

錘に基づくパターン識別方法

小林 匠^{†,††} 大津 展之^{†,††}

[†]産業技術総合研究所 〒305-8568 茨城県つくば市梅園 1-1-1

^{††}筑波大学 〒305-8573 茨城県つくば市天王台 1-1-1

あらまし 一般にパターン認識では、特徴ベクトルは非負制約となることが多く、そのような性質を持つ分布は原点を頂点とする錘として表現される。そこで、新たなパターン識別方法として錘による制約付きの部分空間法を提案する。本手法では、部分空間法と同様に錘の方向に沿ったスケール倍や加法などの広いパターン変動を許容する一方で、錘の境界面での厳密な識別が可能となる。本論文では特に、凸錘と円錐の2つの手法を提案する。顔及び人検出の実験に提案手法を適用することによりその有効性を確認した。

Pattern Classification based on Cone

Takumi KOBAYASHI^{†,††} and Nobuyuki OTSU^{†,††}

[†] National Institute of Advanced Industrial Science and Technology

^{††} University of Tsukuba

Abstract In pattern recognition, feature vectors are occasionally subjected to non-negative constraints. This characteristic can be expressed by a cone in a feature vector space. In this paper, we propose a cone-restricted subspace method. In addition to that the proposed method admits scaling and addition of vectors as well as ordinary subspace methods, it can also strictly classify the vectors at the boundary of the cone. We propose two methods based on a convex cone and on a circular cone. The experimental results for face and person detection showed the effectiveness of the proposed method.

1. ま え が き

パターン認識では対象の構造を反映した認識に本質的な特徴(ベクトル)を抽出することが重要となるが、最終的に識別結果(顔検出では顔であるか否かなど)を得るためには、得られた特徴を効果的に識別することも同様に重要となる。つまり、入力パターンデータにおける本質的な情報を抽出しつつ、本質的でない各種変動に対していかに不変性を保った認識・識別処理を行えるかが重要なのである。ここでの本質的でない変動とは認識課題などにより変わりうるが、パターンの変動分布の形を仮定することで、様々な識別手法を構築することができる。

パターン識別方法としては、kernel SVM に代表される kernel 法を用いた手法[1]が近年多く用いられており、高い識別能力を示している。特に gaussian kernel を用いたものが多く、これはパターン変動が正規分布などのクラスター状の分布となることが多いためと考えられる。つ

まり、kernel 法はクラスター状のパターン変動を仮定した手法とも言える。一方で、パターン変動を線形空間と仮定した識別方法として部分空間法[2]が挙げられる。部分空間法は古くは複合類似度法[3]から、入力が特徴ベクトル集合の場合には相互部分空間法[4]、制約相互部分空間法[5]など特に日本において発展を遂げている手法である。実際に変動が線形空間となる例としては、顔認識における照明変動[6]、加法性をもつ特徴量[7]など実問題に多く見られる。そのため、顔認識[5]や CHLAC 特徴[7]を用いた異常行動の検出[8]において部分空間法は良好な識別性能を示している。

部分空間法ではパターンの変動を許容するという大きなロバスト性を有しているが、これはパターンの変動分布の近似という観点からは必ずしも好ましいとは言えない。つまり、変動分布を線形部分“空間”とする近似はその精度が荒いと考えられる。例えば図 1. に示されるように、各種変動を受けた特徴ベクトルが部分空間“全




図1 部分空間と錘

体”を覆うことは希であり、実際には部分空間内の一部の領域に分布している。一般に特徴ベクトル（の要素）は物理量や頻度など非負値となることが多く（画像濃淡値やヒストグラム値など）、その場合にはベクトル空間の非負領域にのみ存在している。このことから、分布を部分空間“全体”とするのは荒い（広すぎる）近似であることがわかる。

さらに部分空間の次元の取り方も重要となる。パターン分布はその部分空間内において次元毎に異なる変動を持つ。しかし、部分空間法である次元を採用することは、その次元でのパターン変動を無視して当該次元の空間を（いくら変動が小さくとも）全て近似に用いることを意味している。そのため、採用される次元（数）によって識別力が大きく影響を受ける。複数対象の場合には各対象に対応する複数の部分空間を用いるが、その場合にも部分空間同士が重複しないような次元を採用することが重要となる。

