

# ドロネー三角形分割を用いた確率密度推定に基づく スコアレベル統合

楨原 靖<sup>1,a)</sup> モハマド アルタブ ホサイン<sup>2,b)</sup> 村松 大吾<sup>1,c)</sup> 岩間 晴之<sup>1,d)</sup> チュン タン ゴ<sup>1,e)</sup>  
八木 康史<sup>1,f)</sup>

**概要:** 本論文では、2クラス識別問題における複数スコアの統合手法を提案する。各クラスに対する複数スコアの確率密度関数 (PDF) に基づくスコアレベル統合手法は、推定された PDF が正しい限り、受信者操作特性を最適にすることが知られており有望な手法である。従来の格子点状の制御点を用いたノンパラメトリックな確率密度推定に基づく手法の代わりに、本研究では、浮動制御点 (FCP) を導入することでスケラビリティを改善し、全体のクラス事後確率を一般次元のドロネー三角形分割に基づく補間により表現する。本枠組みにおいて、最初に FCP の初期セットが与えられると、学習サンプルを用いて FCP 上のクラス事後確率をエネルギー最小化の枠組みによって推定する。更に、事後確率分布をより効率的に表現するために、各クラスの PDF のピークではなく、事後確率が変化する領域に重点的に FCP を再配置する。実験では、シミュレーションデータ及び生体認証の実データを用いて評価し、提案手法の有効性を確認した。

## 1. Introduction

複数の手がかりに基づく情報の統合は、単独の手がかりが使われる場合と比べてより良い性能を達成することが期待されていることから、多くのパターン認識の問題において重要な役割を果たす。実際に、情報の統合手法に関する数多くの手法がこれまでに開発されており、中でも、生体情報 (バイオメトリクス) による個人認証の分野で活発に研究が行われてきた [1], [10], [15], [20], [22]。複数の手がかりは、異なる種類のセンサ、モダリティ、特徴、識別器等、多様な情報源から取得し得る。加えて、統合のレベルについても様々なものが考えられ、センサレベル、特徴レベル、スコアレベル、決定レベル等が挙げられる [21]。これらの統合レベルの中で、スコアレベル統合は適用範囲の広さから最も幅広く研究がなされている。

また、スコアレベル統合手法は、主に、(1) 変換に基づく

手法 [9], [10], [22], (2) 識別に基づく手法 [8], (3) 確率密度推定に基づく手法 [1], [6], [13], [15] の三つに分類される。これらの中で、確率密度推定に基づく手法は、各クラスに対するスコアの確率密度関数 (PDF: probability density function) が正しく推定される限り、受信者操作特性を最適にすることが知られている [16]。

更に、確率密度推定に基づくスコアレベル統合手法は、(A) パラメトリックな手法とノンパラメトリックな手法、(B) 生成的な手法と識別的な手法、の二つの側面に関して分類される。パラメトリックな生成的な手法は、クラス毎の PDF としてパラメトリックなモデル (例えば、混合ガウス分布 (GMM: Gaussian mixture model) 等) を仮定して、学習サンプルからそのモデルのパラメータを推定する [15]。パラメトリックな識別的な手法は個々の PDF 推定を回避して、尤度比や事後確率の関数 (例えば、尤度比に対する線形ロジスティック回帰 (LLR: linear logistic regression)) [1] のパラメータを推定する。これらのパラメトリックな手法は仮定したモデルが実際の分布と良く一致している場合にはうまく行くが、そうでない場合には失敗する。

一方、ノンパラメトリックな手法は、スコア空間に対するヒストグラムや格子状制御点を用いて PDF 等の分布を表現する。これらの手法はどのような分布の種類に対しても適用可能である一方、ヒストグラムのビン数や制御点数がスコアの次元に対して指数関数的に増加するため、ス

<sup>1</sup> 大阪大学  
Osaka University, 8-1 Mihogaoka, Ibaraki, Osaka, 567-0047, Japan

<sup>2</sup> ラジシャヒ大学  
University of Rajshahi, Matihar, Rajshahi City, Rajshahi 620, Bangladesh

a) makihara@am.sanken.osaka-u.ac.jp

b) altab\_ru@yahoo.com

c) muramatsu@am.sanken.osaka-u.ac.jp

d) iwama@am.sanken.osaka-u.ac.jp

e) trung@am.sanken.osaka-u.ac.jp

f) yagi@am.sanken.osaka-u.ac.jp

ケーラビリティの点で問題がある。このスケラビリティの問題を避けるため、ノンパラメトリックの生成的な手法の中には、各スコアの次元の独立性を仮定してカーネル密度推定 (KDE: kernel density estimation) により得られる各次元の PDF の積により全体の PDF を表現するものもある [6]。しかし、このような手法は各スコアが独立ではない場合には有効ではない。ノンパラメトリックな識別的な手法では、通常複数次元のスコア空間に格子状制御点を配置し、制御点上の事後確率の関数を推定する (図 1(a)) [13]。しかし、この手法は依然としてスケラビリティの問題があるため、低次元のスコア空間 (典型的には高々 2 次元の空間) に対してしか適用できない。

そこで、本論文では、格子状制御点の代わりに浮動制御点 (FCP: floating control point) を用いたノンパラメトリックな識別的な確率密度に基づくスコアレベル統合手法を提案する (図 1(b))。浮動制御点上の事後確率が一旦推定されると、複数次元のスコア空間全体に対する事後確率分布がドロネー三角形分割 [3] により補間される。格子状制御点による手法 [13] に対する提案手法の長所は以下の三点に集約される。(1) 浮動制御点の数がスコアの次元に対して指数的に増えるのではなく、学習サンプル数に対して線形的に増加することから、スケラビリティの問題が改善される。(2) 空白領域に配置される冗長な格子状制御点 (図 1(a)) を削減できる。(3) 推定された事後確率分布に基づいて事後確率の変化が大きい領域に浮動制御点を再配置することで、より効率的に事後確率分布を表現することが可能となる。

## 2. 関連研究

**変換に基づく手法:** まず各スコアを正規化手法 (例えば、z 標準化 [2] や F 標準化 [18]) により変換し、それらを各種規則 (例えば、総和規則や総積規則 [10]) に基づいて、統合スコアを算出する。

**識別に基づく手法:** 複数スコアを特徴ベクトルとして扱い、各クラスを識別するための識別器 (例えば、ニューラルネットワーク [5] やサポートベクトルマシン (SVM: support vector machine) [23]) を構築する。通常、識別境界からの符号付き距離が統合スコアとして扱われることが多い。

