

錐制約部分空間法における 正常データの確率密度推定に基づく異常検出

山崎 優大¹ 野里 博和² 岩田 昌也² 高橋 栄一² 何森 亜由美³ 岩瀬 拓士⁴ 坂無 英徳²

概要: 錐制約部分空間法は非負の特徴ベクトルに対し錐形状の空間を形成することで学習パターンを精度良く表現し、錐との角度を基にパターン認識を行う。しかし、錐形状の空間の広がり大きい場合は認識性能が低下する問題がある。本論文ではその原因が、錐形状の空間内の特徴ベクトルと錐とのなす角度が算出できないためであることを明らかにするとともに、問題の解決策として、錐に含まれる確率の算出方法とその確率を基にした異常検出手法を提案する。提案手法では、錐形状の部分空間の広がり方向を表す空間上において学習パターンの確率密度関数を作成し、その確率を基に特徴ベクトルの識別を行う。実験では乳腺超音波画像の実データを用いて、提案手法による病変検出精度の検証を行い、その有効性を確認した。

キーワード: 錐制約部分空間法, 確率密度推定, 異常検出, パターン認識

Abnormal Detection Based on Density Estimation of Normal Data in Cone-Restricted Subspace

YAMAZAKI YUDAI¹ NOSATO HIROKAZU² IWATA MASAYA² TAKAHASHI EIICHI² IZUMORI AYUMI³
IWASE TAKUJI⁴ SAKANASHI HIDENORI²

Abstract: A cone-restricted subspace method can express learning patterns accurately by generating a convex cone for non-negative feature vectors. Classification of conventional method is performed based on the angle between the input vector and the cone. However, recognition performance is reduced if the spread of the convex cone is large. Because conventional method cannot calculate the angle between an input vector in the subspace of the cone and the boundary. In this paper, we propose an abnormal detection method based on probability density of normal data in cone-restricted subspace. Classification of the proposed method is based on estimated probability density of normal data in a convex cone. We demonstrate abnormal detection from breast ultrasound images using proposed method, and confirmed effectiveness of the method.

Keywords: Cone-Restricted Subspace, Density Estimation, Abnormal Detection, Pattern Recognition

1. はじめに

パターン認識において錐制約部分空間法 [1] が提案されており、錐をなす複雑な分布を錐形状の空間で表現することで、学習パターンを精度良く近似でき、高い認識率を持つ。しかし、錐制約部分空間法を用いて正常クラスの部分空間に基づく異常検出を行う場合は、錐形状の空間に含まれる異常を正常と誤認識する可能性がある。これは、錐に含まれる特徴ベクトルの錐との角度が全て0となり、錐の

¹ 筑波大学大学院システム情報工学研究科
Graduate School of Systems and Information Engineering,
University of Tsukuba
² 産業技術総合研究所情報技術研究部門
National Institute of Advanced Industrial Science and Technology
³ 高松平和病院外科
Department of surgery, Takamatsu Heiwa hospital
⁴ がん研有明病院乳腺センター外科
Breast oncology center, The Cancer Institute Hospital of the
Japanese Foundation for Cancer Research

中心部分や表面付近の区別ができないためである。

そこで、上記の問題を解決するため、特徴ベクトルが正常クラスを表す錐形状の空間に含まれる確率の算出手法とそれを基にした異常検出手法を提案する。提案手法では、錐に含まれる確率を算出するため、正常クラスの錐の広がり方向を表す空間上において正常データの確率密度関数を作成する。そして、その確率密度関数を基に特徴ベクトルが錐に含まれる確率を算出し、確率が小さいものを異常として検出する。

実験では、特徴空間上で錐形状の分布をなす人工データと乳腺超音波画像の実データを用いて提案手法による異常検出精度の検証を行った。その結果、従来の錐制約部分空間法と比較して提案手法の有効性を確認した。