本論文では上述の問題点を解決するために、パターンの変動分布をより良く近似し、かつ部分空間法のロバスト性を保持するような新たなパターン識別方法として錘による制約付きの部分空間法を提案する。提案手法におけるパターン分布の近似方法を図1.(b)に示す。ここで分布は原点を頂点とする錘として表現される。これは、Illumination Cone [6] や HLAC/CHLAC 特徴ベクトル [7] における、特定の特徴ベクトルの“足し算”として変動が記述されることに注目した表現となっている。錘では部分空間と同様に錘の方向に沿ったスケール倍や加法などの広い変動（線形性）を許容する一方で、原点周りの広がりには錘によって制限されているため^(注1)、クラスターベースの識別と同様に錘の境界面での厳密な識別も可能となる。そのため、錘による識別は従来のクラスターベースの識別と部分空間法との中間に位置する手法となることが期待される。本論文では特に、凸錘と円錐の2つの手法を提案する。

(注1)：部分空間では制限されず 360 度全て含む

2. 錘

まず本論文で扱う錘について、その定義と性質について述べる。

2.1 定義

凸錘 凸錘は有限個の基底ベクトルにより張られ（図2）、

$$\left\{ \mathbf{x} \mid \mathbf{x} = \sum_{i=1}^N \alpha_i \boldsymbol{\xi}_i = \Xi \boldsymbol{\alpha}, \alpha_i \geq 0 \right\}, \quad (1)$$

と定式化される。ここで、 α_i は（非負）結合係数、 $\boldsymbol{\xi}_i$ は凸錘の基底ベクトル、 N は基底ベクトルの数を表している。**円錐** 単位超球面上への射影を考えると、凸錘は超球面上での凸包として表現されるが、円錐は超球面上での超円となる。超円は超球と超平面との交線として表現できることから、円錐は

$$\left\{ \mathbf{x} \mid \boldsymbol{\mu}^T \frac{\mathbf{x}}{\|\mathbf{x}\|} \geq b \right\}, \quad (2)$$

と定式化される。ここで、 $\boldsymbol{\mu}$ は円錐の方向（中心）ベクトル、 $\boldsymbol{\mu}^T \mathbf{x} = b$ が交線を成す超平面となっている。

2.2 性質

部分空間は $\left\{ \mathbf{x} \mid \mathbf{x} = \sum_{i=1}^N \alpha_i \boldsymbol{\xi}_i \right\}$ と定式化されるため、凸錘と部分空間の違いは結合係数の非負性のみである。結合係数の非負性は Non-negative Matrix Factorization [11] などにより、近年注目されている特長でもある。ここで非負性は基底ベクトルの加法のみによりパターン変動が生じることを意味しており、SIFT [12] などのヒストグラム特徴や HLAC/CHLAC [7] などの積特徴が有する加法性に合致している。

錘 C はスケールに関しても閉じており ($\mathbf{x} \in C, s > 0 \Rightarrow s\mathbf{x} \in C$)、部分空間と同様にスケール不変な表現ともなっている。そこでスケール不変な斉次座標として単位超球面上への射影を考えると、凸錘は超球面上での凸包として、円錐は超円として超球面上のサンプル分布を表現している。このことから、部分空間よりも分布の近似精度が向上し、パターンへの識別能力が高くなることが期待される。また、実際の有限サンプル集合は凸錘を構成しており、サンプル数が多くなるほど（楕）円錐に近づくため、円錐はサンプル凸錘の近似表現となっている。

3. 錘に基づくパターン識別方法の理論

本論文では、凸錘による識別方法 (3.1)、および円錐による識別方法 (3.2) の2つの錘制約付き部分空間法を提案する。いずれも錘への角度によりパターンを識別する（図2,3）。前述の超球面射影を考えると、錘への角度とは超球面上の凸包または超円への測地線距離としても解釈することができる。




図2 ベクトルと凸錐の角度




図3 ベクトルと円錐の角度

3.1 凸錐による識別方法

本節ではまず、サンプル集合の成す凸錐の基底ベクトルの学習方法を述べる、次に、凸錐と入力ベクトルの角度の算出方法を説明する。

3.1.1 基底ベクトルの学習

凸錐の定義(式(1))より、全てのサンプルベクトルを基底ベクトルとして用いることも可能であるが、これでは凸錐の表現として冗長であり基底ベクトルの数が増えることで計算コストが大きくなってしまう。そこで、サンプル集合が成す凸錐の本質的な(独立な)基底ベクトルを学習により求める。

