

# ROC 曲線最適化のための信頼度付き照合度に対する適応的閾値制御

槇原 靖<sup>†</sup> モハマド アルタブ ホサイン<sup>†</sup> 八木 康史<sup>†</sup>

<sup>†</sup> 大阪大学

〒 567-0047 大阪府茨木市美穂ヶ丘 8-1

E-mail: †{makihara,hossain,yagi}@am.sanken.osaka-u.ac.jp

あらまし ROC 曲線は、1 対 1 認証や特定物体検出等の 2 クラス識別問題において、照合度に対する受け入れ閾値を変化させたときの偽陽性率と偽陰性率のトレードオフを示す曲線である。本論文では、状況変化の度合いに関連した信頼度付きの照合度に対して、受け入れ (検出) 閾値を信頼度に応じて適応的に制御する手法を提案する。ROC 曲線最適化の観点に基づくと、照合度と信頼度の 2 次元空間における閾値曲線群が、全体の受け入れ率に対する偽陽性と偽陰性率の総誤り率の比として定義される誤り勾配の等値線と一致することを示す。シミュレーションデータ及び実データを用いた実験により、特に偽陽性率と偽陰性率のいずれか一方の許容誤り率が小さい条件において、提案手法が有効であることを確認した。

キーワード ROC 曲線, 受け入れ閾値, 信頼度, 誤り勾配, 偽陽性率, 偽陰性率

## Adaptive Acceptance Threshold Control using Matching Distances with Confidence Values for ROC Curve Optimization

Yasushi MAKIHARA<sup>†</sup>, Md. ALTAB HOSSAIN<sup>†</sup>, and Yasushi YAGI<sup>†</sup>

<sup>†</sup> Osaka university

8-1 Mihogaoka, Ibaraki, Osaka, 567-0047

E-mail: †{makihara,hossain,yagi}@am.sanken.osaka-u.ac.jp

**Abstract** In two-class classification problems such as one-to-one verification and object detection, the performance is usually evaluated by a so-called Receiver Operating Characteristics (ROC) curve expressing a tradeoff between False Rejection Rate (FRR) and False Acceptance Rate (FAR). On the other hand, it is also well known that the performance is significantly affected by the situation differences between enrollment and test phases. This paper describes a method to adaptively control an acceptance threshold with confidence values derived from situation differences so as to optimize the ROC curve. We show that the optimal evolution of the adaptive threshold in the domain of the distance and confidence value is equivalent to a constant evolution in the domain of the error gradient defined as a ratio of a total error rate to a total acceptance rate. An experiment with simulation and real data demonstrates the effectiveness of the proposed method, particularly under a lower FAR or FRR tolerance condition.

**Key words** ROC curve, Acceptance threshold, Confidence values, Error gradient, False acceptance rate, False rejection rate

### 1. はじめに

2 クラス識別問題は、特定物体検出や 1 対 1 認証等のパターン認識において広く扱われる基本的な問題である。例えば、顔検出においては顔・非顔の 2 クラスの識別に基づく手法が近年盛んに研究されており [1], 人物検出においても同様に人物・非人物の 2 クラス識別による手法が主流となっている [2]。また、バイオメトリクスによるアクセスコントロールシステムでは、ID 情報に基づい

て登録時と入力時の生体情報の間の 1 対 1 認証を行うが、その際には本人・他人の 2 クラス識別を行っていることになる。いずれの場合においても、顔らしさや人らしさのスコア、また登録時と入力時の特徴間距離、といったような何らかの評価尺度が計算され、その評価尺度と予め定めた受け入れ閾値との大小によって、顔・人物・本人としての受け入れる (正例と見なす) または拒否する (負例と見なす) かを判断することとなる。

これらの 2 クラス識別問題における性能は、通常、二

つの誤り率によって評価される．一つは、入力が負例であるにもかかわらず正例として受け入れてしまう偽陽性率 (第一種過誤, False Acceptance Rate: FAR, とも言う) であり, もう一つは, 反対に, 入力为正例であるにもかかわらず負例として拒否してしまう偽陰性率 (第二種過誤, False Rejection Rate: FRR) である．例えば, アクセスコントロールシステムにおいては, 他人受け入れ誤り率が偽陰性率に当たり, 本人拒否誤り率が偽陽性率に当たる．偽陽性率と偽陰性率は当然のことながら受け入れ閾値に依存しており, 受け入れ閾値を厳しくすると偽陽性率が下がる一方で偽陰性率が上がり, 反対に受け入れ閾値を緩めると偽陽性率が上がり偽陰性率が下がる．このような擬陽性率と偽陰性率のトレードオフの関係を示したものが, 受信者操作特性 (ROC) 曲線 [3] であり, 2 クラス問題の性能評価に標準的に用いられている．