2. 錐制約部分空間法

2.1 錐制約部分空間法の概要

画像認識において、部分空間法が広く用いられており、顔認識や文字認識、画像や動画からの異常検出 [2][3] において適用されている。部分空間法は、学習パターンに対して主成分分析を適用し、主成分ベクトルを算出する。そして、テスト用の特徴ベクトルと主成分ベクトルが張る空間との角度や距離を基にクラス識別や異常検出を行う。

画像から抽出される特徴ベクトルは特徴空間上の非負領域にのみ存在し、分布が偏っている場合が多く、主成分ベクトルが張る空間全体に特徴ベクトルが分布することはない。そのため、非負値を取る特徴ベクトルの分布に対しては、事前にその分布を考慮した空間を定義することで、部分空間法と比較して識別性能を向上できる。

小林らは画像から得られる特徴ベクトルが非負値であることに着目して錐制約部分空間法 [1] を提案している。非負値の特徴ベクトル群はクラス毎に特徴空間の原点を頂点とする錐形状の分布を取る。この錐形状の分布に対して、錐を用いて学習パターンを表現することで、従来の部分空間法と比較して識別性能が向上する。

2.2 錐の定義

特徴空間上において学習パターンの特徴ベクトル群が張る錐 C は次のように定義される。

$$C: \{x \mid x = \sum_{i=1}^N \alpha_i \xi_i = \Xi \alpha, \alpha_i \geq 0\} \quad (1)$$

$$\text{where } \Xi = \{\xi_1, \xi_2, \dots, \xi_N\} \quad (2)$$

$$\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_N\}^T \quad (3)$$

ここで、 N は錐を張る基底ベクトル $\xi_i (\in R^D)$ の数、 α_i は非負の結合係数である。

2.3 特徴ベクトルと錐のなす角度

錐制約部分空間法では、特徴ベクトル y と錐 C とのな




図 1 錐に含まれる特徴ベクトル

図 2 錐が重なる例

す角度 θ を基準として、識別する。角度 θ は特徴ベクトル y とその錐 C への正射影ベクトル x とのなす角度と定義される。

$$\theta = \arcsin(\min \|y - x\| / \|y\|) \quad (4)$$

$$= \arcsin(\sqrt{\min_{\alpha \geq 0} \|y - \Xi \alpha\|^2 / \|y\|^2}) \quad (5)$$

ここで、式 (5) における $\min_{\alpha \geq 0} \|y - \Xi \alpha\|^2$ は非負最小二乗法 [5] を適用することで計算できる。また、非負値の特徴ベクトルは特徴空間上の非負領域に分布する。そのため、特徴ベクトルと錐との角度 θ の範囲は $0 \leq \theta \leq \frac{\pi}{2}$ となる。

2.4 錐の構成方法

錐制約部分空間法 [1] では、3つの錐の構成方法が提案されている。1つ目の手法は、学習パターンから錐を張る基底ベクトルを求めることで厳密な凸錐（厳密凸錐）を構成する。2つ目の手法は、少数の基底ベクトルを算出することで学習パターンを包括する凸錐（包括凸錐）を構成する。そして、3つ目は、凸錐を円錐を用いて近似する手法である。

2.5 錐制約部分空間法の問題点

図 1 に示すような錐の中心部分にある特徴ベクトル y_1 と表面付近にある特徴ベクトル y_2 の錐に属する度合いを比較した場合は、錐の中心部分にある特徴ベクトル y_1 の方が大きい。しかし、錐制約部分空間法では式 (5) において、特徴ベクトル y が錐 C の中に含まれる場合は、錐形状の空間内での位置に関係なく $y = x$ となり、特徴ベクトル y の錐 C とのなす角度は 0 となる。そのため、錐の表面付近と中心付近の特徴ベクトルは区別できない。

パターン認識においては、異なるクラスに属する特徴ベクトルの分布が線形分離可能であることは少なく、錐形状の部分空間同士が重なる可能性がある。クラス識別問題において、図 2 に示すように、錐 C_1 と錐 C_2 が表現する異なるクラスの錐が重複した場合は、重複領域に含まれる特徴ベクトル y の錐との角度は 0 となるため、識別することが出来ない。また、錐制約部分空間法を正常クラスの部分空間に基づく異常検出手法に適用した場合、錐の広がりが大

