だけ反対側に

はみ出すことを許すというものである。これにより、線形 SVM における、データがマージンの外になければならないという条件式 (2 3) は、

$$y_i(\mathbf{w} \cdot \mathbf{x}_i) - b \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad (2 9)$$

と書き直すことができる。

ξ_i の値が大きくなればそれだけ学習データについての識別誤りが増えるということになるので、 ξ_i の値はできるだけ小さくするのが良いということになる。したがって、

$$\text{minimize} \quad \sum_i \xi_i \quad (2 10)$$

という条件が加わることとなる。

マージン最大化と条件式(2 9),(2 10)から、ソフトマージンを用いた SVM は、線形 SVM における制約条件の式 (2 5) を

$$\sum_{i=1}^l y_i \alpha_i = 0, \quad 0 \leq \alpha_i \leq C \quad (i=1, \dots, n) \quad (2 11)$$

と書きかえたものとなる。ここで、 C ははみ出しの程度を決めるパラメータであり、 C の値が小さいほどはみ出しの程度が大きくなる。 C の値の設定は実験的に行うことになる。

2.2.4 非線形 SVM

線形な識別平面で分離することが適当ではない場合も考えられる。そこで、図 2.4 のように、線形分離可能でないデータを写像 ϕ によって線形分離可能な空間に移すことを考える。すると、 $\mathbf{x}_i \cdot \mathbf{x}_j$ は $\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j)$ に写像される。線形 SVM の二次計画問題において、この置き換えをすることによって SVM を非線形に拡張することができる。

$\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j)$ をカーネル $K(\mathbf{x}_i, \mathbf{x}_j)$ と置いて、 $\mathbf{x}_i \cdot \mathbf{x}_j$ をカーネルに置き換えることにより、写像 ϕ の形状を具体的に求めなくても、カーネルの値を知ることによって二次計画問題を解くことができる。このような手法のことを、カーネルトリックと呼ぶ。

カーネルの形状には、多項式カーネル、シグモイドカーネル、ガウシアンカーネルなどがあるが、SVM においてはガウシアンカーネルを使用するのが一般的であり、本研究においてもガウシアンカーネルを用いて同定を行った。ガウシアンカーネルの形状は式 (2 12) のようになっている。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2\right) \quad (2 12)$$

ここで、 γ はサポートベクターが影響する範囲を示すパラメータであり、 γ が小さいほどサポートベクターの数は少なくなり、識別平面はなめらかな形状となる。 γ の値の設定は、実験的に行うことになる。

2.2.5 多群判別

これまで 2 群の場合の判別について見てきたが、実際には多群の場合の判別が必要である。SVM は 2 群のパターン認識手法であるので、2 群の判別の組み合わせにより多群の判別を行うことを考える。

群 1 から群 n までの n 群からなるデータの判別を考える。まず、群 i と群 j ($i=1, \dots, n-1, j=i+1, \dots, n$) の 2 つの群のデータから識別関数を求め、判別すべきデータが群 i に判別されれば群 i に 1 票、群 j に判別されれば群 j に 1 票を入れることにする。これを $\frac{1}{2}n(n-1)$ 組全ての i, j の組について行い、最も多く票の集まった群に属するとして判別する。

2.3 マハラノビス距離を用いた判別分析

第 4 章「考察」において、SVM の有効性を一般的な手法と比較するために、マハラノビス距離を用いた判別分析でも同様のはく離同定を行っている。この節では、マハラノビス距離を用いた判別分析^[5]について説明する。

マハラノビス距離とは、変数間の相関を用いた指標であり、対象データの基準空間からの距離を表す距離尺度である。

説明変数を x とし、データ点数 N 、自由度 T における変数を x_{ij} ($i:1 \sim N, j:1 \sim T$) で表現するとした場合、マハラノビス距離 d は次式で定義される。

$$d_i^2 = \frac{1}{T} \sum_{l=1}^T \sum_{k=1}^T (X_{il} - \bar{X}_{il}) S_{lk}^{-1} (X_{ik} - \bar{X}_{ik}) \quad (2 \quad 13)$$

ここで、 S は次式で表される、標準化された分散共分散行列である。

$$S_{ik} = \frac{1}{T} \sum_{l=1}^T (X_{il} - \bar{X}_l)(X_{lk} - \bar{X}_k) \quad (2 \quad 14)$$

ここで、 X は変数 x を次式で標準化したものである。

$$X_{ij} = \frac{x_{ij} - \bar{x}_j}{\sigma_{x_j}} \quad (2 \quad 15)$$

マハラノビス距離を用いた判別分析では、基準データが作る特性値空間への帰属度から、対象の個体が帰属する群を判別する。ある群に帰属することが既知であるデータを基準データ、各群の基準データの集合を基準空間と呼ぶ。