一方, 識別性能は登録時と入力時の状況変化によって大きく影響されることが知られている．例えば, 人の歩き方の個性に基づく個人認証技術として近年注目を集めている歩容認証においては, 登録時と入力時の方向の違い [4], 歩行速度の違い [5], 服装変化 [6] 等, 様々な状況変化が考えられる．同じ状況であれば識別可能であった正例と負例に対しても, これらの状況変化が大きくなればなる程, 一般的には識別が困難になってくる．また, 音声認識における SN 比のように, 観測の品質によって認識率が変化することも考えられる．

これらは一般に信頼度 (Quality measure) と呼ばれ, 生体認証における認証性能の見積もりにしばしば用いられている [7] [8] [9] [10]．例えば, Hossain ら [11] は, 服装変化を伴う歩容認証において, 体の部位毎の服装の違いに基づいて定義される信頼度と認証性能の間に強い関連性があることを報告している．また, 信頼度に基づいて, 複数サンプルや複数の特徴によるスコアを効果的に統合する手法 [12] [13] や正規化する手法 [14], 異なるモードの生体認証のスコアを統合する手法 [15] [16] が提案されている．

更に, Kryszczuk らは [17] は, evidence space と呼ばれるスコアと信頼度からなる空間において最適な識別境界を求めることで識別性能を改善する手法を提案している．しかし, 手法 [17] においては一つの識別境界が与えられるのみであることから, ROC 曲線全体ではなく ROC 曲線上の一点で表現される一組の偽陰性率と偽陽性率が与えられることになる．厳密に言うと, 識別境界からの符号付き距離等のある種の尺度に基づいて識別境界を移動させることで ROC 曲線を生成することができるものの, そのようにして生成された ROC 曲線が全体として最適であることは保証されない．

これらの考察に着目して, 本論文では, 状況変化の度合いを示す信頼度に基づいて, 受け入れ閾値を適応的に制御することで, ROC 曲線全体としての認証性能を改善する手法を提案する．これにより, 許容偽陰性率が規

定された下での偽陽性率, また反対に, 許容偽陽性率が規定された下での偽陰性率をそれぞれ最小化することができる．本研究では, 主にアクセスコントロールシステムにおける 1 対 1 認証を例に取り上げて説明を行うが, 提案手法自体は特定物体検出等を含む一般の 2 クラス識別問題に適用できる点に注意されたい．

## 2. 適応的受け入れ閾値制御

### 2.1 ROC 曲線

本節では, 提案手法の定式化の事前準備として, ROC 曲線の導入を行う．1 対 1 認証においては, 登録時と入力の特徴間で距離 (相違度) ・類似度といったような何らかの評価尺度が計算される．本論文では評価尺度として距離を取り上げるが, 類似度を評価尺度とする場合にも符号を逆転されることで同様に扱うことができる．距離を評価尺度とすると, 当然のことではあるが, 同一クラス同士の例 (正例と呼ぶ) に対しては距離が小さくなり, 異なるクラス同士の例 (負例と呼ぶ) に対しては距離が大きくなることが望ましい．

例として, 図 1(a) に示すように, 正例と負例に対する距離の確率密度関数 (Probability Distribution Function: PDF) と, 受け入れ閾値  $T$  が与えられたとする．この場合, 面積  $A_{FR}$  が本人拒否誤り率 (False Rejection Rate: FRR) を, 面積  $A_{FA}$  が他人受入誤り率に対応する．ここで, もし, 受け入れ閾値をより厳しい値  $T_T (< T)$  へと変化させた場合には, FRR が大きくなる一方, FAR が小さくなる (図 1(a))．反対に, 受け入れ閾値をより緩い値  $T_L (> T)$  に変化させた場合には, FRR が小さくなる一方, FAR が大きくなる (図 1(a))．極端な場合で言うと, 受け入れ閾値を極限まで厳しくして  $-\infty$  に設定すると, 全てのサンプルが拒否されるので, FRR が 100% で FAR が 0% ということになり, 反対に受け入れ閾値を極限まで緩くして  $+\infty$  に設定すると, 全てのサンプルが受け入れられるので, FRR が 0% で FAR が 100% ということになる．

よって, 受け入れ閾値を一番厳しい値 (例えば  $-\infty$ ) から一番緩い値 (例えば  $+\infty$ ) まで連続的に変化させると, 図 1(b) にあるような FRR と FAR のトレードオフ曲線が得られ, それがいわゆる ROC 曲線 [3] となる．

ROC 曲線が与えられると, 該当する 1 対 1 認証システムの管理者は, 予め設定した許容 FRR または FAR に基づいて適切な閾値を決定することや, FRR と FAR のトレードオフを考慮して, 例えばそれらが等しくなる等誤り率 (Equal Error Rate: EER) になるように閾値を設定することができるようになる．

また, ROC 曲線は 1 対 1 認証システムの性能評価にも用いられる．当然のことながら, システムとしては, 正例と負例の距離の PDF が良く分離されており, FRR と FAR の両方の値を小さく抑えられることが望ましい．つまり, 図 3(上段) にあるように, PDF が良く分離され




図 1 正例と負例の距離 PDF の例と、ROC 曲線




図 2 距離と信頼度の分布

ていて、ROC 曲線が左下の原点に寄っている程、性能が良いことを示す。反対に、図 3(下段)にあるように、PDF の重なりが大きく、ROC 曲線が原点から離れているほど、性能が悪いことを示している。

