

# 虹彩および目の周辺の分割画像を用いた個人認証

白川 功浩<sup>1,a)</sup> 吉浦 裕<sup>1</sup> 市野 将嗣<sup>1</sup>

受付日 2017年11月27日, 採録日 2018年6月8日

**概要:** 虹彩認証は, 他のバイオメトリック認証方式と比べ, 非常に高い認証精度を持つことが知られている. しかし, 虹彩認証は高画質の画像を必要とするため, 至近距離で認証を行う必要があり, 被認証者に負担を与えてしまうという問題点があった. これに対して, 先行研究では虹彩認証と目の周辺画像を用いた認証 (以下, 目の周辺認証) を統合する手法を提案されている. 目の周辺画像には, 目頭や目尻, まぶたの形などに個性が存在すると考えられるが, 先行研究の多くはそれらを一律に扱っていた. そこで本研究では目の周辺の領域ごとの個性を積極的に利用するために, 目の周辺の分割画像を利用して目の周辺認証を行い, 虹彩と統合する認証を提案した. その結果, 従来手法と比較し認証精度が向上し, 領域分割を利用した提案手法の有効性を確認した.

**キーワード:** バイオメトリクス, 虹彩認証, 目の周辺認証, 領域分割, AdaBoost

## Person Authentication Based on Iris and Periocular Using Region Partitioning

YOSHIHIRO SHIRAKAWA<sup>1,a)</sup> HIROSHI YOSHIURA<sup>1</sup> MASATSUGU ICHINO<sup>1</sup>

Received: November 27, 2017, Accepted: June 8, 2018

**Abstract:** Iris authentication has high accuracy as compared with other biometric authentication methods. However, since iris authentication requires high-quality images, it is necessary to approach at a close distance and burden is given to the person. In order to reduce the burden, in the previous research, a method of integrating iris authentication and periocular authentication was proposed, enabling long distance authentication. However, many previous studies are not conscious of features of each part such as the shape of the inner corner and eyelids. Therefore, in this research, in order to positively utilize the individuality of each area around the eyes, we proposed periocular authentication using divided images around the eyes. As a result, compared with previous research, the authentication accuracy was improved, and the effectiveness of the proposed method using region partitioning could be confirmed.

**Keywords:** biometrics, iris authentication, periocular authentication, region partitioning, AdaBoost

### 1. はじめに

近年, 携帯端末や銀行 ATM の利用など, 多くの場面で安全性・利便性の高い個人認証を行う必要性が高まっている. 現在, よく用いられている個人認証方式としてはパスワードなどの本人の知識, 記憶によるものや, IC カードなどの本人の所有物によるものがあげられる. しかし, こ

れらの方式は, 忘却や盗難, 紛失などの恐れがあり, 第三者によるなりすましが行われる危険性も存在する. そこで注目されているのが, 指紋や虹彩, 音声など, 本人の身体的・行動的な特徴を利用するバイオメトリック認証 (生体認証) 方式である. この方式では, パスワードの記憶や鍵などの携帯がいらず, 偽造やなりすましも難しいという利点がある.

バイオメトリック認証の中でも, 特に虹彩認証は他のバイオメトリック認証と比べ他人受入率がきわめて低いため, 高い安全性が実現できる技術である. しかし, 虹彩は複雑な模様で構成されているため, 撮影の際には模様が鮮

<sup>1</sup> 電気通信大学  
The University of Electro-Communications, Chofu, Tokyo  
182-8585, Japan

<sup>a)</sup> y.shirakawa@uec.ac.jp

明に映るように、カメラと非認証者との距離が0.5mほどの至近距離まで近寄る必要がある。これにより従来の虹彩認証では被認証者の負担が大きくなり、利便性が低下するという問題点がある。これを軽減する方法として、認証機器から離れて虹彩を撮影する方法が考えられるが、距離が離れるにつれて虹彩画像の質が劣化し、精度が低下することが報告されている [1]。