マハラノビス距離は、基準空間との差異が大きくなると急激に大きな値を取る。そのため、判別すべきデータの各基準空間とのマハラノビス距離を計算し、最小のマハラノビス距離を与える基準空間にそのデータは帰属すると判定できる。

ユークリッド距離が円距離であるのに対し、マハラノビス距離は変数間の相関を考慮した楕円距離になっている。そのため、図 2.5 のように説明変数 X_1, X_2 に関して2つの群が分布しているとき、各分布の重心から判別すべきデータまでの距離は、ユークリッド距離では D_1 のほうが短くなるが、マハラノビス距離では D_2 のほうが短くなり、群 2 に属していることが正しく判定できる。




図 2.1 2 クラスを分離する平面

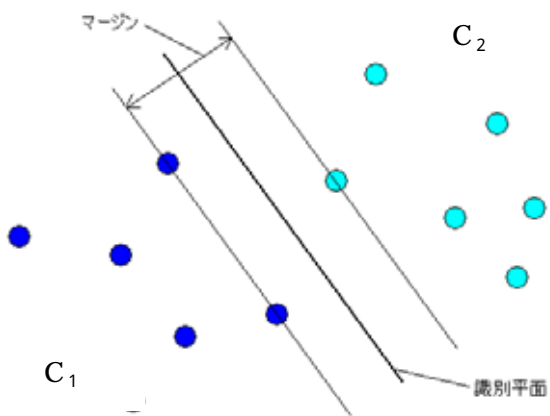


図 2.2 マージン最大化




図 2.3 ソフトマージン




図 2.4 線形分離可能な空間への写像

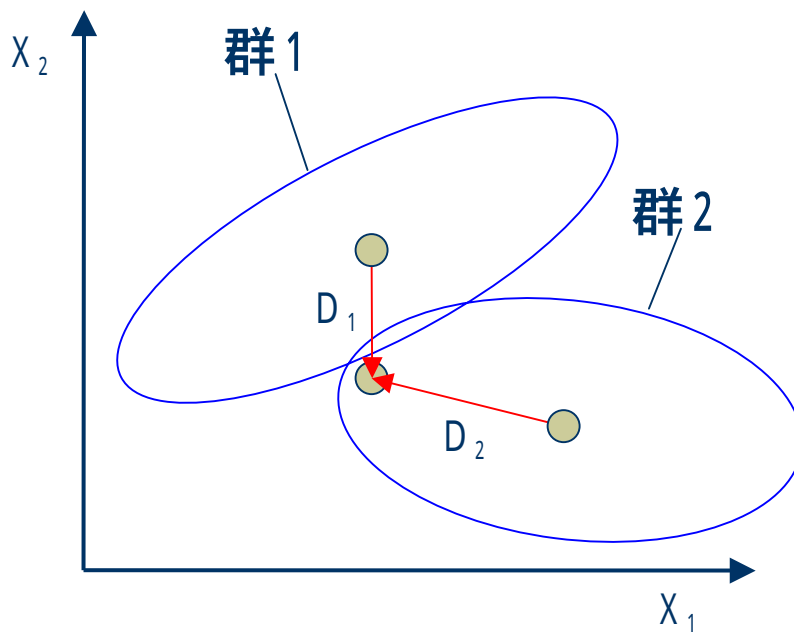


図 2.5 マハラノビス距離

第3章 SVMを用いた複合材料積層板の層間 はく離同定

3.1 電気抵抗変化法による複合材料積層板の層間はく離同定

複合材料積層板は、炭素繊維の膜を積層し、樹脂で固めたものであり、従来の金属材料と比較して、比強度・比剛性などの力学的特性が非常に優れている。しかし、層間の強度が弱く、面外からの衝撃により容易に層間はく離が生じる。

この層間はく離の診断手法として、複合材料の炭素繊維の導電性を利用し、層間はく離によって生じる複合材料積層板内の電気抵抗変化を、積層板表面に電極を取り付けて測定することにより、層間はく離の位置および寸法を同定する電気抵抗変化法を用いる。

一方向プリプレグを多方向に積層している複合材料積層板では、図 3.1 に示すように繊維はうねりを有し、隣接繊維と接触点を有している。そのため、複合材料積層板は繊維直交方向に繊維方向に比べて 10^{-3} 程度の非常に小さな電気伝導率を有する。また厚さ方向には、構造的には繊維直交方向と同じであるが、図 3.2 のように層間に樹脂リッチな層を有するために、繊維直交方向よりもやや小さい 10^{-4} 程度の電気伝導率を有する。

この繊維接触によるネットワーク構造により、試験片全体に有限な値の異方性電気抵抗が存在する。はく離が発生すると、はく離がこの繊維ネットワークを切断するため電気抵抗が変化し、この電気抵抗変化の大きさを測定することではく離の位置・寸法の同定をすることが可能である。