このような性能の違いは、システムに用いられている認証手法のみならず、与えられる正例と負例の識別難度によっても大きく左右される。例えば、ある特徴量と照合基準を備えた歩容認証システムがあったとして、登録時と入力時で歩行速度・観測方向・服装が同じ場合には正例と負例の識別は比較的容易であり、ROC 曲線は原点付近に寄ってくる。しかし、同じシステムに対して、登録時と入力時で異なる状況下での特徴が与えられた場合には、正例と負例の識別は困難になり、ROC 曲線は原点から離れてしまう。

ここでは、そのような登録時と入力時の状況の類似度を「信頼度」として見積もることができるものとする。例えば、速度変化を伴う歩容認証の場合は、追跡結果から速度差を計算して、速度差が小さい程高い信頼度を与えることができる。また、認識非対象者に対して収集した学習セットを用いることで、代表的な信頼度毎に正例と負例の PDF 及び ROC 曲線を事前に構築できるものとする。

受け入れ閾値は、通常、信頼度とは関係なく一斉に上げ下げされるので、信頼値に対しては一定値で推移する。その一方、先の例にあるように信頼度によって性能が大きく変化する場合には、受け入れ閾値を信頼度に応じて適応的に制御することで、全体性能を改善することができる。次節以降では、その適応的な閾値制御の方法について述べる。

## 2.2 2 値信頼度に対する例

本節では、適応的受け入れ閾値制御の直観的理解を助けるための簡単化された例を示す。まず、正例と負例が距離と信頼度の領域において図 2 に示すように分布していると想定する。ここでは簡単化のために、信頼度を大まかに二つに分類して考える。一つは、正例・負例の分布が良く分離されている高信頼度(図 2 右半分)であり、もう一方は正例・負例の分布が重なっている低信頼度(図 2 左半分)である。更に、各信頼度に対する距離の PDF と ROC 曲線が図 3 のようになっているものとして、低信頼度と高信頼度において FAR が 0% を満たす受け入れ

閾値の上限値をそれぞれ  $T_{NoFA}^L$  と  $T_{NoFA}^H (> T_{NoFA}^L)$  とする。また、FRR が 0% を満たす受け入れ閾値の下限値それぞれ  $T_{NoFR}^L$  and  $T_{NoFR}^H (< T_{NoFR}^L)$  とする。

次に、従来の信頼度間で一定の閾値制御を行う従来の ROC 曲線の生成過程について考える。最初に、受け入れ閾値を  $-\infty$  に設定し、その閾値を徐々に緩めて大きくしていくことで、正例を徐々に受け入れていく。この時、受け入れ閾値  $T_{NoFA}^L$  に達するまでは、両方の信頼度において負例の受け入れは生じない。受け入れ閾値  $T_{NoFA}^L$  から  $T_{NoFA}^H$  の受け入れ閾値の区間においては、受け入れ閾値が増加するにつれて、高信頼度ではやはり負例の受け入れがない一方、低信頼度では負例の一部が受け入れられる(図 3(a) の灰色部分)。更に受け入れ閾値が増加して  $T_{NoFR}^H$  に達すると、高信頼度に対しては全ての正例が受け入れられる一方、低信頼度に対してはまだいくらかの正例が残っていることになる。よって、受け入れ閾値が  $T_{NoFR}^H$  から  $T_{NoFR}^L$  に増加すると、低信頼度に対しては正例・負例の両方が受け入れられるのに対して、高信頼度に対しては負例のみが受け入れられる。

このことから考察すると、次のようなより良い受け入れ閾値の制御方法があることが分かる。まず、先と同様にして受け入れ閾値  $T_{NoFA}^L$  まで進めた後、低信頼度に対する不必要な負例の受け入れを避けるために、低信頼度に対する受け入れ閾値の増加を止めておき、高信頼度に対する受け入れ閾値を  $T_{NoFA}^H$  まで増加させる。また、受け入れ閾値が  $T_{NoFR}^H$  に達した後は、負例のみを受け入れる高信頼度に対する受け入れ閾値の増加を止めて、多少なりとも正例の存在する低信頼度に対する受け入れ閾値を  $T_{NoFR}^L$  まで増加させる。

このように、高信頼度と低信頼度に対して受け入れ閾値の進行度合いを変化させることにより、不要な負例の受け入れを抑えて全体の性能を改善することができることが分かる。

## 2.3 定式化

本節では、前節で述べた例を拡張して、一般的な適応的受け入れ閾値の制御手法を定式化する。まず、正例と負例に対する距離  $t$  の PDF をそれぞれ  $p^P(t)$ ,  $p^N(t)$  と定義する。ここで、受け入れ閾値が  $T$  に設定された場合の FAR を  $R_{FA}(T)$ , FRR を  $R_{FR}(T)$  とすると、それぞれ以下のように表される。