**確率密度に基づく手法:** 1 節で述べたように、確率密度に基づく手法は二つの側面において分類される。生成的な手法では、最初に各クラスの PDF をパラメトリックな手法 (例えば、Naive ベイズ [17] や GMM [15]))、もしくはノンパラメトリックな手法 (例えば、KDE [6]) により推定し、PDF の関数 (例えば、クラス間の尤度比や事後確率) を計算し、それを統合スコアとして利用する。識別的な手法では、そのような PDF の関数を、パラメトリックな手法 [1] もしくはノンパラメトリックな手法 [13] により推定する。

**計算幾何におけるドロネー三角形分割:** ドロネー三角形分

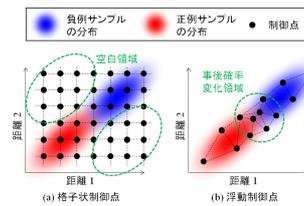


図 1 格子状制御点と浮動制御点  
**Fig. 1** Lattice-type and floating control points

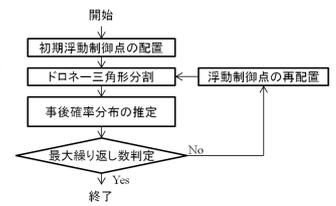


図 2 処理の流れ  
**Fig. 2** Flowchart

割はしばしば 3 次元物体や地理データの効率的な表現や描画のためのメッシュ生成に用いられる [4]。提案手法のドロネー三角形分割による事後確率分布の近似は、事後確率を 2 次元スコア空間上の高さで見なすことで、上記の計算幾何の問題と類似性がある。しかしながら、計算幾何の問題設定においては計測される 3 次元点がメッシュ生成のために与えられるのに対して、我々の問題設定においてはそのような 3 次元点、即ち、2 次元のスコアデータと事後確率の正解データのセットが与えられるわけではなく、代わりに 2 次元のスコアデータとクラスラベルの正解データが与えられることから、これらの二つの問題設定は全く異なることに注意されたい。

## 3. 確率密度に基づくスコアレベル統合

本節では、複数スコアによる 2 クラス識別問題 (例えば、生体情報に基づく本人認証における本人と他人、歩行者検出における歩行者と非歩行者) における確率密度に基づくスコアレベル統合の枠組みについて簡単に説明する。ここで、本論文においては、2 クラスをそれぞれ、正例 (本人認証の場合の本人や歩行者検出における歩行者) と負例 (他人や非歩行者) と呼ぶものとする。

まず、2 クラス識別問題を扱うシステムが  $M$  個の情報を利用し、 $M$  次元の特徴間距離のベクトル<sup>\*1</sup>  $\mathbf{t} = [t_0, \dots, t_{M-1}]^T \in \mathbb{R}^M$  が入力として与えられる。次に、正例・負例に対する距離ベクトル  $\mathbf{t}$  の PDF を各々  $p(\mathbf{t}|X = Pos)$ ,  $p(\mathbf{t}|X = Neg)$  として定義する。更に、統合距離のスカラー  $t_F$  を生成する距離ベクトル  $\mathbf{t}$  の関数  $t_F = f(\mathbf{t})$  を考える。ここで、統合距離  $T_F$  に対する閾値  $T$  が与えられると、負例の受入誤り率 (FAR: false acceptance rate)  $R_{FA}$  と正例の拒否誤り率 (FRR: false rejection rate)  $R_{FR}$  がそれぞれ以下のように定義される。

$$R_{FA}(T_F; f) = \int_{f(\mathbf{t}) \leq T_F} p(\mathbf{t}|X = Neg) d\mathbf{t} \quad (1)$$

$$R_{FR}(T_F; f) = 1 - \int_{f(\mathbf{t}) \leq T_F} p(\mathbf{t}|X = Pos) d\mathbf{t} \quad (2)$$

2 クラス識別問題における受信者操作特性 (ROC: receiver operating characteristic) 曲線は、統合距離に対する閾値を

<sup>\*1</sup> 類似度スコアの場合は符号を反転させることで距離ベクトルとする

変化させたときの FAR と FRR のトレードオフ曲線として与えられる。ここで、確率密度に基づくある種の関数が、ROC を最適化する距離統合関数  $f(t)$  として用いられることが、Neyman-Pearson 定理 [16] として知られている。その典型例が、所謂、尤度比検定で使われる負例の正例に対する尤度比であり、以下により定義される。

$$l(t) = \frac{p(t|X = Neg)}{p(t|X = Pos)} \quad (3)$$

他にも、以下で定義される負例の事後確率<sup>\*2</sup>を用いることもできる。

$$P(X = Neg|t) = \frac{p(t|X = Neg)P(X = Neg)}{\sum_{X \in \{Pos, Neg\}} p(t|X)P(X)}, \quad (4)$$

ここで、 $P(X = Neg)$  と  $P(X = Pos)$  はそれぞれ正例と負例の事前確率であり、事前情報がない場合には共に 0.5 に設定される。尤度比が有界ではない(定義域  $[0, \infty)$ ) のに対して、事後確率は有界(定義域  $[0, 1]$ ) であることから、本論文では、事後確率に基づく表現を採用するものとする。

まとめると、複数距離のベクトル  $t$  が与えられると、統合距離のスカラ  $t_F$  が負例の事後確率  $P(X = Neg|t)$  として与えられることとなる。よって、負例の事後確率分布  $P(X = Neg|t)$  を以下に正確に推定するかが重要な点となり、その詳細を以下の節にて説明する。

## 4. 提案手法

### 4.1 概要

提案手法における重要な処理は、浮動制御点の配置と事後確率分布の推定の二つである。1 節で述べたように、事後確率分布を効率的に推定するためには、浮動制御点を事後確率が変化する領域に配置する必要がある。一方、浮動制御点を事後確率が変化する領域に配置するためには、事後確率分布を予め求めておく必要がある。結局、浮動制御点の配置と事後確率分布の推定は所謂鶏と卵の問題であることから、図 2 の処理の流れに示すように繰り返し解法の枠組みを導入する。