こうした問題に対して、複数のモダリティを組み合わせるマルチモーダルバイオメトリック認証が注目されている。先行研究では、遠距離での虹彩認証に目の周辺画像を用いた認証（以下、目の周辺認証とする）を組み合わせる方法が提案されていた [2], [3], [4]。虹彩画像と目の周辺画像は、1つのカメラで同時に撮影ができるため、被認証者にあまり負担をかけずにデータを取得することができる。また、これらを組み合わせることで認証精度が向上したことが報告されている。

しかし、多くの先行研究では目の周辺認証を目の周辺の領域ごとの個人性を意識せずに行っている。目の周辺には、まぶたや目頭の形など明らかに個人性が存在する部分があるほか、部位として明確に定義されていない領域にも個人性が存在すると考えられる。

そこで本研究では、虹彩認証と目の周辺認証のマルチモーダルバイオメトリック認証において、目の周辺の領域ごとの個人性を積極的に利用するために、目の周辺の分割画像を利用した目の周辺認証を提案する。そして、両目の虹彩、目の周辺とその分割画像から得られる特徴量それぞれを、Boostingの代表的な手法であるAdaBoostを用いて統合することで先行研究よりも高い識別性能を有することを示す。

## 2. 関連研究

### 2.1 虹彩認証

虹彩とは、黒目の内側で瞳孔より外側に存在するドーナツ状の筋肉質の部位であり、一卵性双生児や同一人物の左右の目であっても、虹彩の模様はまったく同じにはならない。また、2歳ごろを過ぎると、その模様が変化することはないため、他のバイオメトリック認証と比べ認証精度が劣化しにくい [5]。

以下に虹彩認証の代表的アルゴリズムであるDaugmanのアルゴリズムについての説明を示す [6]。

#### (1) 局域化処理

ここでは、目画像から虹彩部分のみを切り出す処理を行う。虹彩の外側と内側の境界およびまぶたとの境界を、輝度の差から検出する。

#### (2) Iriscodeの作成

(1)で切り出した虹彩を、同心円状に8分割する。このとき、髪の毛やまつ毛、瞬きなどによるオクルージョンの問題がある可能性がある部分に関して、あ

らかじめ照合に用いる部分の範囲を制限する。その後、使用する部分に関して複数の空間周波数に対するGaborフィルタを用いたウェーブレット変換を行い、濃淡変化を抽出する。抽出した濃淡変化を $n$ bitのデジタルデータ化したものがIriscodeと呼ばれる特徴量となる。

#### (3) 本人認証処理

取得されたIriscodeと登録されたIriscodeのハミング距離をスコアとして、これを用いて本人を認証する。ここで、スコアとは対象の2つのデータから得られた特徴の相違を数値で表したものである。虹彩認証におけるスコアは、学習データとテストデータのIriscodeどうしのハミング距離である。4章の評価実験ではmin-max正規化を行うため、スコアの値の範囲は0から1である。認証には、照合と識別がある。照合とは、提示されたデータの特徴とシステム内に登録されたデータの特徴との1対1の対応関係を確認することである。照合の際には、本人、他人を区別するために閾値を用いる。照合で用いる閾値は、次の方法で算出する。本人の学習データから得られたIriscodeと本人のテストデータから得られたIriscodeを求め、そのスコアを算出する。その処理を人物を変えて行う。また、本人の学習データから得られたIriscodeと本人とは異なる他人のテストデータから得られたIriscodeを求め、そのスコアを算出する。その処理を人物を変えて行う。これらの処理で求まる本人本人間のスコアと本人他人間のスコアに対して、閾値の値を変えながら本人、他人の判定を行う。そして、最も誤判定されるデータが少なくなる閾値の値を照合に利用する閾値として定める。この閾値とスコアの大小関係で本人と判別する。また、識別とは、提示されたデータの特徴とシステム内に登録されたデータの特徴を比較し、最も近いものを探すことである。識別の際には、提示されたデータから得られたIriscodeとシステム内に登録された各人のテストデータから得られたIriscodeからスコアを算出する。そして、各人のスコアの大小関係を基つき、提示されたデータの人物に最も近い、システム内に登録されたデータの人物を探す。