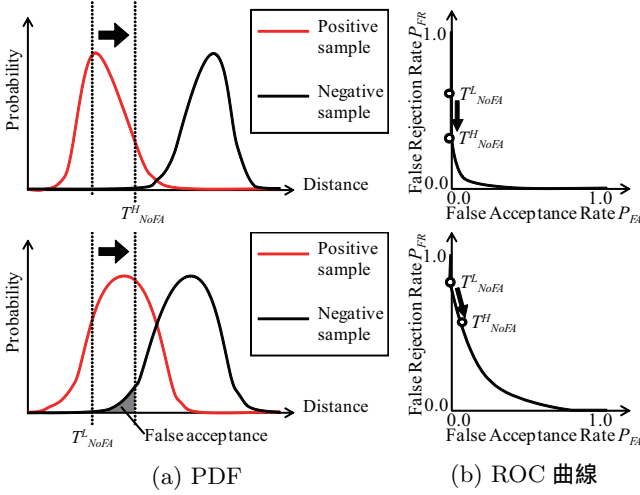


図 3 高信頼度 (上段) と低信頼度 (下段) に対する PDF と ROC 曲線

$$R_{FA}(T) = \int_{-\infty}^T p^N(t) dt \quad (1)$$

$$R_{FR}(T) = 1 - \int_{-\infty}^T p^P(t) dt. \quad (2)$$

次に、新しい変数として誤り率  $R_E(T)$  と受け入れ率  $R_A(T)$  を以下のように定義する。

$$R_E(T) = R_{FA}(T) + R_{FR}(T) \quad (3)$$

$$R_A(T) = R_{FA}(T) + (1 - R_{FR}(T)). \quad (4)$$

更に、受け入れ率  $R_A(T)$  に対する誤り率  $R_E(T)$  の勾配である誤り勾配を以下で定義する。

$$g(T) = \frac{dR_E(T)}{dR_A(T)} = \frac{p^N(T) - p^P(T)}{p^N(T) + p^P(T)}. \quad (5)$$

ここで、低誤り勾配 (例えば  $g(T) \simeq -1.0$ ) であることは、受け入れるサンプルの殆どが正例であることを意味し、逆に高誤り勾配 (例えば  $g(T) \simeq 1.0$ ) であることは、受け入れるサンプルの殆どが負例であることを意味する。加えて、誤り勾配が中間 (例えば  $g(T) \simeq 0.0$ ) であることは、受け入れるサンプルにおける正例と負例が拮抗している、つまり、正例・負例がより混在している領域であることを意味している。

次に、FAR と FRR が最小になる組を実現するための受け入れ閾値制御方法を考える。今、信頼度毎にある受け入れ閾値が設定されているとすると、誤り率の増加が一番抑えられる信頼度、即ち、誤り勾配が最小の信頼度の受け入れ閾値のみを進めることが最善の方策であると言える。そのような方策を進めて行くと、現在考えている閾値曲線上の全ての信頼度において誤り勾配  $g(T)$  が等しくなることが分かる。つまり、常に閾値曲線上の誤り勾配  $g(T)$  が等しくなるように、各信頼度の閾値を増加させていくような制御方法が、最善の方策と言える。

別の見方をすると、距離と信頼度の 2 次元空間におけ

る誤り勾配の等値線が、制御すべき受け入れ閾値曲線の集合となっていることを表す。更に、特徴間距離  $t$  と信頼度  $c$  に基づいて誤り勾配  $g(t)$  の領域にマッピングして、誤り勾配の領域において従来の一定の受け入れ閾値制御をすることで、同等の最適な閾値制御を実現することができる。結局は、学習段階において信頼度毎の誤り勾配  $g(T)$  を求めておくことで、テスト段階では信頼度と距離から誤り勾配にマッピングして従来通りの受け入れ閾値制御を行えば良いことになる。

## 2.4 実装

本節では、適応的受け入れ閾値制御の実装方法について述べる。まず、 $N_P$  個の学習用の正例と  $N_N$  個の学習用の負例が与えられ、 $i$  番目の正例と負例がそれぞれ距離と信頼度の組としてそれぞれ  $(t_i^P, c_i^P)$  と  $(t_i^N, c_i^N)$  で与えられるものとする。次に、距離  $t$  と信頼度  $c$  を適当な上限・下限・量子化ステップによって、それぞれ以下のように量子化した制御点を設定する。

$$t_j = t_{min} + j s_t, \quad j \in \mathbb{Z}, 0 \leq j \leq (t_{max} - t_{min}) / s_t \quad (6)$$

$$c_k = c_{min} + k s_c, \quad k \in \mathbb{Z}, 0 \leq k \leq (c_{max} - c_{min}) / s_c \quad (7)$$