まず、学習サンプルが与えられると、浮動制御点を初期配置する。次に、その浮動制御点に対して複数次元に対するドロネー三角形分割を適用し、浮動制御点上の事後確率をエネルギー最小化の枠組みによって推定する。最後に、事後確率が変化する領域に集中するように浮動制御点を再配置する。最後の三つの処理を最大繰り返し数に達するまで繰り返し行う。各処理の詳細については以降の節において述べる。

### 4.2 浮動制御点の初期配置

空白領域への配置を避けるため、浮動制御点の初期

<sup>\*2</sup> 本論文では距離に基づく表現を採用していることから、ここでは負例の事後確率を用いる。当然のことながら、類似度スコアに基づく表現を用いる場合には、正例の事後確率が用いられる。

シードを学習サンプルから選択する。まず、 $N$  個の学習サンプルが  $M$  次元距離ベクトルと正負ラベルの組  $\{t_l, y_l\} (l = 0, \dots, N-1)$  として与えられるものとする。ここで、 $y_l = 1$  が正ラベルを、 $y_l = -1$  が負ラベルを表すものとする。更に、 $l$  番目のサンプルに対する重み  $w_l$  を以下のように設定する。

$$w_l = \begin{cases} \frac{1}{2N_{Pos}} & (y_l = 1) \\ \frac{1}{2N_{Neg}} & (y_l = -1) \end{cases}, \quad (5)$$

ここで、 $N_{Pos}$  と  $N_{Neg}$  はそれぞれ正例と負例の学習サンプル数である。

このサンプル重み  $w_l$  は、 $l$  番目のサンプルが浮動制御点の初期シードとして選ばれる事前確率として用いられる。このようにして、事前確率に基づいて学習サンプルから  $N_V$  個の初期シードが選択される。ここで、式 (5) にあるように、サンプル重みが正例と負例のサンプル数を考慮して設定されていることから、結果としてほぼ同数の正例と負例のサンプルが初期シードとして選択される点に注意されたい。

次いで、この初期シードを  $k$  平均法の初期クラスタ中心として与える。 $k$  平均法は異なる初期クラスタ中心から複数回実行され、最終的に最もコンパクトな結果、即ち、学習サンプルと所属するクラスタ中心の距離の自乗和を最初にする結果を与えるクラスタ中心を浮動制御点として採用する。これにより、比較的均等に分布する初期シードを取得することができる。

### 4.3 ドロネー三角形分割による補間

浮動制御点上以外の事後確率をノンパラメトリックに補間するために、一般次元に対するドロネー三角形分割 [3] を導入する。まず、 $i$  番目の浮動制御点を  $M$  次元空間における距離ベクトル  $v_i^{FCP} \in \mathbb{R}^M$  とそれに対応する事後確率  $p_i^{FCP}$  ( $i = 0, \dots, N_V - 1$ ) の組で表現する。ここで、 $N_V$  は浮動制御点の数である。更に、浮動制御点上の事後確率を並べたものをベクトル  $\mathbf{p}^{FCP} = [p_0^{FCP}, \dots, p_{N_V-1}^{FCP}]^T$  として定義しておく。

この浮動制御点に対してドロネー三角形分割を適用し、 $N_S$  個の単体(例えば、2次元空間の場合は三角形で、3次元空間の場合には四面体となる。)を逐次加点法による生成する。ここで、各単体は  $(M+1)$  個の頂点を持ち、 $j$  番目の単体の  $k$  番目の頂点から浮動制御点のインデクスへの射影関数(もしくはルックアップテーブル)を  $I(j, k)$  として導入する。これにより、 $j$  番目の単体は浮動制御点のセット  $\{v_{I(j,k)}^{FCP}\} (k = 0, \dots, M)$  により構成されることとなる。

次に、入力  $M$  次元距離ベクトル  $t \in \mathbb{R}^M$  が与えられ、それに対応する事後確率  $\hat{p}(t; \mathbf{p}^{FCP})$  を最近傍の単体により補間することを考える。まず、 $j$  番目の単体に含まれ、かつ、入力ベクトル  $vect$  に最も近いベクトル  $\hat{t}_j(t)$  を以下

により求める.

$$\hat{\mathbf{t}}_j(\mathbf{t}) = \sum_k \alpha_{j,k}(\mathbf{t}) \mathbf{v}_{I(j,k)}^{FCP} \quad (6)$$

$$\{\alpha_{j,k}(\mathbf{t})\} = \arg \min_{\{\alpha_k\}} \left\| \sum_k \alpha_k \mathbf{v}_{I(j,k)}^{FCP} - \mathbf{t} \right\|^2 \quad (7)$$

$$\text{s.t.} \quad \sum_k \alpha_k = 1, \alpha_k \geq 0 \forall k. \quad (8)$$

次に, 入力ベクトル  $\mathbf{t}$  に最も近い単体  $J(\mathbf{t})$  を以下により選択する.

$$J(\mathbf{t}) = \arg \min_j \|\hat{\mathbf{t}}_j(\mathbf{t}) - \mathbf{t}\|. \quad (9)$$

最後に, 入力ベクトル  $\mathbf{t}$  に対する事後確率の補間  $\hat{p}(\mathbf{t}; \mathbf{p}^{FCP})$  が以下により与えられる.

$$\hat{p}(\mathbf{t}; \mathbf{p}^{FCP}) = \sum_k \alpha_k(\mathbf{t}) p_{I(J(\mathbf{t}),k)}^{FCP}, \quad (10)$$

ここで,  $\alpha_k(\mathbf{t})$  は,  $J(\mathbf{t})$  番目の単体の  $k$  番目の頂点に対する補間重みであり, 以下の線形方程式を解くことにより得られる.

$$\sum_k \alpha_k(\mathbf{t}) \mathbf{v}_{I(J(\mathbf{t}),k)}^{FCP} = \mathbf{t} \quad (11)$$

$$\sum_k \alpha_k(\mathbf{t}) = 1 \quad (12)$$

ここで, 事後確率の補間  $\hat{p}(\mathbf{t}; \mathbf{p}^{FCP})$  は, 入力ベクトル  $\mathbf{t}$  がいずれかの単体に含まれている場合には内挿となり, 最近傍のベクトル  $\hat{\mathbf{t}}_j(\mathbf{t})$  は入力ベクトル  $\mathbf{t}$  と一致し, そうでない場合には, 外挿となる点に注意されたい.