本章では、電気抵抗変化法を用いた複合材料積層板の層間はく離同定問題に第 2 章で述べた SVM を用いた判別分析を適用し、SVM の有効性の検証を行った。

3.2 解析手法

解析には、図 3.3 のような試験片形状の複合材料積層板中の層間はく離により引き起こされる電気抵抗変化のデータを用いた。

試験片は、長さ 290 [mm]、厚さ 1 [mm] の梁状のもので、試験片の中央を原点として $x = 0, \pm 45, \pm 90, \pm 135$ [mm] の 7 点に A ~ G の電極を取り付けてある。この電極間に電流を流し、電極間ではく離が発生する場合について有限要素法で解析し、はく離同定を行った。解析モデルを図 3.4 に示す。解析に用いた積層構成は $[0/90]_s$ である。

本研究では層間はく離を有限要素法でモデル化する際、モード の開口型はく離を仮定し、はく離位置の節点を二重に定義し、それぞれの節点の連結をはずすことではく離をモデル化した。これによつてはく離を横切る電流は流れない。また要素は、四角形四節点要素のサイズを縦 0.0625 × 横 0.25 [mm] に設定し、汎用有限要素法ソフト ANSYS

で自動要素分割を行い，約 18560 要素に分割した．節点数は約 19800 である．

試験片の繊維方向の導電率 σ_0 を 5.5×10^3 [m^{-1}], 90° 方向の導電率 σ_{90} と 0° 方向の導電率 σ_0 の比 σ_{90}/σ_0 を 3.7×10^{-2} ，厚さ方向の導電率 σ_t と繊維方向の導電率 σ_0 の比 σ_t/σ_0 を 3.8×10^{-3} として解析を実施した．ここで，有限要素法解析においては，本来，層内と樹脂リッチな層間は異なる導電率を有しているが，簡単のために厚さ方向に均一な導電率を有する要素とモデル化して解析した．

図 3.5 に電極 BC 間にはく離がある場合の 2 つのデータについて各電極間における電気抵抗変化を示した．データには，図 2.5 のデータ 1 のように，はく離のある位置で電気抵抗変化が大きくなる傾向があり，また，はく離寸法が大きいほど抵抗変化の度合いも大きくなるという傾向がある．しかし，電極間に電流を流し，電極間の電気抵抗を測定する際に，電気抵抗の強い異方性のため，隣接する電極間にまで電流が流れてしまい，図 2.5 に示したデータ 2 のように，はく離がある所とは別の場所で最大の電気抵抗変化を示す場合がある．そこで，このような場合にも適切に同定を行うために，逆問題解析を用いて損傷同定を行う必要性が生じる．

3.3 SVM の複合材料積層板の層間はく離同定への適用

3.3.1 はく離同定方法

本研究で用いたデータは，はく離の寸法，位置，電極間の 6 個の電気抵抗変化率の値からなり，データの数 は 263 個である．はく離位置については電極位置で 6 水準に，はく離寸法については水準 1 (5[mm])，水準 2 (10[mm])，水準 3 (20[mm])，水準 4 (30[mm])，水準 5 (40[mm]) の 5 水準に分割し，電極間の電気抵抗変化率の値を説明変数，水準化されたはく離の位置および寸法を被説明変数として同定を行った．

6 個の電気抵抗変化の値を 6 次元のベクトルと考えた場合において，損傷の位置がベクトルの方向に，寸法が長さに大きな影響を及ぼすと考えられるので，電気抵抗変化をベクトルの長さが 1 となるように規格化した値に，元のベクトルの長さを加えた 7 次元のデータを説明変数として用いた．

また，本研究では 263 個のデータから交差推定により損傷同定を行った．交差推定では，263 個のデータのうち 262 個を学習用データとし，学習に用いなかった残りの 1 個のデータについて同定を行う．これを 263 回繰り返すことで 263 個全てのデータについて同定を行った．

3.3.2 パラメータ最適化

カーネルのパラメータ σ はサポートベクターが影響する範囲を示すパラメータであり、 σ が大きいほどサポートベクターの数は少なくなり、識別平面はなめらかな形状となる。

ソフトマージンのパラメータ C は、ソフトマージンによりどの程度データのはみ出しを許すかを決定するパラメータであり、 C の値が小さいほどはみ出しの程度は大きくなり、識別平面はなめらかになっていく。 C の値が一定以上になるとはみ出しを全く許さないことになり、ソフトマージンの効果はなくなる。

SVMによる判別分析の際には、この2つのパラメータの最適化から最良の分析モデルを決定する。最適化は学習データの判別率を目的関数として行っている。位置同定においてパラメータを変化させたときの判別率を図3.6に、寸法同定においてパラメータを変化させたときの判別率を図3.7に示す。