更に、 $i$  番目の正例学習サンプルの  $k$  番目の信頼度制御点に対する重み  $w_{i,k}^P$  を以下のように計算する。

$$w_{i,k}^P = \max(1.0 - |c_i^P - c_k| / s_c, 0) \quad (8)$$

続いて、 $j$  番目の距離制御点と  $k$  番目の信頼度制御点に対する PDF の値  $p_{j,k}$  を、ノンパラメトリックなガウシアンカーネルによる確率密度推定手法により以下のように求める。

$$p_{j,k}^P = \frac{1}{Z_k} \sum_i w_{i,k}^P \exp\left(-\frac{(t_i^P - t_j)^2}{2\sigma^2}\right), \quad (9)$$

ここで  $Z_k$  は PDF を  $\sum_j p_{j,k}^P s_t = 1$  として正規化するための分配関数であり、 $\sigma$  は事前に定めたガウシアンカーネルのサイズである。負例の PDF  $p_{j,k}^N$  についても同様に計算した後、制御点  $(t_j, c_k)$  における誤り勾配  $g_{j,k}$  を式 (5) によって計算する。ここで、適応的受け入れ閾値制御の最適性を満たすために、各信頼度制御点  $c_k$  に対して、誤り勾配が準単調増加でなければならないため、誤り勾配  $g^* = \{g_{j,k}^*\}$  を、以下の制約化付きの自乗誤差最小化の枠組みで最適化する。

$$g^* = \arg \min_{\hat{g}} S(\hat{g}) \quad (10)$$

$$S(\hat{g}) = \sum_{k,j} \{(\hat{g}_{j,k} - g_{j,k})^2 + \alpha(\hat{g}_{j,k} - \hat{g}_{j-1,k})^2\} \quad (11)$$

$$\text{subject to } \hat{g}_{j-1,k} \geq \hat{g}_{j,k}, \quad (12)$$

ここで、 $\alpha$  は正規化係数である。この最適化問題は凸 2 次計画法により効率的に解くことができる。また、全制御点において得られた誤り勾配を誤り勾配マップと呼ぶ。

これより、任意の距離と信頼度の組が与えられると、それを誤り勾配マップに基づく線形補間によって誤り勾配の領域にマッピングし、誤り勾配領域において従来の受け入れ閾値制御を適用する。

ここで、学習セットとテストセットの傾向がほぼ同様である場合には、この誤り勾配マップが学習セットのみならずテストセットに対しても適用可能である点に注意されたい。

### 3. 実験

#### 3.1 シミュレーションデータ

本節ではシミュレーションデータによる実験を行う。まず、学習セットとテストセットの正例と負例を生成するためのPDFを設定する。信頼度  $c$  のPDFは  $0 \leq c \leq 1$  の範囲の一様分布として、正例と負例で共通に用いる。次に、正例と負例の距離に関するPDFをガウス分布としてそれぞれ  $\mathcal{N}(\mu^P(c), \sigma^P(c))$  と  $\mathcal{N}(\mu^N(c), \sigma^N(c))$  で定義する。基本的に、これらの二つのPDFは信頼度  $c$  が低い程、識別が困難になるように設定するため、ガウス分布の平均と標準偏差をそれぞれ  $\mu^P(c) = 5.0 - 3.0c$ ,  $\mu^N(c) = 7.0 - 2.0c$ ,  $\sigma^P(c) = 1.0 - 0.5c$ ,  $\sigma^N(c) = 1.0 - 0.5c$  とする。

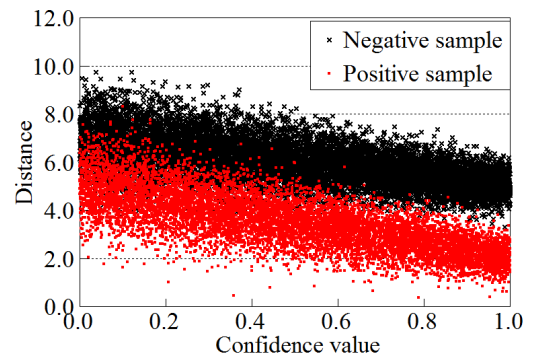
更に、学習セットの正例と負例を設定したPDFからそれぞれ 10,000 サンプル生成する (図 4(a))。図より、高信頼度の領域 (例えば  $c = 1.0$ ) においては正例と負例の分布が良く分離されているのに対して、低信頼度の領域 (例  $c = 0.0$ ) においてはそれらの分布がより重なっていることが分かる。同様にして、性能評価に用いるテストセットの正例・負例を同様に 10,000 サンプル生成する。

次に、実験に用いるパラメタを設定する。PDF 推定については、ガウシアンカーネルのサイズと制御点間隔をそれぞれ  $\sigma = 0.3$ ,  $s_t = 0.01$ ,  $s_c = 0.1$  とした。また、距離の領域を  $t_{min} = 0.0, t_{max} = 10.0$ , 正則化係数を  $\alpha = 1.0$  とした。