### 2.2 目の周辺認証

目の周辺認証は虹彩や目を取り囲む領域を利用した生体認証である。目の周辺認証で利用する画像の領域は先行研究によって様々であるが、一般的にまぶたやまつげ、およびそれ以外の皮膚領域などが含まれている [2]。また、目の周辺の情報として目の内側の領域（虹彩、強膜領域）を含めた場合、含めない場合と比較して識別率が15%以上向上したことが報告されている [7]。

また、目の周辺認証で利用されている特徴量は先行研究

表 2 虹彩と目の周辺認証の統合

Table 2 Combination of iris and periocular authentication.

| 論文著者             | 目の周辺特徴量             | 虹彩特徴量                             | データセット                             | 統合方法       |
|------------------|---------------------|-----------------------------------|------------------------------------|------------|
| Woodard [2]      | LBP                 | Gabor                             | MBGC                               | 重みつけ和      |
| C. Tan [3]       | LBP, HOG, SIFT, LMF | Log Gabor                         | UBIRIS.v2, FEGC, CASIA v4-distance | 重みつけ和      |
| T. Tan [12]      | Dense-SIFT          | Ordinal measures, Color histogram | UBIRIS.v2                          | 重みつけ和      |
| Raghavendra [13] | LBP+SRC             | LBP+SRC                           | 自作データセット                           | 重みつけ和      |
| Raja [14]        | BSIF+SRC            | BSIF+SRC                          | 自作データセット                           | 重みつけ和      |
| ashmed [15]      | TLBP                | Gabor                             | MICHE II                           | 重みつけ和      |
| Mikaelyan [16]   | SAFE                | Gabor                             | BioSec, MobBIO                     | 重みつけ和      |
| Ahuja [17]       | CNN                 | CNN, SIFT                         | MICHE II, VISOB                    | 重みつけ和      |
| Joshi [19]       | LBP                 | Wavelets                          | UBIRIS.v2, CASIA-Iris-Interval     | Direct LDA |
| Santos [18]      | LBP, SIFT           | wavelets                          | UBIRIS.v2                          | ロジスティック回帰  |
| 大石ら [4]          | LBP, HOG, SIFT      | Gabor                             | CASIA v4-distance                  | AdaBoost   |

表 1 目の周辺認証で利用された特徴量

Table 1 Features used in previous research.

| 参考文献        | 目の周辺 特徴量            |
|-------------|---------------------|
| Woodard [2] | LBP                 |
| Tan [3]     | LBP, HOG, SIFT, LMF |
| Park [7]    | LBG, HOG, SIFT      |
| Sambit [8]  | SIFT, SURF, PILP    |

によって様々である。表 1 に、先行研究で用いられている特徴量を示す。表 1 に示すように、LBP [9], HOG [10], SIFT [11] という 3 つの特徴量が多くの研究で用いられている。

目の周辺認証において、本研究における LBP 特徴量を用いた場合のスコアは、学習データの画像とテストデータの画像それぞれから算出した特徴ベクトル間のマンハッタン距離である。本研究における HOG 特徴量を用いた場合のスコアは、学習データの画像とテストデータの画像それぞれから算出した特徴ベクトル間のマンハッタン距離である。本研究における SIFT 特徴量を用いた場合のスコアは、以下の式により算出される  $S$  である。

$$S = N * \frac{1}{\frac{\sum_{j=1}^N d_j}{N}} \quad (1)$$

ただし、 $N$  は学習データの画像とテストデータの画像の間の対応点の数、 $d_j$  は学習データの画像とテストデータの画像の  $j$  番目の対応点間の距離を表している。4 章の評価実験では min-max 正規化を行うため、LBP 特徴量、HOG 特徴量、SIFT 特徴量のスコアの値の範囲は 0 から 1 である。

目の周辺認証において、虹彩認証と同様に、照合の際には、閾値とスコアの大小関係で本人を判別する。識別の際には、提示されたデータから得られた特徴量とシステム内に登録された各人のテストデータから得られた特徴量をそれぞれ求め、スコアを算出する。そして、各人のスコアの大小関係を基づき、提示されたデータの人物に最も近い、システム内に登録されたデータの人物を探す。