#### 4.4 エネルギー最小化による事後確率分布の推定

浮動制御点上の事後確率  $\mathbf{p}^{FCP}$  を推定する際には, (1) 学習データに対する当てはまり具合と, (2) 分布の滑らかさの二点を考慮する必要がある. そこで, データ項  $S_{data}(\mathbf{p}^{FCP})$  と平滑化項  $S_{smooth}(\mathbf{p}^{FCP})$  からなる次のようなエネルギー関数を導入して, それを最小化するような事後確率を求めるものとする.

$$S(\mathbf{p}^{FCP}) = S_{data}(\mathbf{p}^{FCP}) + \lambda S_{smooth}(\mathbf{p}^{FCP}). \quad (13)$$

ここで,  $\lambda$  は平滑化項の係数である. 各項について, 以下で詳細を述べる.

データ項は, 入力ベクトル  $\mathbf{t}_i$  に対する事後確率の補間  $\hat{p}(\mathbf{t}_i; \mathbf{p}^{FCP})$  と学習サンプルのラベル  $y_i$  を一致させるためのものであり, 以下で定義される.

$$S_{data}(\mathbf{p}^{FCP}) = \sum_{l=0}^{N-1} w_l (\hat{p}(\mathbf{t}_i; \mathbf{p}^{FCP}) - \delta_{y_l, -1})^2 \quad (14)$$

ここで,  $\delta$  はクロネッカーのデルタであり,  $\delta_{y_l, -1}$  は, 負例に対しては 1, 正例に対しては 0 となることに注意されたい. 言い換えると, 負例と正例は, 負例の事後確率  $\hat{p}(\mathbf{t}_i; \mathbf{p}^{FCP})$  をそれぞれ 1 と 0 に引きつけることとなる. 加えて, 式

(10)にあるように, 事後確率の補間  $\hat{p}(\mathbf{t}_i; \mathbf{p}^{FCP})$  が, 浮動制御点上の事後確率  $\mathbf{p}^{FCP}$  に関して線形であるため, データ項は事後確率  $\mathbf{p}^{FCP}$  に関して 2 次形式となる.

平滑化項  $S_{smooth}(\mathbf{p}^{FCP})$  は, 過学習を抑制するために事後確率分布を局所的に平面に近づけるものである. 具体的には, 平滑化項各浮動制御点の近傍での超平面当てはめ誤差の自乗和として定義される.  $i$  番目の頂点に  $N_i^E$  個の頂点が接続されているとして, その  $k$  番目の頂点インデックスを  $E(i, k)$  ( $k = 0, \dots, N_i^E - 1$ ) として定義する. 次に,  $M$  次元の距離  $\mathbf{t}$  と事後確率  $p$  からなる  $(M+1)$  次元空間における超平面を考え, 事後確率  $p$  に関する標準形として以下のように表現する.

$$p = \mathbf{g}^T \mathbf{t} + p_0 = \tilde{\mathbf{t}}^T \boldsymbol{\theta} \quad (15)$$

ここで,  $\mathbf{g} \in \mathbb{R}^M$  と  $p_0 \in \mathbb{R}$  はそれぞれ超平面の勾配と切片であり,  $\boldsymbol{\theta} \in \mathbb{R}^{M+1}$  はそれらの超平面パラメタを組み合わせたパラメタベクトル  $[\mathbf{g}^T, p_0]^T$ ,  $\tilde{\mathbf{t}}$  は拡張ベクトル  $[\mathbf{t}^T, 1]^T$  である. 隣接頂点  $\mathbf{v}_{E(i,k)}^{FCP}$  とその頂点上での事後確率  $p_{E(i,k)}^{FCP}$  を上記の式 (15) に代入すると, 以下が得られる.

$$V_{E_i}^{FCP} \boldsymbol{\theta} = \mathbf{p}_{E_i}^{FCP} \quad (16)$$

$$V_{E_i}^{FCP} = \begin{bmatrix} (\tilde{\mathbf{v}}_{E(i,0)}^{FCP})^T \\ \vdots \\ (\tilde{\mathbf{v}}_{E(i, N_i^E-1)}^{FCP})^T \end{bmatrix}, \quad \mathbf{p}_{E_i}^{FCP} = \begin{bmatrix} p_{E(i,0)}^{FCP} \\ \vdots \\ p_{E(i, N_i^E-1)}^{FCP} \end{bmatrix} \quad (17)$$

ここで,  $\tilde{\mathbf{v}}$  も拡張ベクトル  $[\mathbf{v}^T, 1]^T$  を表す. これより, 隣接頂点への当てはめを行った超平面のパラメタ  $\boldsymbol{\theta}$  は, 以下の最小自乗法により算出される.

$$\hat{\boldsymbol{\theta}} = V_{E_i}^{FCP+} \mathbf{p}_{E_i}^{FCP} \quad (18)$$

ここで,  $V_{E_i}^{FCP+}$  は  $V_{E_i}^{FCP}$  の擬似逆行列である.  $i$  番目の頂点  $\mathbf{v}_i^{FCP}$ , その頂点上での事後確率  $p_i^{FCP}$ , 推定されたパラメタ  $\hat{\boldsymbol{\theta}}$  を超平面の方程式 (Eq. (15)) に代入すると, 当てはめ誤差  $\Delta_i$  が以下として得られる.

$$\Delta_i = (\tilde{\mathbf{v}}_i^{FCP})^T V_{E_i}^{FCP+} \mathbf{p}_{E_i}^{FCP} - p_i^{FCP} \quad (19)$$

これより, 平滑化項は当てはめ誤差の自乗和として以下で定義される.

$$S_{smooth}(\mathbf{p}^{FCP}) = \frac{1}{N_V} \sum_{i=0}^{N_V-1} \Delta_i^2 \quad (20)$$

ここで,  $\Delta_i$  が事後確率  $\mathbf{p}^{FCP}$  に関して線形であることから, 平滑化項は  $\mathbf{p}^{FCP}$  に関する 2 次形式となることに注意されたい.

結局, 式 (13) のエネルギー関数は事後確率  $\mathbf{p}^{FCP}$  に関して 2 次形式であることが分かり, 大域最適解  $\mathbf{p}^{FCP*}$  が線形解法により容易に求まることが分かる.