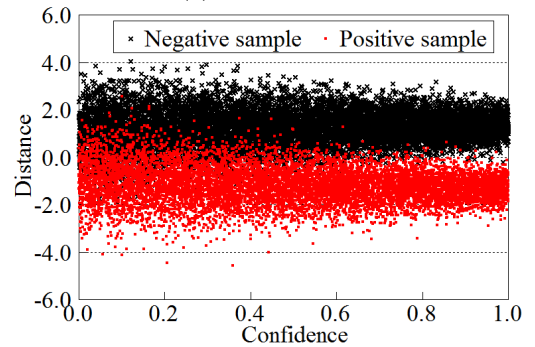
加えて、比較手法として  $z$  標準化 [3] を取り上げる。 $z$  標準化は、アクセスコントロールシステム等において 1 対 1 認証を行う際、他の全登録者との距離を計算し、その平均と標準偏差で距離を標準化する手法である。ここでは、近似的に元の分布の平均  $\mu(c)$  を引いて、標準偏差  $\sigma(c)$  で割った値を新たな距離として用いる。結果として得られた学習サンプルを図 4(b) に示す。ここで、 $z$  標準化後の平均と標準偏差はそれぞれ 0 と 1 に一致することに注意されたい。

#### 3.2 性能評価

まず、学習セットから誤り勾配を推定し、その誤り勾配の等値線を図 5 に示す。これより、正例と負例の識別が容易な高信頼度の領域では等値線が密になっているのに対して、正例と負例の識別が困難な低信頼度の領域では等値線が疎になっていることが分かる。また、学



(a) 学習サンプル



(b)  $z$  標準化したサンプル

図 4 学習サンプルの距離と信頼度の分布

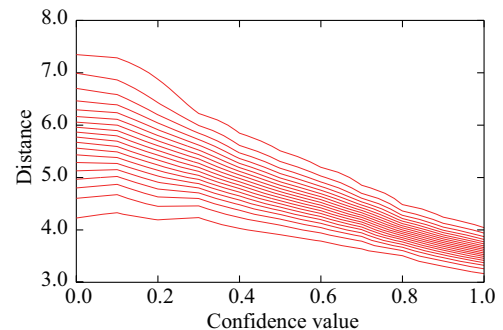


図 5 学習セットの誤り勾配の等値線 (間隔 0.1)

習した誤り勾配マップに基づいて、テストサンプルを誤り勾配の領域にマッピングした結果を図 6 に示す。図より、誤り勾配がバランスしている領域 (例えば  $g = 0.0$ ) について、高信頼度の領域ではサンプルが疎になっており、低信頼度の領域ではサンプルが密になっていることが分かる。また、信頼度によらず、低誤り勾配 (例えば  $g = -1.0$ ) においては殆どが正例によって占められており、中間の誤り勾配 (例えば  $g = 0.0$ ) においては正例と負例が混在しており、高誤り勾配 (例えば  $g = 1.0$ ) においては殆どが負例によって占められていることが分かる。

最後に、テストセットに対する性能評価を行うために ROC 曲線を図 7(a) に示す。結果として、提案手法の適応的受け入れ閾値制御 (AATC) が従来の固定閾値制御 (const) の性能を上回っていることが分かる。一方、 $z$  標準化 (Z-norm) については提案手法に近い性能を達成し

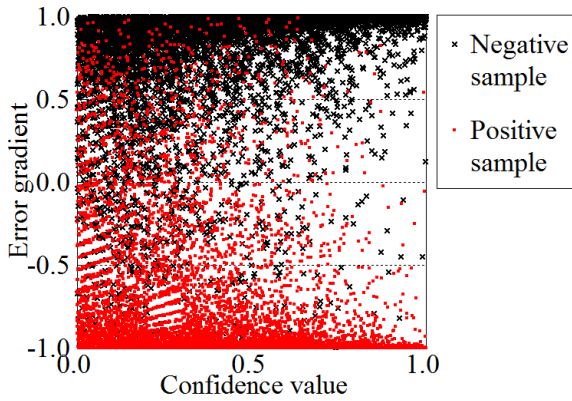


図 6 テストセットの誤り勾配領域へのマッピング

ているが、許容 FAR が極めて小さい範囲 (図 7(b)) や許容 FRR が極めて小さい範囲 (図 7(c)) で見ると、提案手法の方が  $z$  標準化より良い性能になっていることが分かる。これより、提案手法が許容 FAR と FRR のいずれかが厳しい場合に特に有効であることが分かる。

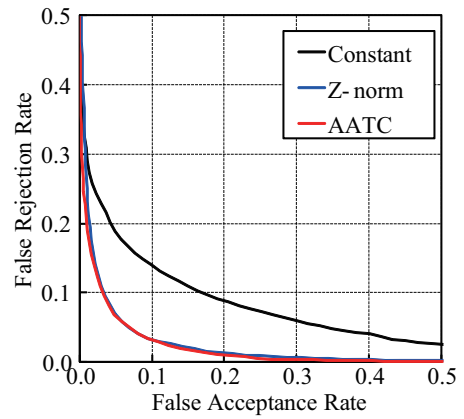
### 3.3 実データに対する実験

実データ実験として、服装変化を伴う歩容認証に本手法を適用した。データセットは、68 人の被験者の最大 32 種類の服装からなる合計 2,120 の歩容シーケンスを用いた。本実験で用いた服装変化の例を図 8 に示す。この内、20 人を認識対象外の学習被験者として学習セットに用い、残りの 48 人の被験者を認識対象のテストセットとした。また、テスト被験者のデータの内、特定の 1 種類の服装のデータをギャラリーとし、残りの服装のデータをプローブとして、1 対 1 認証を行った。