基底ベクトルの学習方法として、1) サンプル集合の成す凸錐の基底ベクトルを厳密に求める方法、2) サンプル集合の成す凸錐を包括するような凸錐の基底ベクトルを求める方法の2つを提案する。

厳密な基底ベクトル サンプル集合が成す凸錐の「独立な」基底ベクトルを求める。

[定義1] サンプル集合を $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]$ とすると、非独立なサンプルとは $\mathbf{x}_t = \mathbf{X}_{\bar{t}} \tilde{\alpha}_{\bar{t}} (\tilde{\alpha}_{\bar{t}} \geq 0)$ となる。ここで N はサンプル数、 \bar{t} は t 番目のサンプル(または係数)を除いた集合を表す。

[定理1] 非独立なサンプルを除いても凸錐は不変である。証明。凸錐 C において、非独立サンプルを \mathbf{x}_t とし、 \mathbf{x}_t を除いた凸錐 $C_{\bar{t}}$ を考えると

$$\begin{aligned} C_{\bar{t}} &= \{\mathbf{x} | \mathbf{x} = \mathbf{X}_{\bar{t}} \boldsymbol{\alpha}_{\bar{t}}, \boldsymbol{\alpha}_{\bar{t}} \geq 0\} \subset C \\ \forall \mathbf{x} \in C, \mathbf{x} &= \mathbf{X} \boldsymbol{\alpha} = \mathbf{X}_{\bar{t}} \boldsymbol{\alpha}_{\bar{t}} + \alpha_t \mathbf{x}_t \\ &= \mathbf{X}_{\bar{t}} (\boldsymbol{\alpha}_{\bar{t}} + \alpha_t \tilde{\alpha}_{\bar{t}}) \in C_{\bar{t}} \\ \therefore C_{\bar{t}} &= C \quad \square \end{aligned}$$

定理より、非独立なサンプルを除いていくことで最終的に凸錐を基本的に構成する独立サンプルのみが残ること

Leave-one-out による基底ベクトルの選択

- 1) サンプル集合 \mathbf{X} からランダムに部分集合 \mathbf{X}_S を抽出(その補集合を $\mathbf{X}_{\bar{S}}$ とする)。
- 2) 各サンプル $\mathbf{x}_i \in \mathbf{X}_S$ に対して、そのサンプルを除いた凸錐 $C_{S \setminus i}$ への角度 θ_i を算出 (Leave-one-out 法)。
- 3) 閾値 $\theta_{thre} (\approx 0)$ に対して $\theta_i < \theta_{thre}$ のサンプルを非独立サンプルとして \mathbf{X} および \mathbf{X}_S から除去。
- 4) サンプル $\mathbf{x}_j \in \mathbf{X}_{\bar{S}}$ に対して \mathbf{X}_S の成す凸錐 C_S への角度 θ_j を算出し、3)と同様に閾値未満のサンプルを非独立サンプルとして \mathbf{X} から除去。
- 5) 1)~4)を複数回繰り返し、除去サンプルがなくなるようになれば終了、そうでなければ再び繰り返す。

図4 厳密な基底ベクトルの学習

PCA による基底ベクトル

- 1) ノルム正規化 $\mathbf{z}_t = \mathbf{x}_t / |\mathbf{x}_t| \in \mathbf{R}^d$
- 2) サンプル集合を $\mathbf{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_N]$ として、主成分分析 $\mathbf{Z} \mathbf{Z}^T \mathbf{e}_i = \lambda_i \mathbf{e}_i$
- 3) $r+1$ 次元までを採用する。第 $i (i=2, \dots, r+1)$ 固有ベクトル上の分布 $\mathbf{Z}^T \mathbf{e}_i$ の端点 (x_L^i, x_R^i) として $\pm k \sqrt{r} \sqrt{\lambda_i}$ の2点を選ぶと基底ベクトルは

$$\begin{aligned} \xi_{2i-3} &= \mathbf{e}_1 + x_L^i \mathbf{e}_i = \mathbf{e}_1 - k \sqrt{r} \sqrt{\lambda_i} \mathbf{e}_i \\ \xi_{2i-2} &= \mathbf{e}_1 + x_R^i \mathbf{e}_i = \mathbf{e}_1 + k \sqrt{r} \sqrt{\lambda_i} \mathbf{e}_i \end{aligned} \quad (3)$$