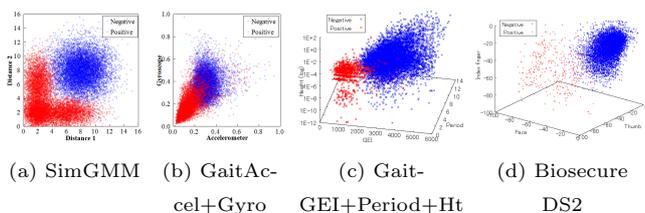


図 3 学習サンプルの分布

Fig. 3 Distribution of training samples

表 1 実データに対する学習及びテストサンプル数

Table 1 Numbers of training and test samples for real data

データセット	学習セット		テストセット	
	正例	負例	正例	負例
GaitAccel+Gyro	7,252	10,000	7,629	2,612,826
GaitFreq0+1+2	1,881	10,000	1,880	300,000
GaitGEI+GFI	1,881	10,000	1,880	3,532,520
GaitGEI+Period+Ht	968	10,000	968	300,000
Biosecure DS2	406	10,000	1,238	250,790

#### 4.5 浮動制御点の再配置

現在の浮動制御点上での事後確率  $p^{FCP}$  が一旦求まると、事後確率の変化領域にフォーカスするように新しい浮動制御点を再配置する。事後確率の変化領域においては事後確率勾配の大きさが増加することから、事後確率分布の勾配に再度着目する。事後確率  $p^{FCP}$  が分かっているとすると、 $i$  番目の頂点における超平面パラメタ  $\theta_i^{FCP} = [g_i^{FCPT}, p_{0,i}^{FCPT}]^T$  が式 (18) により得られる。次いで、式 (10) の事後確率の補間と同様に、 $l$  番目の学習サンプルに対する勾配  $g_l$  が以下のように補間される。

$$g_l = \sum_k \alpha_k(t_l) g_{I(J(t_l), k)}^{FCP} \quad (21)$$

更に、学習サンプル重みを補間された勾配の大きさによって以下のように更新する。

$$w'_l = \frac{\|g_l\| w_l}{\sum_{m=1}^{N-1} \|g_m\| w_m} \quad (22)$$

最終的に、更新された学習サンプル重みは初期シードの選択に用いられ、更にそれが 4.2 節で説明したように  $k$  平均法において同様に用いられる。ここで、更新後の学習サンプル重み  $\{w'_l\}$  が浮動制御点の再配置に用いられるのに対して、事後確率分布を推定する際の式 (14) のデータ項においては、依然として元のサンプル重み  $\{w_l\}$  が用いられることに注意されたい。

## 5. 実験

### 5.1 実験設定

**シミュレーションデータ:** シミュレーションによる正例と負例をそれぞれ三つと一つのコンポーネント数からなる 2 次元 GMM より図 3(a) のようにサンプリングした (以降、SimGMM と呼ぶ)。この分布において、正例の一部は 2 次元の内のいずれか一方に関して距離が大きくなっているが、

これは、何らかの望ましくない状況 (例えば、指紋認証における低品質なセンサー等) により、2 クラス識別問題における複数の手がかりの内の一つが劣化したという状況を想定している。学習・テストセットはそれぞれ 10,000 ずつの正例・負例から構成される。

**実データ:** 生体認証の実データとして、次に挙げる五セット用意し、実験に用いた。(1) GaitAccel+Gyro: 装着型センサーを用いた歩容による本人認証を想定した、加速度センサーとジャイロセンサーによる距離、(2) GaitFreq0+1+2: 歩容認証における周波数領域特徴 [14] の 0, 1, 2 倍周波数成分から計算される距離、(3) GaitGEI+GFI: 平均シルエット [12] (もしくは、GEI: gait energy image [7] と呼ばれる) と GFI (gait flow image) [11] による距離、(4) GaitGEI+Period+Ht: GEI, 歩行周期, 身長による距離、(5) Biosecure DS2: 顔, 親指, 人差し指, 中指による距離 [19]。実データの各データセットは、センサー、特徴、モダリティーといった複数の情報源に基づく複数の距離を含んでいる。データセット GaitAccel+Sensor, GaitGEI+Period+Ht, 及び Biosecure DS2 における学習サンプルの例を図 3(b), (c), 及び (d)\*3 に示す。学習・テストセットにおけるサンプル数は表 1 の通りである。

**パラメタ設定:** 浮動制御点数  $N_V$  と平滑化係数  $\lambda$  はそれぞれ 200 と 1.0 に設定した。全体の枠組みの繰り返し回数 (図 2 に示すループ) と初期シード選択の繰り返し回数はそれぞれ 1 回と 10 回に設定した。

**比較手法:** 変換に基づく手法と識別に基づく手法の比較手法として、総和規則 (Sum と呼ぶ)、線形カーネルと RBF カーネルによる SVM\*4 (それぞれ、SVM (Linear), SVM (RBF) と呼ぶ) をそれぞれ用いた。確率密度に基づく手法としては、パラメトリックな生成的手法として GMM [15]\*5、パラメトリックな識別的手法として線形ロジスティック回帰 [1] (LLR と呼ぶ)、ノンパラメトリックな生成的手法として KDE [6] を用いた。また、提案手法の浮動制御点の再配置無しと有りの場合のものをそれぞれ FCP と FCP+ と表記する。

**前処理としてのスコア正規化:** 全ての比較手法において、学習サンプルの平均と標準偏差を距離の次元毎に独立に計算した。そして、平均が 0 と標準偏差が 1 になるように、 $z$  標準化を適用した。

### 5.2 事後確率分布

本節では、推定された統合距離 (もしくは、確率密度手法における事後確率) の分布をデータセット SimGMM に対して確認した (図 4)。本データセットは GMM よりサン