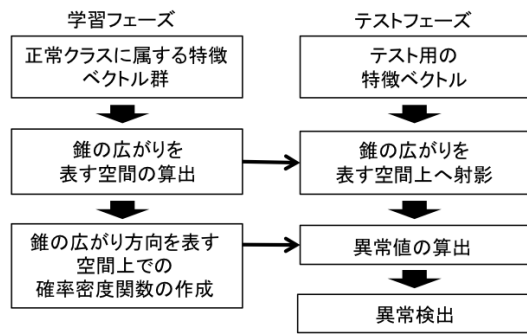


図 3 提案手法のフローチャート




図 4 錐の広がり方向を表す空間の例

きいと異常を正常と誤認識する．そのため，識別性能が低下するという問題がある．

この問題を解決するため，錐制約部分空間法と SVM を組み合わせることで複数のクラスの錐が分離するような部分空間を算出する手法が提案されている [6]．しかし，この手法はクラス識別問題を対象としているため，正常クラスの部分空間に基づく異常検出手法には適用できない．

3. 提案手法

本論文では，錐制約部分空間法を正常クラスの部分空間に基づく異常検出手法に適用した場合の問題点を解決するため，特徴ベクトルが錐形状の空間に含まれる確率の算出手法とそれを基準とした異常検出手法を提案する．提案手法では，正常クラスに属する特徴ベクトルに基づいて錐形状の空間内の確率密度分布を推定し，正常の錐に含まれる確率が小さいものを異常として検出する．

提案手法は，学習フェーズとテストフェーズにより構成されている．学習フェーズでは，学習パターンから構成される錐の広がり方向を表す空間を算出し，その錐の広がり方向を表す空間上において学習パターンの分布を推定して確率密度関数を作成する．テストフェーズでは，テスト用の特徴ベクトルを学習フェーズで算出した錐の広がり方向を表す空間上に射影し，その空間上において確率密度関数を基にテスト用の特徴ベクトルが錐に含まれる確率を算出し，それを基に異常を検出する．以下，図 3 に示すフローチャートに沿って各処理について説明する．

3.1 錐の広がり方向を表す空間の算出

錐の広がり方向を表す空間の算出方法としては，錐制約部分空間法における包括凸錐の構成方法を利用する．サンプル数 N の学習パターンの特徴ベクトル群 $X = \{x_1, \dots, x_N\}$ (x_i は D 次元の列ベクトル) に対し，次式に示すようにベクトルのノルムを 1 とする正規化を施して，特徴ベクトル群を単位超球面上に射影する．

$$\bar{x}_i = \frac{x_i}{\|x_i\|} \quad (i = 1, \dots, N) \quad (6)$$

単位超球面上の特徴ベクトル群 $\bar{X} = \{\bar{x}_1, \dots, \bar{x}_N\}$ に対して自己相関行列 $R_{\bar{X}}$ を算出する．

$$R_{\bar{X}} = \bar{X} \bar{X}^T \quad (7)$$

自己相関行列 $R_{\bar{X}}$ に対して固有値問題を解くことで固有値・固有ベクトルを算出する．

$$R_{\bar{X}} U = U \Lambda \quad (8)$$

ここで， U は固有ベクトルを列とする行列 $U = \{u_1, \dots, u_N\}$ であり， Λ は固有値を対角要素とする対角行列 $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_D)$ である．自己相関行列に対する固有値問題では，元の特徴空間における学習パターンを低次元に正射影したときの写像の誤差が最小となるベクトルを算出する．そのため，固有ベクトルを固有値の大きさに従って降順に並べると，第 1 固有ベクトル u_1 は特徴空間の原点からの錐の方向ベクトルとなり，第 2 以降の固有ベクトルが張る空間は学習パターンの超球面上での分布の広がり方向を表す．元の特徴空間上における特徴ベクトルを錐の広がり方向を表す空間上に射影するための射影行列 U_C は次式により定義される．