位置同定においては $0.01 < \gamma < 50$, $100 < C < 1.2 \times 10^5$ の範囲で、寸法同定においては $0.1 < \gamma < 1$, $5 \times 10^3 < C < 4 \times 10^4$ の範囲で最適化を行った。

図3.6に示すように、はく離位置に関しては広い範囲で判別率が100%に漸近しており、本手法で高い精度で推定できていることがわかる。

はく離寸法に関しては、図3.7に示すように、 C, γ の微小変化で判別精度が大きく変動しており、最適化が必要なことがわかる。ただ、図に見られるように、判別精度に最適解が存在し、今回求めた $\gamma = 0.5$, $C = 10000$ がほぼ最適解であるといえる。

3.3.3 SVMによる新規データ損傷同定結果

3.3.2で求めたSVMのパラメータを用いた際の学習データを用いない新規データの位置同定の結果を表3.1に、寸法同定の結果を表3.2に示す。縦方向に実水準、横方向にSVMにより判別された水準を取り、実水準に対して各水準に判別されたデータの数を示してある。正しく判別されたデータは対角線上に現れることになる。

表3.2に示されるように、誤判別データを実水準の近傍の水準に推定できており、損傷診断の実用上問題ないことがわかる。このようにSVMを用いた判別分析では判別群の重心からの距離を中心的なパラメータとして判別を行うため、大きなはずれ判定を起こさず、100%の診断が困難である関係上、損傷診断手法として有効であることがわかる。

3.3.4 結言

以上，はく離を有する梁試験片の電気抵抗変化を FEM で解析した結果を用いて，SVM による多群判別分析からはく離位置と寸法の同定を行った．得られた結果を以下に示す．

- 1．はく離位置，寸法の同定問題で SVM が高い精度で判別可能なことを示した．
- 2．SVM では 2 パラメータの調整で判別モデルの策定を行うため計算コストも小さく，かつ推定誤差も小さい．そのため，電気抵抗変化法による層間はく離診断には SVM が有効である．
- 3．SVM を用いた判別分析では判別群の重心からの距離を中心的なパラメータとして判別を行うため，大きなはずれ判定を起さず，100%の診断が困難である関係上，損傷診断手法として有効である．




図 3.1 炭素繊維による層内ネットワーク構造




図 3.2 プリプレグ間の樹脂リッチ層




図 3.3 CFRP 積層板




図 3.4 解析モデル

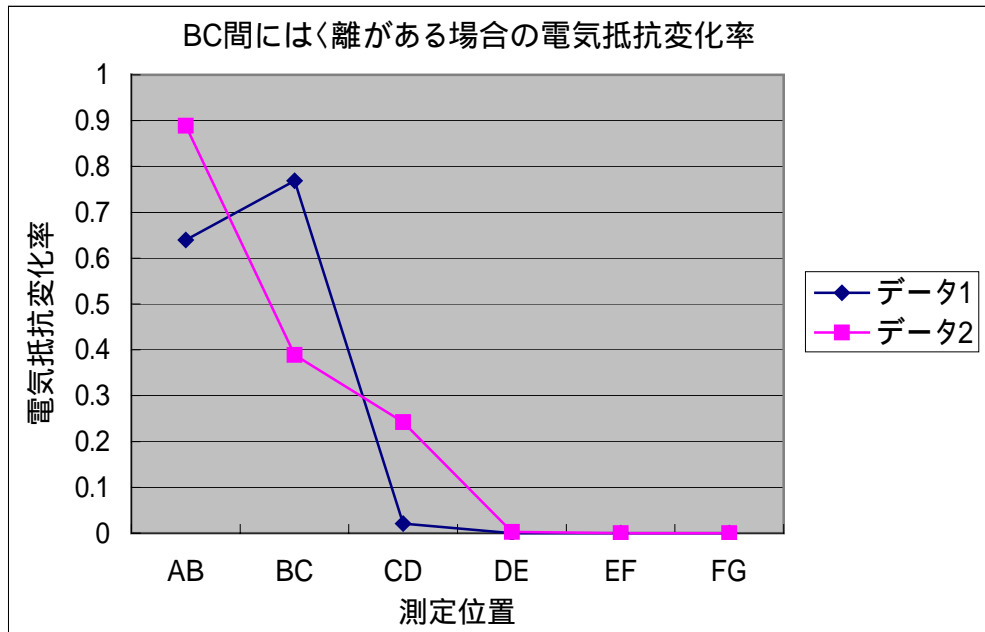


図 3.5 測定データの例




図 3.6 パラメータによる位置同定の判別率の変化




図 3.7 パラメータによる寸法同定の判別率の変化

表 3.1 SVM による位置同定結果

=0.1	C=50000					
判別結果	1	2	3	4	5	6
実水準 1	39	0	0	0	0	0
2	0	45	0	0	0	0
3	0	0	45	0	0	0
4	0	0	0	50	0	0
5	0	0	0	0	45	0
6	0	0	0	0	0	39
			263/263		100%	