の $2r$ 個得られる。なお PCA により採用する次元数 $r+1$ は、第2以降の固有値での累積寄与率 $\eta_i = \sum_{j=2}^i \lambda_j / \sum_{j=2}^d \lambda_j$ に従って決定される。

図5 PCA による基底ベクトルの学習

がわかる。図4の処理により独立な基底ベクトルを得る。

近似的な基底ベクトル サンプル集合が成す凸錐を包括する単純な形の凸錐を近似として用い、その基底ベクトルを求める。単位超球面上への射影により、サンプル集合(凸錐)の広がり超球面上の分布により表現される。そこで、主成分分析(PCA)によりその分布を近似し、サンプル分布を包括する超球面上の凸包を求める。まず、サンプルベクトルを正規化(単位超球面上へ射影)し、自己相関行列に対するPCAを適用する。得られた固有ベクトルを固有値の大きさに従い並べると、非負特徴ベクトルなどの多くの場合で第1固有ベクトルは原点からの凸錐の方向(中心)ベクトルとなり、それに直交する第2以降の固有ベクトルが超球面上の分布の方向を示す(図6(a))。つまり、分布は第2以降の固有軸上での広がりとして表現され、各固有軸上で分布範囲を包括するような2点を選ぶことで分布を包括する凸包を構成できる(図6(b))。アルゴリズムは図5のようになる。第1固有ベクトルが




図6 超球面サンプルに対する主成分分析




図7 超平面

錘の中心ベクトルとなることから、第2以降の固有軸上での分布は原点が中心となり、その分散は固有値 λ_i で与えられる。さらに、半径 $k\sqrt{\lambda}$ の r 次元超球を内包する凸包を考えるとその頂点は式(3)となる。ここで凸包の頂点はサンプル分布の各軸上の端点でも良い。

サンプルを単位超球面へ射影し、さらに第1固有ベクトルに直交する第2以降の固有軸上への射影は、正準化処理[3]と同等である。

3.1.2 凸錘への角度

ベクトルの凸錘への角度は図2のように、入力ベクトルと凸錘への正射影ベクトルとの成す角度として定義される。そのため、ベクトル \mathbf{y} と凸錘 C との成す角度 θ は

$$\theta = \arcsin\left(\frac{\min_{\mathbf{x} \in C} \|\mathbf{y} - \mathbf{x}\|}{\|\mathbf{y}\|}\right). \quad (4)$$

ここで $0 \leq \theta \leq \pi/2$ である。つまり、角度が $\theta > \pi/2$ の場合には常に式(4)において $\mathbf{x} = \mathbf{0}$ となってしまう角度を測ることができない ($\theta = \pi/2$ となる)。凸錘内のベクトル \mathbf{x} は式(1)のように表現できることから、角度の算出は正射影の結合係数 α を求める次の非負最小二乗法[9]へと帰着する。

$$\min_{\alpha} \|\mathbf{y} - \alpha \mathbf{c}\|^2 \quad \text{s.t.} \quad \alpha \geq 0$$

一般に特徴ベクトル(の要素)は非負の値をとることが多く、その成す角度は常に $0 \leq \theta \leq \pi/2$ となり、本手法が適用可能となる^(注2)。