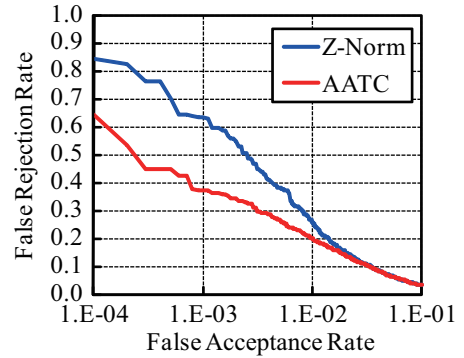
特徴間距離及び信頼度の計算は、Hossain ら [6] の手法を用いた。詳細については [6] を参照されたいが、概要は以下の通りである。大きさの正規化や位置合わせを行ったシルエットシーケンスから周波数領域特徴 [18] を抽出する。その特徴を体の部位に分割してそれぞれで特徴間距離を計算し、服装変化の影響を受けている部位の重みを下げて、逆に服装変化の影響を受けていない部位の重みを上げて距離を統合する。一方、信頼度は体の部位に対する重みの総和として定義される。

本実験における学習サンプルの距離と信頼度の分布を図 9 に、テストセットを誤り勾配領域にマッピングした結果を図 10 に示す。本実験セットにおいて、低信頼度領域においては、正例のみ・負例のみが占める距離が存在しないため、誤り勾配の -1 付近、+1 付近にはマッピングされていない。しかし、いずれの信頼度においても誤り勾配毎の正例・負例の割合は概ね等しくなっていることが分かる。

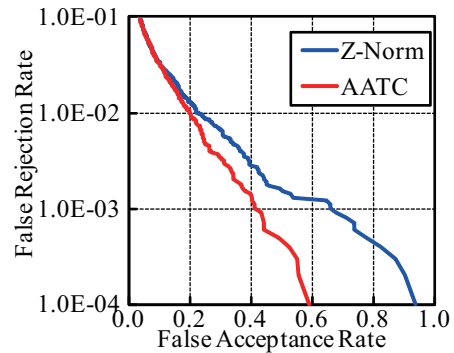
最後に、1 対 1 認証実験の性能評価を図 11 の ROC 曲線により行う。結果として、提案手法が従来的一定閾値制御の性能を概ね上回っていることが分かる。一方、 $z$  標準化については提案手法より若干良い性能を示している。



(a) 通常範囲



(b) 低 FAR 範囲



(c) 低 FRR 範囲

図 7 ROC 曲線




図 8 歩容認証における服装変化の一例

これは、提案手法が学習セットとテストセットで信頼度と距離の分布傾向がほぼ同じことを仮定しているのに対して、実際にはそれらの間にずれが存在するため、実際には最適な適応的受け入れ閾値制御とはならなかったものと考えられる。よって、適応的受け入れ閾値制御の汎化性能の向上に関する研究が今後の課題の一つとなる。

## 4. 考察

本論文の実験においては  $z$  標準化との比較を行った。




図 9 歩容認証における学習サンプルの距離と信頼度の分布




図 10 歩容認証におけるテストセットの誤り勾配領域へのマッピング




図 11 歩容認証実験に対する ROC 曲線

本節では、提案手法と  $z$  標準化との特性について考察する。事前学習の観点について見ると、提案手法が誤り勾配へのマッピングを事前学習しておく必要があるのに対して、 $z$  標準化は事前学習が不要である点が利点である。一方、テスト段階における計算量について考えると、提案手法は 1 対 1 認証の計算 1 回と誤り勾配へのマッピング 1 回で済むことから計算量は  $O(1)$  である。 $z$  標準化は登録している  $N$  人との距離計算及びそれらの距離の平均と標準偏差の計算と正規化計算が必要であり、その計算量は  $O(N)$  である。現在主に用いられている指紋や静脈によるアクセスコントロールシステムは、基本的にカードや番号入力によって登録 ID を取得することで 1

対 1 認証を行う方式が主になっている。これは、1 対  $N$  認証では時間がかかりユーザの利便性を損なうことが一つの要因である。よって、誤り率が同等程度であっても、実用時の計算コストの低い提案手法は有用であると考えられる。

また、2 クラス識別の観点からすると、1. でも述べたように、距離と信頼度の組を 2 次元特徴ベクトルと見なして、LDA [19] や SVM [20] 等の識別技術を適用することも考えられる。しかし、これらの識別技術は最適な識別面を求めることを目的としており、ROC 曲線全体を最適化することを目的としたものではなく、基本的には識別面に対応して一つの FAR と FRR の組が決まるのみである。また、識別面までの符号付き距離に対して受け入れ閾値を変化させることで ROC 曲線を決めることはできるものの、ROC 曲線全体の最適化が保証される訳ではない点に注意されたい。