\*3 この図では可視化の都合上、中指に対する距離が省略されているが、実験では顔, 親指, 人差し指と共に中指も用いられている。

\*4 ハイパーパラメタは交叉検定により自動的に決定した。

\*5 コンポーネント数については、最小記述長の基準により自動的に選択した。

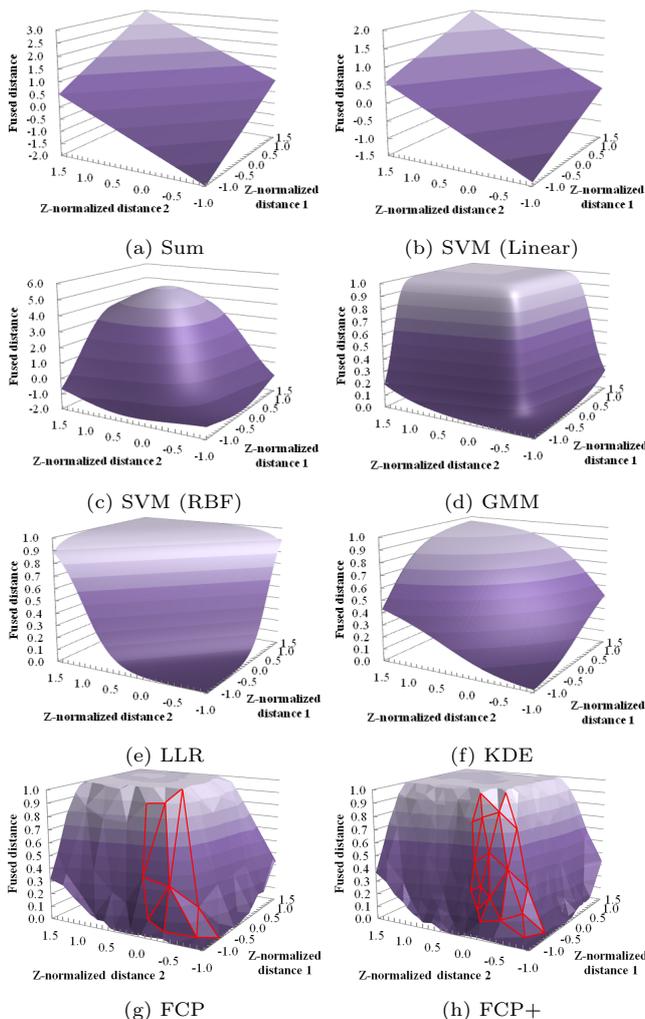


図 4 SimGMM データセットに対する統合距離の推定分布. (g) と (h) においては、ドロネー三角形の一部を赤色の三角形で示している.

Fig. 4 Estimated distributions of fused distance for SimGMM dataset. In (g) and (h), some of the Delaunay triangles are depicted by red triangles

プルが抽出されているので、GMM により推定された分布 (図 4(d)) がある種の真値として見なせる. 当然のことながら、Sum (図 4(a)), SVM (Linear)(図 4(b)), LLR (図 4(e)) といった線形な手法では、GMM によって得られる分布とは遠くかけ離れた分布になってしまう. これらの線形な手法とは異なり、SVM (RBF) (図 4(c)) や KDE (図 4(f)) は非線形な分布を表現することができるが、それでも GMM による分布とは大きく異なる. 一方、提案手法の FCP (図 4(g)) と FCP+ (図 4(h)) は GMM による分布にある程度近い分布を表現できている. 更に、事後確率の変化領域において、FCP+に対するドロネー三角形が、FCP に対するものよりも、より細くなっていることが分かる. これは、浮動制御点の再配置による効果である.

### 5.3 性能評価

データセット SimGMM, GaitAccel+Gyro, GaitGEI+

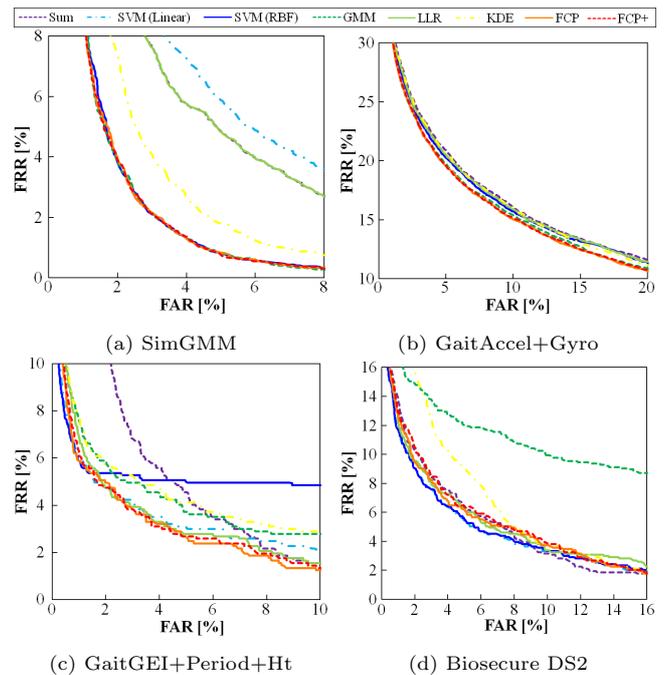


図 5 受信者操作特性曲線

Fig. 5 ROC curves

Period+Ht, Biosecure DS2 に対するスコアレベル統合の性能を図 5 に示すように ROC 曲線により評価する. 比較手法の中で、SVM (RBF) が SimGMM や Biosecure DS2 に対して、GMM が SimGMM や GaitAccel+Gyro に対して比較的良い性能を発揮している. しかしながら、データセットのいくつかに対しては、非常に悪い性能となっているものもある (例えば、GaitGEI+Period+Ht に対する SVM (RBF) や GaitGEI+Period+Ht や BiosecureDS2 に対する GMM 等.). 一方、提案手法の FCP と FCP+は殆どのデータセットに対して最高の性能を発揮している. BiosecureDS2 に対しては、SVM (RBF) と比較して性能が劣るものの、GMM よりは依然として良い結果が得られている.

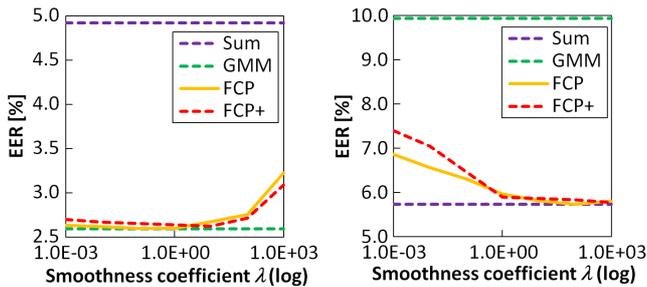
ROC 曲線に加えて、FAR と FRR の等価誤り率 (EER: equal error rate) を全データセットに対して評価したものを表 2 にまとめた. GMM は SimGMM に対しては最高性能を達成しているものの、Biosecure DS2 に対しては性能が低く、他の比較手法と比較してもかなり悪化していることが分かる. これは、GMM がコンポーネント間の平滑化を保証しておらず、あくまでもコンポーネント内の滑らかさのみを考慮しているためであり、それ故、過学習により、局所的には滑らかであっても大域的に粗い分布となることがある.