表 3.2 SVM による寸法同定結果

=0.5	C=10000				
判別結果	1	2	3	4	5
実水準 1	51	4	0	0	0
2	4	51	0	0	0
3	0	2	49	2	0
4	0	0	4	47	0
5	0	0	0	4	45
		243/263		92.40%	

第4章 考察

4.1 緒言

前章「SVM を用いた複合材料積層板の層間はく離同定」では，複合材料積層板中の層間はく離により引き起こされる電気抵抗変化の解析結果から層間はく離を SVM を用いて同定し，その汎化能力に関して検討を行った．その結果，カーネルパラメータ，ソフトマージン係数の最適化により，統計データ解析手法である SVM を用いることで十分な汎化能力を得ることを示した．最適な判別モデル導出に試行錯誤によるパラメータ最適化が必要であるが，繰り返し学習が不要な統計データ解析手法であることから SVM が計算コスト削減の上で有効であることがこれにより明らかとなった．

一方，通常判別分析に用いる手法では，繰り返し学習が不要かつ，パラメータの最適化が不要な手法として線形判別関数やマハラノビス距離などが用いられており，これらの手法でも同様に判別群の重心距離から判別が可能である．しかしながら，これらの手法では重心からの距離のみから判定が行われており，損傷同定問題のように判別のパラメータ（この場合構造に取り付けたセンサの出力）が空間的にモデル化されていない問題に関しては判別精度が落ちると考えられる．そこで本章では，これらのうち判別群間の分散が異なる際に有効であると言われるマハラノビス距離を用いた判別分析と本手法の精度，判別境界の比較を行い，本手法の有効性の検証を行う．

4.2 マハラノビス距離を用いた判別分析の複合材料積層板の層間はく離同定への適用

本章では比較検討のため，一般的な判別分析の手法として，マハラノビス距離を用いた判別分析により損傷診断を行った．

マハラノビス距離を用いた判別分析に用いたデータは SVM による損傷同定に用いたものと同じであり，電気抵抗変化をベクトルの長さで規格化したものにベクトルの長さを加えた 7 次元のデータを説明変数としたものを用いた．263 個のデータから交差推定により損傷同定を行った．位置・寸法水準に関しても同様に位置を 6 水準，寸法を 5 水準に分割している．SVM による多群判別と異なり，マハラノビス距離による判別分析では，判定すべきデータのマハラノビス距離を式 (2-13) に従って導出し，最小のマハラノビス距離をとるデータ群に帰属すると判定し，損傷同定を行っている．

マハラノビス距離を用いた判別分析による位置同定の結果を表 4.1 に，寸法同定の結果を表 4.2 に示す．

4.3 SVMによる損傷同定結果のマハラノビス距離を用いた判別分析による同定結果との比較

SVM とマハラノビス距離を用いた判別分析の各々の判別率を表 4.3 にまとめて示した。SVM の結果は、ガウシアンカーネル(2-12)内のパラメータ σ とソフトマージンにおけるはみだしの程度 C を調整し、最も判別率が高かった場合の結果である。

表からわかるように、SVM では位置、寸法ともに高い精度で同定できているが、マハラノビス距離を用いた判別分析では寸法同定がほとんどできていない。この判別精度の違いは、2つの手法により形成される判別の境界の形状の違いに起因すると考えられる。そこで、両手法によって形成される境界の形状を調べる

4.4 判別の境界線

先に示したように、SVM とマハラノビス距離を用いた判別分析で、(特に寸法同定において)判別精度に違いがあったのは、この2つの手法により形成される判別の境界の形状の違いによるものと考えられる。そこで、両手法によって形成される境界の形状を調べる。

マハラノビス距離を用いた判別分析では、最小マハラノビス距離を与える群に帰属すると判定するので、群 A と群 B の境界線は、

$$D_A^2 - D_B^2 = 0 \quad (4-1)$$

で与えられる。これに式(2-13)を代入して計算すると、 x の二次式となる。したがって、マハラノビス距離を用いた判別分析において形成される境界線は図 4.1 のように二次曲線の形状となる。

一方 SVM では、カーネル内のパラメータとソフトマージンの調整を行うことにより、同じ学習データを用いても、図 4.2 のように、単純な形状の境界線から複雑な形状の境界線まで表現することができる。

損傷同定問題においては各センサの値がデータ空間上における位置のパラメータとなるため、データ空間上できれいな楕円分布は描かず、それが判別精度の違いとなって表れたと考えられる。そこで、続いてデータの傾向から実データにおける境界に関して考察を行った。