$$U_C = \{u_2, \dots, u_{M+1}\} \quad (1 \leq M \leq D-1) \quad (9)$$

ここで， U_C は錐の広がり方向を表す空間を張る基底ベクトルを列とする行列である．また， M は錐の広がり方向を表す空間の次元数を表すパラメータである． M が大きくなるほど錐の広がり方向を表す空間は高次元となり，学習パターンの確率密度の推定が困難となる．図 4 に 3 次元 ($D = 3$) の特徴空間の場合の錐の方向ベクトルと，錐の広がり方向を表す 2 次元 ($M = 2$) の空間の例を示す．

3.2 錐の広がり方向を表す空間上での確率密度関数の作成

錐の広がり方向を表す空間上での学習パターンの分布から確率密度関数を作成する．確率密度関数を作成する手法としては，ノンパラメトリックな確率密度の推定方法の一つで高精度に確率密度を推定可能なカーネル密度推定法 [7] を用いる．

錐の広がり方向を表す空間上において学習パターンの確率密度関数を作成する手順は以下の通りである．まず，単位超球面上に射影された学習パターンの特徴ベクトル \bar{x}_i を

次式により錐の広がり方向を表す空間上に射影して、錐の広がり方向を表す空間上での特徴ベクトル \mathbf{x}_i^c を算出する．

$$\mathbf{x}_i^c = U_c^T \bar{\mathbf{x}}_i \quad (i = 1, \dots, N) \quad (10)$$

次に、錐の広がり方向を表す空間上での学習パターンの特徴ベクトル群を基に、カーネル密度推定法 [7] を用いて学習パターンの確率密度関数 $p(\mathbf{t})$ を作成する．

$$p(\mathbf{t}) = \frac{1}{N} \sum_{i=1}^N \frac{1}{h^M} k\left(\frac{\mathbf{t} - \mathbf{x}_i^c}{h}\right) \quad (11)$$

$$\text{where } k(\mathbf{x}) = \frac{1}{(2\pi)^{M/2}} \exp\left(-\frac{1}{2}\mathbf{x}^T \mathbf{x}\right) \quad (12)$$

ここで、 \mathbf{t} は確率変数であり、 M は錐の広がり方向を表す空間の次元数、 h はバンド幅を表すパラメータである．また、 $k(\mathbf{x})$ はカーネル関数であり、提案手法ではガウスカーネル関数を使用する．

3.3 異常値の算出

テストフェーズでは、学習フェーズで作成した錐の広がり方向を表す空間上での学習パターンの確率密度関数を用いて、テスト用の特徴ベクトルが錐に含まれる確率を算出し、その確率を基に識別を行う．テスト用の特徴ベクトル \mathbf{y} が錐に含まれる確率を算出するために、まず、次式により特徴ベクトル \mathbf{y} を単位超球面上へ射影する．

$$\bar{\mathbf{y}} = \frac{\mathbf{y}}{\|\mathbf{y}\|} \quad (13)$$

そして、学習フェーズにおいて算出した錐の広がり方向を表す空間への変換行列 U_c を用いて次式により特徴ベクトルを錐の広がり方向を表す空間へ射影して、錐の広がり方向を表す空間上での特徴ベクトル \mathbf{y}^c を算出する．

$$\mathbf{y}^c = U_c^T \bar{\mathbf{y}} \quad (14)$$

次に、錐の広がり方向を表す空間に射影された特徴ベクトルの錐に含まれる確率を学習フェーズで算出した確率密度関数を用いて算出する．そして、この錐に含まれる確率を基準に、テスト用の特徴ベクトルを識別する．学習フェーズで作成した確率密度関数 $p(\mathbf{y}^c)$ は特徴ベクトルが錐に含まれる確率となるため、異常であることの確率 $p_{\text{abnormal}}(\mathbf{y}^c)$ は次式で定義できる．

$$p_{\text{abnormal}}(\mathbf{y}^c) = 1 - p(\mathbf{y}^c) \quad (15)$$

この異常であることの確率 $p_{\text{abnormal}}(\mathbf{y}^c)$ を異常値として、異常値が予め設定した閾値以上のものを異常として検出する．