他方、提案手法は浮動制御点上の事後確率に対する平滑化を考慮しているため、過学習の問題をある程度緩和することができる. 結果として、提案手法 FCP と FCP+は殆どのデータセットに対して最高もしくは二番目の性能を達成している.

表 2 等価誤り率 (%). 太字, イタリック, アンダーラインの値は, 各々, 各データに対する最高, 二番, 最低の性能を表す.

Table 2 EERs (%). Bold, italic, and underlined digits denote the best, the second best, and the worst performance, respectively.

データセット \ 手法	Sum	SVM (Linear)	SVM (RBF)	GMM	LLR	KDE	FCP	FCP+
SimGMM	4.92	<u>5.42</u>	2.63	<b>2.59</b>	4.92	3.42	<b>2.59</b>	2.63
GaitAccel+Gyro	13.86	<u>25.71</u>	13.87	13.59	13.78	13.74	<b>13.23</b>	<i>13.29</i>
GaitFreq0+1+2	<u>5.69</u>	4.29	5.26	4.37	4.36	5.48	<b>4.15</b>	<i>4.19</i>
GaitGEI+GFI	<u>6.65</u>	4.06	4.84	<i>3.88</i>	3.99	6.54	3.89	<b>3.85</b>
GaitGEI+Period+Ht	4.78	3.60	<u>4.99</u>	<u>4.22</u>	3.62	4.30	<b>3.42</b>	<i>3.52</i>
Biosecure DS2	5.74	<b>5.22</b>	<i>5.25</i>	<u>9.94</u>	5.72	6.70	5.83	5.90



(a) SimGMM (b) Biosecure DS2  
図 6 平滑化係数の影響

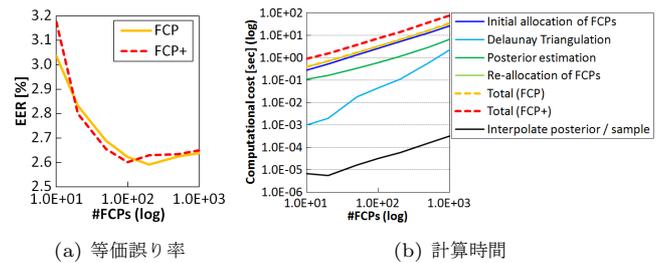
Fig. 6 Effect of the smoothness coefficient

## 6. 考察

### 6.1 平滑化係数の影響

提案手法は全体としては良い性能となっているものの, Biosecure DS2 については若干性能が悪化している (表 2 参照). この性能低下の主要な要因の一つとして, 確率密度に基づく手法ではよくある, 所謂, 汎化誤差が挙げられる. 実際に, Biosecure DS2 の学習サンプルの正例数は他のデータセットと比較すると非常に少ないことが分かる (表 1).

提案手法においてそのような汎化誤差の問題をうまく扱うためには, 平滑化係数  $\lambda$  が重要な役割を果たす. データセット SimGMM と Biosecure DS2 の性能に対する平滑化係数  $\lambda$  の影響を図 6 に示す. 一般的には, 大きな平滑化係数である程, 事後確率分布を平面的な形に制約し, 小さな平滑化係数の場合にはそのような制約が弱くなる. 十分な学習サンプル数 (例えば SimGMM) が与えられる場合には, 汎化誤差は小さいことから, 大きな平滑化係数を設定すると性能が悪化する傾向にある (図 6(a)). 一方, 比較的少数の学習サンプルが提供される場合 (例えば Biosecure DS2) には, 大きな平滑化係数によって性能が改善する (図 6(b)). よって, 交叉検定やブートストラップ法等のパラメータ選択手法を用いることで, 適切な平滑化係数を自動的に選択することが今後の重要な課題と言える.



(a) 等価誤り率 (b) 計算時間

図 7 浮動制御点数の影響 (SimGMM データセット)

Fig. 7 Effect of the number of FCPs (SimGMM dataset)

### 6.2 浮動制御点数による計算量と性能への影響

本節では, 提案手法の計算量について考察する. 比較的大きな計算量を必要とする主要処理は, 浮動制御点の初期配置や再配置, エネルギー最小化に基づく事後確率分布の推定であり, これらの計算量は主に学習サンプル数  $N$  と浮動制御点数  $N_V$  に依存する. 浮動制御点の配置における  $k$  平均法の計算量のオーダーが  $O(NN_V)$  であるのに対して, 事後確率推定の計算量のオーダーは  $O(N_V^3)$  となるが, これは,  $\mathbf{p}^{FCP} \in \mathbb{R}^{N_V}$  に対する線形解を求める際に必要な計算量である. しかしながら, 浮動制御点の数  $N_V$  は, 通常, 学習サンプル数  $N$  よりもかなり少ないことから, 実際の計算量としては扱えるものである (図 7(b) 参照).

更に, 浮動制御点の数  $N_V$  は平滑化係数  $\lambda$  と共に重要なハイパーパラメータであることから, 性能と計算量のトレードオフ\*6に関する調査を行った (図 7 参照). 性能に関しては, 数百程度の浮動制御点で十分な等価誤り率を達成していることが分かる. また, 数百程度の浮動制御点に対しては, 計算時間が 10 秒程度と, 学習段階においては十分に受け入れられる計算量となっている. また, 入力サンプル毎の事後確率の補間計算については, 数百程度の浮動制御点に対して 0.1 ms 以下となっており, こちらについても十分に受け入れ可能な計算量であることが分かる.

## 7. まとめ

本論文では, 複数の情報源による 2 クラス識別問題における確率密度に基づくスコアレベル統合手法を提案した.

\*6 実験に用いた計算機のスペックは, Intel<sup>R</sup> Core<sup>TM</sup> i5 CPU 2.4 GHz, メモリ 4GB である.