4.5 データの傾向

図 4.3 から、はく離位置によって電気抵抗変化の値に現れる傾向を調べる。図 4.3(a)は、6つの位置水準について AB 間、BC 間の電気抵抗変化の値を示したものであり、図 4.3(b)は BC 間、CD 間の、図 4.3(c)は CD 間、DE 間の電気抵抗変化を示したものである。AB 間にはく離がある場合には AB 間と BC 間のみで電気抵抗変化が生じ、BC 間にはく離がある場合には AB 間、BC 間と CD 間に変化が生じる。はく離位置に近い電極間の電気抵抗が大きく変化し、はく離位置から遠い電極間の電気抵抗はほとんど変化しないことがわかる。このように、はく離位置により電気抵抗変化の値には顕著な傾向が見られ、そのため、はく離位置については判別が容易であり、二次の平面でもうまく区切ることができ、SVM、マハラノビス距離を用いた判別分析の両方で高い判別精度になったと考えられる。

図 4.4 は、5つのはく離寸法の水準について、図 4.4(a)は AB 間と BC 間の、図 4.4(b)は BC 間と CD 間の、図 4.4(c)は CD 間と DE 間の電気抵抗変化の値を示したものである。この図から、はく離寸法によっては電気抵抗変化の値に顕著な傾向は現れないことがわかる。また、図 4.5 は、はく離寸法に対するベクトル長さの分布を示したものである。この図から、はく離寸法が大きくなるほどベクトル長さも大きくなるという傾向が見られるが、はく離寸法に対してベクトル長さの分布が大きく広がりを持っており、その分布に重なりがあり、はく離寸法とベクトル長さが 1 対 1 に対応していない。このため、ベクトル長さだけで寸法を推定すると高い判別精度は期待できない。

図 4.6 に、各寸法水準のベクトル長さの中央値を用い、ベクトル長さからはく離寸法の回帰を行った結果を示す。回帰には二次の多項式を用いた。図からわかるように、ベクトル長さのみをもちいた回帰では推定値に大きな誤差が生じ、うまく寸法同定できていないことがわかる。

はく離寸法に対するベクトル長さの分布は重なりが多いが、図 4.7、図 4.8 からわかるように、はく離が電極付近 ($x = 0, \pm 45, \pm 90, \pm 135$ [mm]) にあるとベクトルが長く、電極から遠い位置にあると短いという傾向があり、分布の重なっている部分については電極からの距離を知ることによって判別ができると考えられる。そのため、ベクトルの長さや方向の両方のデータを組み合わせることで、はく離寸法についても同定ができた。

しかし、二次の平面ではうまく区切ることができない分布になっているために、マハラノビス距離を用いた判別分析では適切な境界線を形成することができず、マハラノビス距離を用いた判別分析による寸法同定の精度は低くなったと考えられる。SVM ではカーネルとソフトマージンのパラメータを適切に選択することにより境界の形状がデータの分布に合った形状となり、高い精度での判別ができたと考えられる。

表 4.1 マハラノビス距離を用いた判別分析による位置同定結果

判別結果		1	2	3	4	5	6
実水準	1	33	6	0	0	0	0
	2	0	45	0	0	0	0
	3	0	0	45	0	0	0
	4	0	0	0	50	0	0
	5	0	0	0	0	45	0
	6	0	0	0	0	6	33

251/263 95.44%

表 4.2 マハラノビス距離を用いた判別分析による寸法同定結果

判別結果		1	2	3	4	5
実水準	1	32	23	0	0	0
	2	16	23	16	0	0
	3	0	14	23	16	0
	4	0	0	20	25	6
	5	0	0	0	8	41