3.2 円錐による識別方法

本節ではまず、サンプル集合が成す凸錘を近似する円錐の学習方法を述べ、次に円錐への入力ベクトルからの角度の算出方法を説明する。

3.2.1 円錐の学習

円錐はサンプル集合の成す凸錘の近似である。ここでは、まず近似精度を向上させるための前処理について、次に円錐の学習方法について述べる(アルゴリズムは図8)。

次元近似 元の特徴ベクトル空間における円錐近似では全ての次元への等方的な広がり仮定しており、サンプルが存在していない冗長な次元も含まれている。そこで、

3.1.1と同様に超球面への射影後にPCAを行い、サンプルが存在する部分空間での円錐近似を行う。

空間近似 さらに、円錐は超球面上での超円として表現され、サンプルが空間的に等方に分布していると仮定している。しかしながら多くの場合、特に上述のPCA処理後の分布は楕円として表現される。そこで、超球面上でのサンプル分布の白色化を行って等方分布へ変換することで、その後の(等方的な)円錐による近似の精度を大きく向上させることができる。3.1.1より、PCAの結果、第1軸は錘の中心ベクトルとなり第2軸以降が超球面上の楕円分布の軸となる。白色化後の超球面上の円分布の半径は任意であることから、第3軸以降を第2軸での標準偏差を基準半径として白色化する。

超平面の学習 円錐は式(2)のように、単位超球と超平面との交線の超円により表現される(図7(a))。従ってサンプル分布を近似する円錐とは、単位超球面上でサンプル集合(凸包)を内包する最小円となる。超円の半径は交差する超平面の原点からの距離に従って小さくなることから(図7(b))、円錐を示す超平面は

$$\min_{\mu, b} \frac{1}{2} \|\mu\|^2 - b \quad \text{s.t.} \quad \mu^T \mathbf{x}_i \geq b \quad (5)$$

から求まる。ただし、サンプル \mathbf{x}_i はノルム正規化されているとする ($\|\mathbf{x}_i\| = 1$)。これは、1-class SVM[10]の最適化問題と同一であるため、SVMの凸2次計画法を用いて求めることができる。

以上をまとめると図8のような処理の流れとなる。

3.2.2 円錐への角度

ベクトルの円錐への角度は図3(a)のように、入力ベクトルと円錐表面への正射影ベクトルとの成す角度として定義される。まず、入力ベクトル \mathbf{y} を式(8)により部分空間へ射影しスケールリングする ($\tilde{\mathbf{y}} = \mathbf{S}\mathbf{E}^T\mathbf{y}$)。次に $\tilde{\mathbf{y}}$ の円錐表面への単位射影ベクトル \mathbf{a} を求める。入力ベクトル $\tilde{\mathbf{y}}$ と円錐 C の方向ベクトル μ を含む平面で円錐を切ると、断面は図3(b)のようになる。そのため射影 \mathbf{a} は

$$\mathbf{a} = \cos \theta_C \mu + \sin \theta_C \frac{\tilde{\mathbf{y}} - (\tilde{\mathbf{y}}^T \mu) \mu}{\|\tilde{\mathbf{y}} - (\tilde{\mathbf{y}}^T \mu) \mu\|} \quad (6)$$

となる。ここではスケールリングにより空間が歪んでいる

(注2)：主成分分析や判別分析等の変換を行った場合はその限りではない

- 1) ノルム正規化 $\mathbf{z}_t = \mathbf{x}_t / \|\mathbf{x}_t\| \in \mathbb{R}^d$
- 2) 次元近似
サンプル集合を $\mathbf{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_N]$ として, 主成分分析 $\mathbf{Z}\mathbf{Z}^T \mathbf{e}_i = \lambda_i \mathbf{e}_i$
- 3) 空間近似
 r 次元部分空間へ射影した後に白色化

$$\hat{\mathbf{z}}_t = \mathbf{S}\mathbf{E}^T \mathbf{z}_t. \quad (8)$$

ここで, スケーリング行列 $\mathbf{S} = \text{diag}(1, 1, \sqrt{\frac{\lambda_2}{\lambda_3}}, \dots, \sqrt{\frac{\lambda_2}{\lambda_r}})$, 射影行列 $\mathbf{E} = [\mathbf{e}_1, \dots, \mathbf{e}_r]$. なお部分空間の次元数 r は,

第 2 以降の固有値での累積寄与率 $\eta_i = \sum_{j=2}^i \lambda_j / \sum_{j=2}^d \lambda_j$ に従って決定される.

4) 超平面の学習

白色化したサンプル $\hat{\mathbf{z}}_t = \hat{\mathbf{z}}_t / \|\hat{\mathbf{z}}_t\|$ に対して 1-class SVM により円錐を表す超平面を求め

$$\min_{\mu, b} \frac{1}{2} |\mu|^2 - b \quad \text{s.t.} \quad \mu^T \hat{\mathbf{z}}_i \geq b \quad (9)$$

上記最適化問題の解 $\mu \leftarrow \mu / |\mu|, b \leftarrow |\mu|b$ がそれぞれ超平面の法線ベクトル (円錐の方向ベクトル) と切片となる.