## 2.3 虹彩と目の周辺を組み合わせた認証

虹彩認証は、非常に高精度の認証が可能であるという利点がある。しかし、至近距離での撮影が必要であり、撮影距離が離れるにつれて精度が大幅に低下してしまうという欠点がある [1]。そこで虹彩画像を撮影する際に同時に取得可能な目の周辺画像を利用した目の周辺認証を組み合わせることで遠距離における精度低下を補うことができる可能性がある。先行研究では虹彩認証と目の周辺認証をスコアレベルで統合することで認証精度が向上したことが報告されている。表 2 に先行研究を示す。

Woodard ら [2] は目の周辺領域全体から LBP 特徴量を抽出し、虹彩領域から得た Gabor フィルタの反応値を Gabor 特徴量として利用した。それぞれの特徴量のスコアに対して単純に重みをつけ、その和を統合スコアとして認証に用いた。以降、この統合手法を重みつけ和という。また、C. Tan ら [3] は、目の周辺認証において、目の周辺領域全体から従来よく使われている LBP, HOG, SIFT と、LMF と呼ばれる様々な向きおよびスケールのガウシアンフィルタなどで構成されるフィルタ群の反応値を特徴量として利用した。虹彩認証においては、Log-Gabor フィルタを特徴抽出に利用した。そして目の周辺認証のスコアと虹彩認証のスコアを重みつけ和により組み合わせた。T. Tan ら [12] は、目の周辺認証では、SIFT の応用である Dense SIFT と呼ばれる特徴量を目の周辺領域から抽出した。従来の SIFT が輝度勾配から算出された特徴点の周辺からしか特徴を抽出しないのに対して、Dense SIFT は特徴点をグリッド状に配置することで画像全体から特徴を抽出する。また、虹彩認証では、虹彩領域から得られた Ordinal Measures と呼ばれる Ordinal フィルタの反応値と、虹彩領域の色ヒストグラムから得られる特徴量を用いた。それぞれの特徴量に対するスコアを重みつけ和を用いて組み合わせた。また、Raghavendra ら [13] は目の周辺領域全体から得られた LBP 特徴量と虹彩領域から得られた LBP 特徴量に対してスパース表現に基づく識別法 (SRC) を組み合わせて、それぞれの特徴量に対するスコアを算出し、それぞれのスコ



アを重み付け和で組み合わせた。Raja ら [14] は、目の周辺認証、虹彩認証それぞれにおいて、対象画像にサイズの異なる複数種類のパッチフィルタを適用し、それぞれに対して BSIF と呼ばれる特徴量と SRC を組み合わせ、パッチごとのスコアを重み付け和で統合した。そして、さらに目の周辺認証のスコアと虹彩認証のスコアの統合手法として重み付け和を用いた。Ashmed ら [15] は、虹彩認証については、1-D Gabor filter を用いて特徴量を抽出した。目の周辺認証では、従来の LBP の代わりに、注目画素の時計回り方向の隣接画素の大小関係をパターン化した TLBP という特徴量を目の周辺領域全体から抽出した。そして、目の周辺認証のスコアと虹彩認証のスコアの統合手法として重み付け和を用いた。Mikaelyan ら [16] は、目の周辺認証については、目の周辺の対称的なパターンに注目し、目の周辺領域全体から指紋認識に用いられている SAFE 特徴量を目の周辺認証に適用した。虹彩認証については、虹彩領域から得られる Gabor 特徴量を用いた。そして、目の周辺認証のスコアと虹彩認証のスコアの統合手法として重み付け和を用いた。Ahuja ら [17] は Convolutional Neural Network (CNN) を用いて目の周辺領域全体と虹彩領域から特徴抽出を行い、目の周辺認証、虹彩認証それぞれのスコアを算出した。そして、それぞれのスコアを重み付け和で統合した。以上のように、目の周辺認証と虹彩認証を組み合わせる研究において、目の周辺認証と虹彩認証それぞれにおける特徴抽出方法についての研究が多い。虹彩認証のスコアと目の周辺認証のスコアの統合手法に関しては、ほとんどの研究において重み付け和<sup>\*1</sup>を用いている。