4. 計算機実験

本章では、提案手法の有効性を検証するために行った 2 次元の特徴空間上において 2 つの錐を形成する人工データに対する異常検出実験と乳腺超音波画像を使った実データに対する異常検出実験について述べる．




図 5 実験で使った人工データの散布図

4.1 人工データを用いた実験

提案手法の有効性を検証するため、錐形状の分布を取る人工データを生成して異常検出実験を行った．実験では、従来の錐制約部分空間法の中で学習パターンの近似精度が最も高い厳密凸錐との比較実験を行った．比較方法としては、ROC(Receiver Operating Characteristic) 解析における AUC(Area Under the Curve) 値を算出して評価を行う．ROC 曲線は、横軸に偽陽性率 (False Positive Rate)、縦軸に真陽性率 (True Positive Rate) をとり、正常か異常かを分類する閾値を変化させた場合の偽陽性率と真陽性率の軌跡である ROC 曲線に基づいて識別性能を評価する．ここで、偽陽性率は正常データを異常として検出した割合で、真陽性率は異常データを正しく異常として検出する割合を表す．AUC 値は ROC 曲線下面積であり、AUC 値は 0.5 から 1 までの値をとる．異常検出が完全な場合は 1 となり、ランダムな場合は 0.5 となる．

4.1.1 人工データ

本実験で用いるデータは 2 次元の特徴空間上に正常データと異常データが異なる錐形状の分布を取るよう人工的に作成した．作成したデータは錐の広がり方向を表す空間上で正規分布を取るようにし、錐の中心部分ではデータの密度が大きく、錐の表面付近でデータの密度が小さい．また、正常データと異常データの分布が線形分離しない場合に関する検出性能の評価を行うため、実験で使った正常データの分布と異常データの分布は重なるように生成した．使用したデータの分布を図 5 に示す．学習フェーズで使用する正常データを 1000 サンプル、テストフェーズで使用する正常データを 1000 サンプル、異常データを 1000 サンプル用意した．

4.1.2 人工データに対する実験結果

2 次元の特徴空間上での人工データに対する従来の錐制約部分空間法での錐との角度と提案手法での異常値において、それぞれの閾値を変化させたときの ROC 曲線を図 6 に示す．厳密凸錐での AUC 値は 0.74、提案手法での AUC 値は 0.90 となっている．この結果より、提案手法では従




図 6 人工データに対する従来手法と提案手法の ROC 曲線

来手法と比較して AUC 値が 0.16 向上していることがわかる。これは、従来の錐制約部分空間法では錐の中に含まれる特徴ベクトルと錐とのなす角度が全て 0 となり、錐の中にある異常データを全て正常として判定し、異常を見落としてしまったためである。一方で、提案手法では、テスト用の特徴ベクトルが錐形状の空間内に含まれる確率を基に異常値を算出しており、正常データの密度が大きい錐の中心部分では異常値が小さく、逆に表面付近の異常値が大きくなるため、正常クラスの錐に含まれる異常サンプルも正しく検出できる。

4.2 乳腺超音波画像からの腫瘍像検出実験

提案手法の実世界のデータに関する有効性を検証するため、医用画像の 1 つである乳腺超音波画像を対象として、腫瘍像の検出実験を行った。

わが国のがん患者数は年々増加しており [8][9]、女性に最も多いのは乳がんで、16 人に 1 人が経験すると言われている。その検査方法として近年最も注目されているのが乳腺超音波検査であるが、超音波プローブの操作と正確な診断を同時に行うための非常に高度な技量が必要なため、熟練した医師の養成に時間がかかるという課題がある。そこで、画像認識技術を用いて病変を自動検出し、医師の診断を支援するシステムの開発が急務となっている。