図 8 円錐学習のアルゴリズム

ために, \mathbf{a} を元の空間表現に戻すことで \mathbf{y} との角度を求め

$$\theta = \arccos \frac{\mathbf{y}^T \mathbf{E}\mathbf{S}^{-1}\mathbf{a}}{\|\mathbf{y}\| \|\mathbf{E}\mathbf{S}^{-1}\mathbf{a}\|} = \arccos \frac{\hat{\mathbf{y}}^T \mathbf{S}^{-2}\mathbf{a}}{\|\hat{\mathbf{y}}\| \|\mathbf{S}^{-1}\mathbf{a}\|} \quad (7)$$

ここで, $\hat{\mathbf{y}}, \mathbf{a}$ は部分空間内のベクトルでありその次元 r は元の次元 d に比べ小さくなっている ($r < d$). そのため, 式 (6), (7) の計算オーダーは式 (8) に比べ小さく, 円錐への角度計算の計算オーダーは部分空間法と同等となる ($O(dr)$). さらに凸錐の場合 (式 (4)) と異なり, 対応できる角度 (式 (7) の値域) は $0 \leq \theta \leq \pi$ であり, 任意の角度を計算できることに注意されたい.

4. 実験

4.1 実験設定

[顔検出] MIT-CBCL Face Database [13] を用いて顔検出のための顔/非顔の識別を行う. 対象/非対象といった識別では, 対象画像にはある一定のパターンが存在するが, 非対象画像にはそのパターン以外の任意のものをとることが可能である. そのため, 非対象の画像は学習時には与えず, 対象画像のみを与えてそのパターン構造を学習する semi-supervised 学習が効果的であると考えられる. 学習には顔画像 (19 × 19) を 2429 枚, テストには顔画像 472 枚, 非顔画像 28121 枚を用いた (図 9). 画像特徴量には, 顔画像が位置合わせされていることから, 画像



図 9 MIT Database

を 2 × 2 に分割し各領域のエッジの 8 方向ヒストグラム (SIFT [12]-like な特徴ベクトル 32 次元) を用いた.

[人検出] MIT Pedestrian Database [14] を用いて人検出のための人/非人の識別を行う. 上述の顔検出の場合と同様に, ここでも semi-supervised 学習を行う. 学習には人画像 (128 × 64) を 400 枚, テストには人画像 524 枚, 非人画像 3000 枚を用いた (図 9(b)). 画像特徴量には, 人画像が位置合わせされていることから, 画像を 8 × 4 に分割し各領域のエッジの 8 方向ヒストグラム (SIFT [12]-like な特徴ベクトル 256 次元) を用いた.

4.2 実験結果

[顔検出] 提案手法の凸錐 (厳密な基底, PCA による基底) と円錐, および比較として部分空間法を適用したところ, その識別結果は図 10 となった. 図 10 により提案手法が部分空間法よりも識別率が高く, 錐がパターン分布をよりよく近似していることが分かる. さらに, 部分空間の次元 (主成分寄与率) と (誤) 識別率との関係も図 11 に示されている. 厳密な基底においては, 部分空間による近似を行っていないため, ここでの比較には含まれないことに注意されたい. 図 11 の横軸において, 主成分寄与率の大小が部分空間次元の大小を示しており, 縦軸は True Positive Rate が 0.9 のときの False Positive Rate を示している. 部分空間法では識別率は次元に左右されピークが存在する. しかし, 提案手法では次元が高い場合でも識別率は低下しない (次元が低い場合はサンプル分布の近似精度が悪いため部分空間法と同様に識別率は低くなる). これは提案手法が, 超球面上でのパターン分布を凸包や円などのクラスター状に近似することで, 部分空間内の冗長な次元の影響を軽減させているためだと考えられる. そのため, 部分空間法では問題であった次元の取り方は, 提案手法においてはある程度高い次元をとればよく, 識別に対してその次元の影響が少ないことがわかる.