統合手法として重み付け和が多く用いられているが、そのほかの統合手法を用いた先行研究として次のものがある。Santos ら [18] は、目の周辺認証については、目の周辺領域全体から LBP や SIFT を特徴量として用い、それぞれの特徴量でスコアを求めた。虹彩認証においては、ウェーブレット表現など複数の特徴量を算出し、それぞれの特徴量に対してスコアを求めた。そして、目の周辺認証と虹彩認証の複数種類の特徴量に対するスコアをロジスティック回帰を利用して統合した。各特徴量のスコアを軸にとったスコア空間上で考えると、ロジスティック回帰による統合手法では本人・他人を分ける識別境界が線形となる。非線形境界が必要な場合においても非線形に対応した特徴量の適応的な選択はできないという問題がある。Joshi ら [19] は、目の周辺認証においては、目の周辺領域全体から LBP 特徴量を抽出した。虹彩認証においては、ウェーブレット変換を用いて特徴抽出した。目の周辺認証と虹彩認証の特徴量の統合手法として Direct LDA (線形判別分析) を利用した。各特徴量を軸とした特徴空間上で、Direct LDA に

よる識別境界は線形となる。非線形境界が必要な場合においても非線形に対応した特徴量の適応的な選択はできないという問題がある。大石ら [4] はアンサンブル学習の代表的手法である AdaBoost を利用して、4 種類の特徴量のスコアを統合していた。AdaBoost による統合手法では、非線形に対応した特徴量の適応的な選択が可能である。

以下で、先行研究で多く用いられていた重み付け和による統合手法と、AdaBoost による統合手法について説明する。

### 2.3.1 重み付け和による統合手法

先行研究 [2], [3] では、虹彩認証と目の周辺認証により算出したスコアに対し、重み付け和によって統合を行っている。以下に、この重み付け和による統合手法の手順を示す。

#### (1) スコアの正規化

虹彩認証のスコアに対し、min-max 正規化を行う。min-max 正規化は以下の式を用いて算出する。

$$x_{new} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

ここでは、あるデータのスコアを  $x$ 、そのスコアの最小値と最大値をそれぞれ  $x_{min}$  と  $x_{max}$ 、正規化後のデータのスコアを  $x_{new}$  としている。

#### (2) スコア統合

スコアをそれぞれ  $S_{iris}$ ,  $S_{periocular}$  両部位のスコアの統合スコア  $S$  は以下のように算出する。

$$S = \omega_1 S_{iris} + \omega_2 S_{periocular} \\ \omega_1 + \omega_2 = 1 \quad (3)$$

このとき、それぞれのスコアに付与する重みを  $\omega_1$ ,  $\omega_2$  とする。Tan らによれば、離れた距離での虹彩認証の識別率が約 55%、目の周辺認証の識別率が約 39–68%であったが、組み合わせた場合の識別精度は約 78–83%に向上したことが報告されている。

多くの先行研究では重み付け和による統合手法が利用されている。しかし、重み付け和による統合手法では、スコア空間において識別境界が線形となる。スコア空間とは、各特徴量のスコア (min-max 正規化を行っている) の範囲は 0 から 1 の間を軸にとった空間を示している。スコア分布 (min-max 正規化を行っている) の範囲は 0 から 1 の間とは、スコア空間上に本人・他人の点 (各特徴量のスコアの値を並べたものをベクトルとし、そのベクトルに相当) をプロットしたものである。認証の際に、照合ではスコア空間上で、本人、他人のスコア分布を分ける境界を求め、各点が境界の本人側、他人側のどちらに存在するかで本人か他人かを判定する。識別の際には、本人・他人の各点を式 (3) に代入し、各人の式 (3) の値の大小関係をに基づき、提示されたデータの人物に最も近い、システム内に登録されたデータの人物を探す。

重み付け和による統合手法を利用した研究として、T.