本節では、乳がんの疑いのある病変の 1 つである腫瘍像を検出対象として異常検出することを目的に 2 つの実験を行った。1 つ目は、乳腺超音波画像から腫瘍像を異常として検出し、提案手法の有効性を検証するための実験である。2 つ目は、提案手法の異なる被験者の汎化性能を検証するための実験である。

4.2.1 乳腺超音波画像

本実験で使用した乳腺超音波画像は画素数 800×600 、フレームレートは 30fps、256 階調の動画像である。実験では、乳がんの兆候である腫瘍像ありと診断された被験者 7 人から撮影された動画像 A, B, C, D, E, F, G を用意




図 7 乳腺超音波画像の例




図 8 乳腺超音波画像に対する ROC 曲線

した。これらの動画像の各フレームから、正常な乳腺領域を 50×50 画素の静止画像としてランダムに切り出し、正常な乳腺画像を作成した。また、図 7 に示すように、腫瘍像が描出される部位を 50×50 画素の静止画像として手動で切り出し、腫瘍像画像を作成した。

画像からの特徴抽出手法には、高次局所自己相関特徴 (Higher-order Local Autocorrelation; HLAC) 特徴 [4] を用いている。これを採用した理由は、自己相関関数により定義されているためノイズに頑健であること、検出対象の輪郭を切り出す処理が不要であること等の性質が、スペックルノイズが非常に多い上に、腫瘍像の輪郭が不鮮明である事が多い超音波画像に大変適していると考えられるためである。

4.2.2 乳腺超音波画像に対する有効性の検証

本実験では予備実験を行い、錐の広がり方向を表す空間の次元数 M を 1 から 34 まで変化させ、カーネル密度推定法におけるバンド幅 h を 0.01 から 20 まで変化させたときの最も高い AUC 値のパラメータを決定した。本実験では、学習フェーズにおいて、被験者 7 人の正常な乳腺画像からランダムに 10000 枚取得し、HLAC 特徴を抽出することで、正常クラスに特徴ベクトル群を作成する。テストフェーズにおいては、学習フェーズで使用した画像とは異なる正常な乳腺画像 1000 枚と腫瘍像画像 1363 枚を使用した。

図 8 に厳密凸錐と提案手法の ROC 曲線を示す。この結

表 1 各被験者に対する AUC 値

	厳密凸錐	提案手法
被験者 A	0.87	<u>0.93</u>
被験者 B	0.50	<u>0.77</u>
被験者 C	0.61	<u>0.80</u>
被験者 D	0.80	<u>0.92</u>
被験者 E	0.50	<u>0.62</u>
被験者 F	0.71	<u>0.85</u>
被験者 G	0.52	<u>0.81</u>




図 9 被験者 A の腫瘍像画像




図 10 被験者 E の腫瘍像画像

果より、提案手法は厳密凸錐の ROC 曲線よりも左上方に存在する。また、厳密凸錐の AUC 値は 0.85、提案手法の AUC 値は 0.87 となっており、厳密凸錐と比較して提案手法の AUC 値が向上したことがわかる。提案手法で算出された錐の広がり方向を表す空間における正常データの確率密度関数が正常であることを精度良く捉え、厳密凸錐では見落とされていた腫瘍像画像を検出できたことが、性能向上の理由であると考えられる。

4.2.3 異なる被験者に対する汎化性能の影響

乳腺超音波画像は被験者の年齢や体格などにより、乳腺組織や腫瘍像の写り方の様子が異なる。そこで異なる被験者に対する提案手法の汎化性能を検証するため、被験者毎の交差検定を行った。7人の被験者の中から6人の正常な乳腺画像を学習フェーズで使用し、残りの1人の被験者の正常な乳腺画像と腫瘍像画像を用いた異常検出性能の評価を、被験者の数だけ繰り返し行った。

実験の結果を表1に示す。表1は各被験者をテストフェーズで使用したときの AUC 値を示している。提案手法と厳密凸錐のうち、AUC 値が高い方を下線で示す。この結果から、被験者毎のばらつきは大きいですが、提案手法の AUC 値が厳密凸錐よりも高いということがわかる。