## 5. まとめ

本論文は、2 クラス問題における信頼度に基づく適応的受け入れ閾値の制御手法を提案した。受け入れ率に対する誤り率の比率を示す誤り勾配を導入し、ROC 曲線を最適化する適応的受け入れ閾値を誤り勾配の等値線として定式化した。また、誤り勾配の等値線を扱う代わりに誤り勾配の領域にマッピングすることで、従来の一定閾値制御が適用可能である。実験では、シミュレーションデータ及び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。

今後の課題としては、提案した適応的受け入れ閾値制御手法を人物検出等の他の 2 クラス問題に適用することや、テストセットに対する汎化性能の向上が挙げられる。

## 謝 辞

本研究は科研費 21220003 の助成を受けたものである。

## 文 献

- [1] P. Viola and M. Jones, "Robust real-time face detection," Int. J. of Computer Vision, vol. 57, no. 2, pp. 137–154, 2004.
- [2] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," CVPR2005, II pp. 886–893, 2005.
- [3] P. Phillips, H. Moon, S. Rizvi, and P. Rauss, "The feret evaluation methodology for face-recognition algorithms," Trans. of Pattern Analysis and Machine Intelligence, vol. 22, no. 10, pp. 1090–1104, 2000.
- [4] Y. Makihara, R. Sagawa, Y. Mukaigawa, T. Echigo, and Y. Yagi, "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, May 2006.
- [5] 辻, 榎原, 八木, "歩容認証のための速度変化に応じたシルエット変換," 第 12 回画像の認識・理解シンポジウム (MIRU2009), pp. 1–8, 7 月 2009.
- [6] M. A. Hossain, Y. Makihara, J. Wang, and Y. Yagi,

- “Clothes-invariant gait identification using part-based adaptive weight control,” Proc. of the 19th Int. Conf. on Pattern Recognition, Tampa, Florida USA, Dec. 2008.
- [7] A. Harriero, D. Ramos, J. Gonzalez-Rodriguez, and J. Fierrez, “Analysis of the utility of classical and novel speech quality measures for speaker verification,” ICB '09: Proceedings of the Third International Conference on Advances in Biometrics, Berlin, Heidelberg Springer-Verlag pp. 434–442, 2009.
- [8] F. Alonso Fernandez, F. Roli, G. Marcialis, J. Fierrez, and J. Ortega Garcia, “Comparison of fingerprint quality measures using an optical and a capacitive sensor,” BTAS07, pp. 1–6, 2007.
- [9] S. Muller, O. Henniger, and T. U. D. Darmstadt, “Evaluating the biometric sample quality of handwritten signatures,” In 2nd International Conference on Biometrics,, 2007.
- [10] E. Krichen, S. Garcia-Salicetti, and B. Dorizzi, “A new probabilistic iris quality measure for comprehensive noise detection,” Biometrics: Theory, Applications, and Systems, 2007. BTAS 2007. First IEEE International Conference on, pp. 1–6, 27-29 2007.
- [11] M. A. Hossain, Y. Makihara, J. Wang, and Y. Yagi, “Clothing-invariant gait identification using part-based clothing categorization and adaptive weight control,” Pattern Recognition,, 2010 (to appear).
- [12] H. Sellahewa and S. Jassim, “Illumination and expression invariant face recognition: Toward sample quality-based adaptive fusion,” BTAS08, pp. 1–6, 2008.
- [13] M. Gales and S. Young, “Robust continuous speech recognition using parallel model combination,” IEEE Transactions on Speech and Audio Processing, vol. 4, no. 5, pp. 352 – 359, 1996.
- [14] N. Poh, J. Kittler, and T. Bourlai, “Improving biometric device interoperability by likelihood ratio-based quality dependent score normalization,” BTAS07, pp. 1–5, 2007.
- [15] J. Fierrez-Aguilar, “Adapted Fusion Schemes for Multimodal Biometric Authentication” PhD thesis Universidad Politecnica de Madrid, 2006.
- [16] S. Bengio, C. Marcel, S. Marcel, and J. Mariethoz, “Confidence measures for multimodal identity verification,” Information Fusion, vol. 3, no. 4, pp. 267–276, 2002.
- [17] K. Kryszczuk and A. Drygajlo, “Improving classification with class-independent quality measures: Q-stack in face verification,” In 2nd International Conference on Biometrics, Seoul, South Korea,, 2007.
- [18] 榎原, 佐川, 向川, 越後, 八木, “周波数領域における方向変換モデルを用いた歩容認証,” 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. 48, no. SIG1(CVIM17), pp. 78–87, Feb. 2007.
- [19] J. H. P. Belhumeur and D. Kiregeman, “Eigenfaces for recognition,” IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 19, no. 7, pp. 711–720, Jul. 1997.
- [20] B. E. Boser, I. M. Guyon, and V. N. Vapnik, “A discriminant analysis for undersampled data,” Proc. of the 5th Annual ACM Workshop on Computational Learning Theory, pp. 144–152, 1992.