従来のノンパラメトリックな確率密度に基づく手法で用いられていた格子状制御点の代わりに、浮動制御点を導入することで、スケーラビリティを改善し、空白領域を避けた効率的な配置を行った。全体の事後確率分布は多次元のドロネー三角形分割による補間で表現した。浮動制御点上の事後確率はエネルギー最小化の枠組みに基づいて推定され、より効率的な表現のために、浮動制御点を事後確率の変化領域に集中するように再配置を行った。実験では、シミュレーションデータ、装着型センサや映像に基づく複数情報源による歩容認証の実データを用い、提案手法の有効性を確認した。

今後の課題として、データセット Biosecure DS2 に対する実験で明らかになったように、汎化誤差を抑えるための平滑化係数の自動選択が挙げられる。また、顔検出や歩行者検出といった、コンピュータビジョンの分野でより一般である 2 クラス識別問題に対して提案手法を適用することも今後の課題と言える。

**謝辞** 本研究の一部は、JSPS 基盤研究 (S)21220003、文部科学省の科学技術戦略推進費による「安全・安心な社会のための犯罪・テロ対策技術等を実用化するプログラム」、科学技術振興機構 (JST) 戦略的創造研究推進事業 (CREST) の助成を受けたものである。

## 参考文献

- [1] Alonso-Fernandez, F., Fierrez, J., Ramos, D. and Ortega-Garcia, J.: Dealing with sensor interoperability in multi-biometrics: the UPM experience at the Biosecure Multimodal Evaluation 2007, *Proc. of SPIE 6994, Biometric Technologies for Human Identification IV*, Orlando, FL, USA (2008).
- [2] Auckenthaler, R., Carey, M. and Lloyd-Thomas, H.: Score Normalization for Text-Independent Speaker Verification Systems, *Digital Signal Processing*, Vol. 10, No. 1-3, pp. 42-54 (2000).
- [3] Berg, M., Cheong, O., Kreveld, M. and M.Overmars.: *Computational Geometry: Algorithms and Applications*, Springer-Verlag (2008).
- [4] Boissonnat, J.-D.: Representing 2d And 3d Shapes With The Delaunay Triangulation, *Proc of the 7th Int. Conf. on Pattern Recognition*, pp. 745-748 (1984).
- [5] Chen, C. and Chu, C.: Fusion of face and iris features for multimodal biometrics, *Proc. of Int. Conf. on Biometrics 2006*, Hong Kong, China, pp. 571-580 (2006).
- [6] Dass, S. C., N, K. and Jain, A. K.: A principled approach to score level fusion in multimodal biometric systems, *Proc. of the 5th Int. Conf. on Audio- and Video-Based Biometric Person Authentication*, Ny, USA, pp. 1049-1058 (2005).
- [7] Han, J. and Bhanu, B.: Individual Recognition Using Gait Energy Image, *Trans. on Pattern Analysis and Machine Intelligence*, Vol. 28, No. 2, pp. 316- 322 (2006).
- [8] He, M., Horng, S. J., Fan, P., Run, R. S., Chen, R. J., Lai, J. L., Khan, M. and Sentosa, K. O.: Performance evaluation of score level fusion in multimodal biometric systems, *Pattern Recognition*, Vol. 43, No. 5, pp. 1789-1800 (2010).
- [9] Jain, A. K., Nandakumar, K. and Ross, A.: Score Normalization in Multimodal Biometric Systems, *Pattern Recognition*, Vol. 38, No. 12, pp. 2117-2127 (December 2005).
- [10] Kittler, J., Hatef, M., Duin, R. P. W. and Matas, J.: On Combining Classifiers, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 20, No. 3, pp. 226-239 (1998).
- [11] Lam, T. H. W., Cheung, K. H. and Liu, J. N. K.: Gait flow image: A silhouette-based gait representation for human identification, *Pattern Recognition*, Vol. 44, pp. 973-987 (2011).
- [12] Liu, Z. and Sarkar, S.: Simplest Representation Yet for Gait Recognition: Averaged Silhouette, *Proc. of the 17th Int. Conf. on Pattern Recognition*, Vol. 1, pp. 211-214 (2004).
- [13] Makihara, Y., Hossain, M., Muramatsu, D. and Yagi, Y.: Score-level Fusion based on the Direct Estimation of the Bayes Error Gradient Distribution, *Proc. of the International Joint Conference on Biometrics (IJCB2011)*, Washington D.C., pp. 1-8 (2011).
- [14] Makihara, Y., Sagawa, R., Mukaigawa, Y., Echigo, T. and Yagi, Y.: Gait Recognition Using a View Transformation Model in the Frequency Domain, *Proc. of the 9th European Conf. on Computer Vision*, Graz, Austria, pp. 151-163 (2006).
- [15] Nandakumar, K., Chen, Y., Dass, S. C. and Jain, A. K.: Likelihood ratio-based biometric score fusion, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 30, No. 2, pp. 342-347 (2008).
- [16] Neyman, J. and Pearson, E.: On the Problem of the Most Efficient Tests of Statistical Hypotheses, *Philosophical Transactions of the Royal Society of London*, Vol. 231, pp. 289-337 (1933).
- [17] Poh, N. and Bengio, S.: EER of fixed and trainable fusion classifiers: A theoretical study with application to biometric authentication tasks, *Multiple Classifier Systems*, pp. 74-85 (2005).
- [18] Poh, N. and Bengio, S.: F-ratio Client-Dependent Normalisation on Biometric Authentication Tasks, *IEEE Int'l Conf. Acoustics, Speech, and Signal Processing (ICASSP)*, Philadelphia, pp. 721-724 (2005).
- [19] Poh, N., Bourlai, T. and Kittler, J.: A multimodal biometric test bed for quality-dependent, cost-sensitive and clientspecific score-level fusion algorithms, *Pattern Recognition*, Vol. 43, No. 3, pp. 1094-1105 (2010).
- [20] Poh, N. and Kittler, J.: A Unified Framework for Biometric Expert Fusion Incorporating Quality Measures, *IEEE Trans. on Pattern Analysis and Machine Intelligence* (accepted).
- [21] Ross, A. A., Jain, A. K. and Zhang, D.: *Handbook of Multibiometrics*, International Series on Biometrics, Vol. 6, Springer (2006).
- [22] Snelick, R., Uludag, U., Mink, A., Indovina, M. and Jain, A. K.: Large Scale Evaluation of Multimodal Biometric Authentication Using State-of-the-Art Systems, *IEEE Trans. on Pattern Analysis and Machine Recognition*, Vol. 27, No. 3, pp. 450-455 (March 2005).
- [23] Wang, F. and Han, J.: Multimodal biometric authentication based on score level fusion using support vector machine, *Opto-Electronics Review*, Vol. 17, No. 1, pp. 59-64 (2009).