厳密凸錐では、被験者 B, E, G において AUC 値が 0.5 となっており、正常な乳腺画像と腫瘍像画像を全く識別できていない。錐制約部分空間法により構成された厳密凸錐が正常データを広い空間で表現したため、腫瘍像画像から得られた特徴ベクトルも錐形状の空間に含まれてしまったことが原因であると考えられる。すなわち、正常な乳腺画像と腫瘍像画像から得られた特徴ベクトルが錐の中に含まれ、錐との角度が全て 0 となり、識別できなかったのではないかと推察される。

一方、提案手法においては被験者 A の AUC 値は 0.93 であるのに対し、被験者 E では 0.62 と低下している。これは、図 9, 10 に示すように被験者 A では腫瘍像の輪郭が鮮明に描出されているのに対し、被験者 E では輪郭が不鮮明に描出されており、被験者 A と被験者 E から得られた腫瘍像画像の描出の様子が大きく異なっている事が原因であると考えられる。厳密凸錐と比較して AUC 値は向上したものの、提案手法においても異なる被験者の影響を受けており、これを低減することが今後の課題である。

5. おわりに

本論文では、錐制約部分空間法を正常クラスの部分空間に基づく異常検出手法に適用した場合の問題点を解決するため、特徴ベクトルが錐形状の空間に含まれる確率の算出手法と、その確率を基準とした異常検出手法を提案した。

提案手法では、正常クラスに属する特徴ベクトルに基づいて、錐形状の空間内の確率密度分布を推定し、正常クラスの錐に含まれる確率を算出する。錐に含まれる確率を算出することで、特徴ベクトルが空間に属する度合いを算出でき、錐の中心付近や表面付近にある特徴ベクトルを区別できる。これにより、従来の錐制約部分空間法と比較して識別性能が向上する。実験では、提案手法の有効性の検証を行うため、2次元空間上での錐を形成する人工データを用いた異常検出実験と乳腺超音波画像から腫瘍像を検出することを目的とした実データに対する実験を行った。実験の結果、提案手法では、正常クラスを表す錐の広がり大きい場合においても、異常を見落とすことなく検出できることを確認した。そのため、従来の錐制約部分空間での厳密凸錐と比較して提案手法の識別性能が向上し、提案手法の有効性を確認した。

参考文献

- [1] 小林匠, 大津展之, “パターン識別のための錐制約部分空間法”, 電子情報通信学会論文誌 (D), Vol.92, No.1, pp.104-111, 2009
- [2] 南里卓也, 大津展之, “複数人動画像からの異常行動検出”, 情報処理学会論文誌 コンピュータビジョンとイメージメディア, Vol.46, No.15, pp.43-50, 2005
- [3] Nosato, H and Kurihara, T et al, “An Extended Method of Higher-order Local Autocorrelation Feature Extraction for Classification of Histopathological Images”, IPSJ Trans. CVA, Vol.3, pp.211-221, 2011
- [4] OTSU, N, “A New Scheme for Practical Flexible and Intelligent Vision System”, Proc. IAPR Workshop on Computer Vision, pp.431-435, Oct.1988,
- [5] Bro, R and Jong, S, “A fast non-negativity-constrained least squares algorithm”, J. Chemometrics, Vol.11, No.5, pp.393-401, 1997
- [6] 北村卓也, 竹内翔吾, 阿部重夫, “標本部分空間法に基づくサポートベクトルマシンの開発”, 情報処理学会論文誌. 数理モデル化と応用, Vol.3, No.3, pp.12-23, 2010
- [7] B. W. Silverman and P. J. Green, “Density Estimation for Statistics and Data Analysis”, Chapman and Hal, 1986
- [8] 人口動態統計によるがん死亡データ (1958 ~ 2010 年), 国立がん研究センターがん対策情報センター
- [9] 地域がん登録全国推計によるがん罹患データ (1975 年 ~ 2006 年), 国立がん研究センターがん対策情報センター