144/263 54.75%

表 4.3 判別率の比較

	位置	寸法
SVM	100.0%	92.35%
マハラノビス距離	95.44%	54.75%

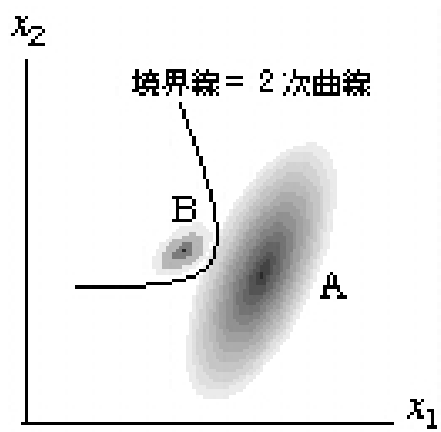


図 4.1 マハラノビス距離を用いた判別分析の判別の境界線

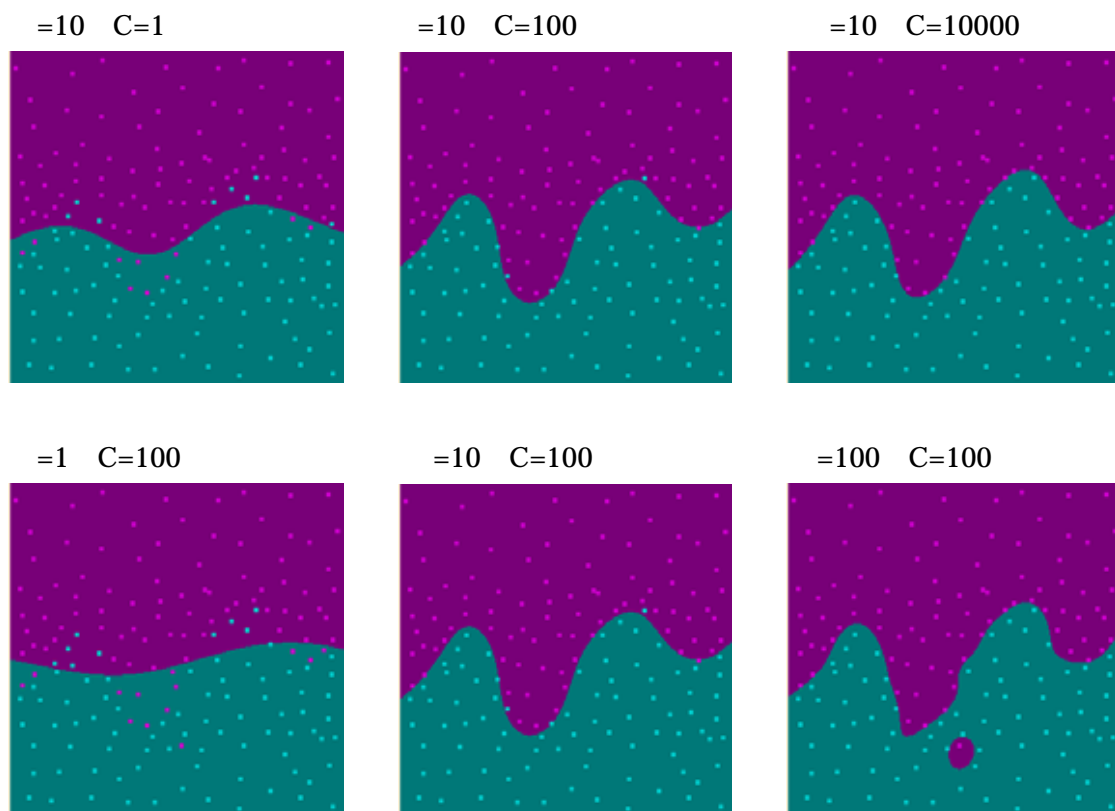

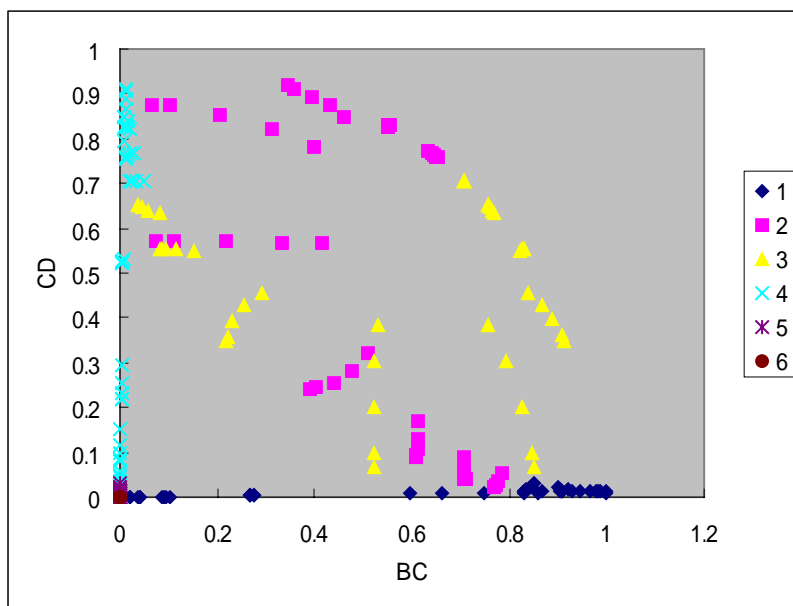


図 4.2 SVM の判別の境界線




(a) AB 間と BC 間の電気抵抗変化




(b) BC 間と CD 間の電気抵抗変化

図 4.3 位置水準による電気抵抗変化の傾向




(c) CD 間と DE 間の電気抵抗変化

図 4.3 位置水準による電気抵抗変化の傾向




(a) AB 間と BC 間の電気抵抗変化

図 4.4 はく離寸法による電気抵抗変化の傾向



(b) BC 間と CD 間の電気抵抗変化



(c) CD 間と DE 間の電気抵抗変化

図 4.4 はく離寸法による電気抵抗変化の傾向




図 4.5 はく離寸法によるベクトル長さの傾向




図 4.6 ベクトル長さからののはく離寸法の回帰結果

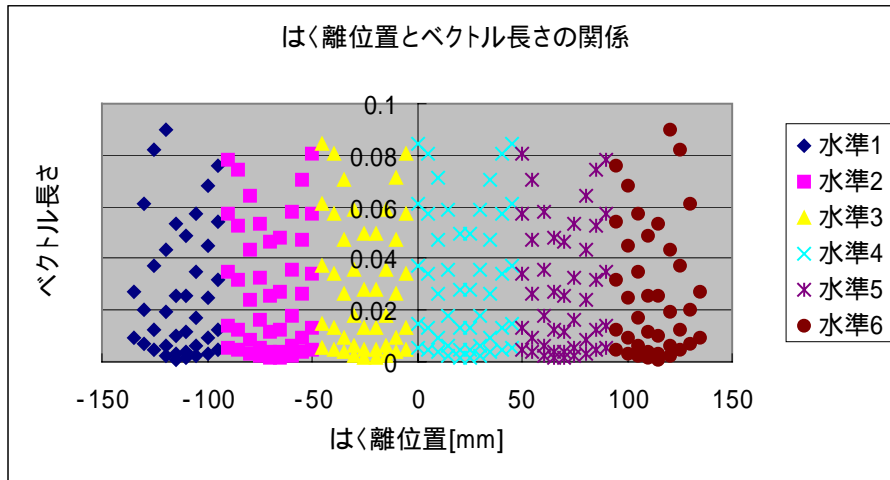


図 4.7 はく離位置に対するベクトル長さの分布

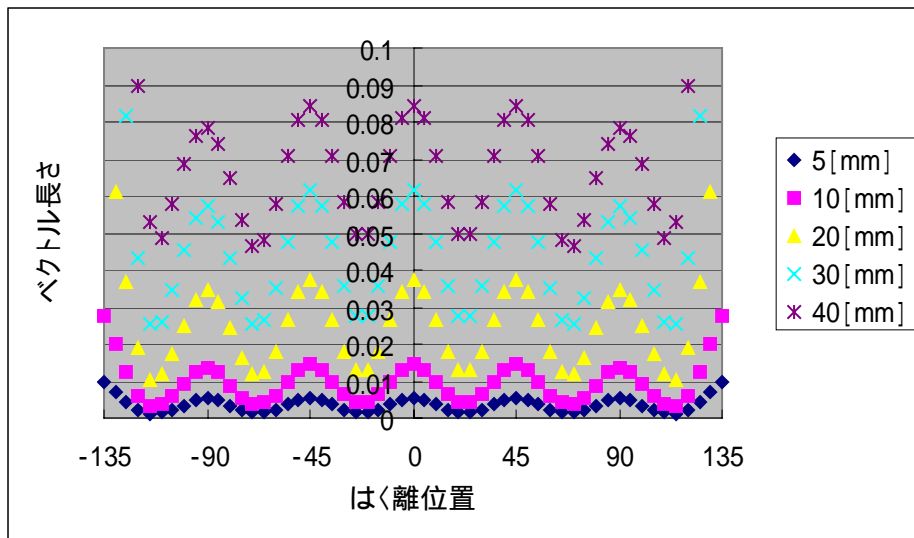


図 4.8 各寸法水準のデータのはく離位置によるベクトル長さ

第5章 結論

5.1 結論