<sup>\*1</sup> スコアの平均値を用いて認証する研究もあるが、平均値は重み付け和におけるすべての重みが等しい場合と同じであるため、本論文では重み付け和で統一して記述している。

Tan ら [12] は、重みの組合せを探索により決めることを行った。利用する特徴量が多くなると、スコア空間上でスコア分布のとりうる状態が多くなる。それにともない、スコア分布が複雑となり、本人、他人のスコア分布を分けるのに非線形の識別境界が必要となる可能性がある。しかしながら、スコア空間において重みつけ和による識別境界は線形となるため、本人と他人の判定を誤る可能性がある。

### 2.3.2 Boosting による統合手法

2.3.1 項で述べた重みつけ和の問題に対して、大石ら [4] はアンサンブル学習の代表的手法である AdaBoost を用いた統合手法を提案した。

この手法には、以下の 2 つの大きな利点が存在する。

- 様々な特徴量を組み合わせる場合、特徴空間においては複雑な分布となり、非線形または区分線形の識別アルゴリズムが必要になると考えられる。AdaBoost は非線形または区分線形の識別面が作成可能である。
- AdaBoost は各学習ステップで弱識別器が適応的 (Adaptive) に選択される。すなわち前学習ステップまでで識別できなかったデータに注目して次の弱識別器を選択するため、効率的に弱識別器を選択し高性能の強識別器を作成できる。

大石らは、この手法によって重みつけ和による統合手法と比べて精度が向上したことを報告しており、虹彩と目の周辺認証の統合における Boosting 適用の有効性を示した。また、片目だけを認証に利用するのではなく、両目から得られる特徴量をあわせて利用することで精度が向上したことも報告していた。

認証の際に、照合ではスコア空間上で、本人、他人のスコア分布を分ける境界を求め、各点が境界の本人側、他人側のどちらに存在するかで本人か他人かを判定する。識別では、本人・他人の各特徴量のスコアを強識別器に代入し、各人の強識別器の出力値の大小関係に基づき、提示されたデータの人物に最も近い、システム内に登録されたデータの人物を探す。

しかし、大石らは目の周辺認証において、目の周辺の画像全体から一律に特徴量を抽出している。目の周辺には、まぶたや目頭の形など、明らかに個人性が存在する部分があるほか、部位として明確に定義されていない領域にも個人性が存在すると考えられる。そこで、このような目の周辺の個人性を考慮して領域ごとに適切に重みつけをすることで、本人の特徴をより強調した認証を行うことができ、精度が向上する可能性がある。

## 3. 提案手法

### 3.1 領域分割された画像に対する特徴量抽出

本研究では、目の周辺から取得できる情報には領域ごとに個人性が存在すると考え、目の周辺画像全体から一律に特徴量を抽出するだけでなく、たとえば図 1 のように画像




図 1 目の周辺の領域分割

Fig. 1 Region partitioning of periocular image.




図 2 領域分割の粒度 (左: 2 分割 右: 4 分割)

Fig. 2 Granularity of region partitioning.

を領域分割し各領域から特徴量を別々に抽出する。

領域分割の粒度については、図 2 のように、大きく上下、または左右に 2 分割した領域からは大まかに目頭や目じり、上まぶたや下まぶたなどの情報がそれぞれ重点的に得られる。また、4 分割した領域からはさらに狭い範囲だけに注目した情報が得られる。しかし、粗い領域分割にすると個人性の薄い、ノイズとなる情報を多く取り入れてしまう可能性がある。また、細かい領域分割にするとまぶたのような広い範囲にわたる部位を分断してしまう可能性がある。そこで、本手法では複数の粒度の領域分割を行い、それらを組み合わせることで、細かい粒度で分割された領域では得られない特徴を、粗い粒度で分割された領域で得られる特徴で補う。また、粗い粒度で分割された領域では得られない特徴を、細かい粒度で分割された領域で得られる特徴で補う。

また利用する特徴量に関してはそれぞれに特性があり、識別を行う画像によって向き不向きが存在する。これを考慮して、提案手法では LBP や HOG などの複数種類の特徴量を各領域から抽出して利用する。特徴量を使い分けることにより、より細かい部位の質感や形状に着目した特徴を取得することが可能となる。