[人検出] 顔検出の場合と同様に, 提案手法と部分空間法による比較を行い, その結果は図 12 に示されている. ここでも提案手法は部分空間法よりも識別率が高く, その中でも厳密な基底による凸錐の結果が最良であった. これは, 顔の場合よりも人の形状の方が多様なパターンを含み, かつその背景が屋外環境であることから特徴ベクトルが複雑な分布形状を成すことによると考えられる. つまり, 凸包 (PCA による基底) や円 (円錐) などの近似




図10 顔検出実験結果 (ROC)




図12 人検出実験結果 (ROC)




図11 主成分寄与率と誤識別率

手法ではその分布形状を捉えきれず識別率が低下していると推測される。

5. むすび

本論文では錘に基づく新たなパターン識別方法を提案し、特に凸錘と円錐の2つの手法を提案した。提案手法ではパターン分布は原点を頂点とする錘として表現され、部分空間法の拡張として位置づけられる。これにより、部分空間法と同様に錘の方向に沿ったスケール倍や加法などのパターンの広い変動を許容する一方で、原点周りの広がり、つまり超球面上での分布は凸包や円により近似されるため、分布の境界面に沿った厳密な識別も可能となる。そのため、錘による識別は従来のクラスターベースの識別と部分空間法との中間に位置する手法とも考えられる。また、凸錘の手法では基底の算出方法を2通り(厳密な基底とPCAによる近似基底)提案し、円錐では部分空間法と計算オーダーの変わらない高速な角度計算方法を提案した。顔検出や対象認識などの認識実験に提案手法を適用することにより、その有効性を確認した。

今後の展開としては、相互部分空間法などのような部分空間同士の比較手法を錘の場合へと発展させることなどが挙げられる。

謝 辞

非負最小二乗法についてアドバイスをいただいた伊藤藤聡氏(現東芝)に感謝します。なお本研究は科研費(19700187)の助成を受けたものである。

文 献

- [1] R. Herbrich, "Learning Kernel Classifiers: Theory and Algorithms", MIT Press, 2001
- [2] エルツキ・オヤ(著), 小川英光, 佐藤 誠(訳), パターン認識と部分空間法, 産業図書, 1986
- [3] 飯島泰蔵, パターン認識理論, 森北出版, 1989
- [4] 前田 賢一, 渡辺 貞一, "局所構造を導入したパターン・マッチング法", 信学論, J68-D, No.3, pp.345-352, 1985
- [5] 福井和広, 山口修, 鈴木薫, 前田賢一, 制約相互部分空間法を用いた環境変動にロバストな顔画像認識 - 照明変動の影響を抑える制約相互部分空間の学習-, 信学論 D-II Vol. J82-D-II, No.4, pp.613-620, 1999
- [6] A.S. Georghiadis, D.J. Kriegman, P.N. Belhumeur "Illumination cones for recognition under variable lighting: Faces", Proc. CVPR, pp.32-37, 1998
- [7] T. Kobayashi, N. Otsu, "A Three-Way Auto-Correlation Based Approach to Human Identification by Gait", Proc. IEEE Workshop on Visual Surveillance (VS), pp185-192, 2006
- [8] T. Nanri, N. Otsu, "Unsupervised Abnormality Detection in Video Surveillance", Proc. IAPR Conf. on Machine Vision Applications, pp.574-577, 2005
- [9] R. Bro, S.D Jong, "A fast non-negativity-constrained least squares algorithm", Journal of Chemometrics, vol.11, pp.393-401, 1997
- [10] B. Scholkopf, J. Platt, J. Shawe-Taylor, A. Smola, R. Williamson, "Estimating the support of a high-dimensional distribution," Neural Computation, 13, pp. 1443-1471, 2001.
- [11] D. D. Lee and H. S. Seung, "Learning the parts of objects by non-negative matrix factorization," Nature, 401, pp.788-791, 1999
- [12] D.G. Lowe, "Distinctive image features from scale invariant features," IJCV, 60, pp.91-110, 2004
- [13] CBCL Face Database, <http://www.ai.mit.edu/projects/cbcl>
- [14] M. Oren, C.P. Papageorgiou, P. Sinha, E. Osuna, T. Poggio, "Pedestrian Detection Using Wavelet Templates", Proc. CVPR, pp. 193-199, 1997