以上本研究では、サポートベクターマシンを用いた判別分析により複合材料積層板の層間はく離同定を行い、一般的な判別分析手法であるマハラノビス距離による判別分析との判別精度の比較からその有効性の検証を行った。

以上、本研究で得られた結果をまとめて以下に示す。

1. SVM では 2 パラメータの調整で判別モデルの策定を行うため計算コストも小さく、かつ推定誤差も小さいことを示した。
2. SVM を用いた判別分析では判別群からの距離を中心的なパラメータとして判別を行うため、大きなはずれ判定を起さず、100%の診断が困難である関係上、損傷診断手法として有効であることを示した。
3. SVM を用いた判別分析では、判別境界形状をカーネルパラメータとソフトマージン係数の調整により変化させるため、マハラノビス距離を用いた判別分析の際の二次平面の境界形状では判別困難な、多群のデータが入り組んだ問題に対して高い精度での判別が可能である。

参考文献

[1]Nello Cristianini ,John Shawe-Taylor :“ An Introduction to Support Vector Machines ”, CANBRIDGE

[2]麻生英樹 , 津田宏治 , 村田昇 :“ パターン認識と学習の統計学 ”, 岩波書店

[3]LIBSVM—A Library for Support Vector Machines

URL <http://www.csie.ntu.edu.tw/~cjlin/libsvm>

[4]K Worden and A J Lane :“ Damage identification using support vector machines ”

[5]武藤真介 :“ 統計解析ハンドブック ”, 朝倉書店