### 3.2 特徴量の統合手法

3.1 節で説明した領域分割された画像に対する特徴量抽出で得られた特徴量を組み合わせて認証に用いることで、領域ごとの個人性をより考慮した認証が可能となる。

一方で、各粒度の分割で得られた領域ごとに特徴量抽出を行うと、多数の特徴量が取得できる。しかし、それぞれ




図 3 AdaBoost における学習の流れ

Fig. 3 Flow of learning in AdaBoost.




図 4 AdaBoost における識別器の学習

Fig. 4 Learning of classifier in AdaBoost.

の特徴量のスコアを各軸にとったスコア空間において、本人と他人の分布が複雑となり、非線形な境界が必要になるという問題が考えられる。

これをふまえ、本研究では非線形の識別境界を作成できる AdaBoost を用いて、分割領域から得られた多数の特徴量から有効な特徴量を逐次的に選択し統合する手法を提案する。

2.3 節の内容と 3.1, 3.2 節の内容をふまえ、本論文で主張したい点は、目周辺形状の認証には、粒度が異なる特徴抽出領域を設定し、特徴抽出法と特徴抽出領域の組合せを Adaboost を利用することで適応的に選択することである。

### 3.3 AdaBoost の適用方法

以下に、提案法における具体的な AdaBoost の適用方法について記述する。AdaBoost の適用は、下記に記載するフェーズ 1 からフェーズ 3 の順番に行う。AdaBoost は、有効な弱識別器の選択とそれに応じた学習データの重みの更新を行う下記のフェーズ 2 に相当する学習ステップを繰り返すことで、強識別器を作成する。全体の概要と識別器の学習の概要を図 3、図 4 に示す。

#### 【フェーズ 1：学習データの重みの初期化】

AdaBoost では、初期重みは各学習データに対して  $1/(\text{全データ数})$  を重みの値として与えることが一般的である。しかし、本研究で用いるデータでは、本人同士の組合せ数に比べ、本人と他人の組合せ数が非常に多い。このようなデータに対して一様な初期重みを与えた場合、本人同士のデータが重視されない可能性がある。そこで、次のような初期重みを用いる。 $i$  を学習データのインデックスとすると、 $D_1(i)$  は 1 番目の学習ステップにおける  $i$  番目の学習データの重みを表す。




図 5 弱識別器の設計

Fig. 5 Design of weak classifiers.

$$D_1(i) = \begin{cases} \frac{1}{\text{本人のデータ数}} & (i \text{ が本人のインデックス}) \\ \frac{1}{\text{他人のデータ数}} & (i \text{ が他人のインデックス}) \end{cases} \quad (4)$$

最後に、すべてのデータに対する初期重みの和が 1 となるように正規化を行う。

#### 【フェーズ 2：弱識別器の学習】

##### (1) 学習ステップの繰り返し

AdaBoost での弱識別器  $h_t$  ( $t = 1, 2, \dots, t'$ ) を求めるために、 $t = 1$  に対して、以下の (2) から (4) の順に処理を行う。そして、 $t$  の値を 1 増やして同様に以下の (2) から (4) の順に処理を行い、これを  $t$  の値が  $t'$  となるまで繰り返す。つまり、具体的には、 $t'$  回の学習ステップを繰り返すことになり、この  $t'$  は識別の際に用いる弱識別器の数に相当する。

##### (2) 弱識別器の設計と選択

本研究では多数の特徴量が存在することを考慮して図 5 に示す構成とした。これにより、各弱識別器に対応する特徴量を 1 種類だけに限定することで、AdaBoost における「弱識別器の選択」を明確に「特徴量の選択」と対応づけさせることが可能となる。すなわち、個人性が低く有効でない特徴量を避けつつ、1 つ前の学習ステップで選択された特徴量の欠点を補うように各学習ステップで特徴量が選択されていき、効率的な特徴量の統合が可能となる。

具体的には、各学習ステップで特徴量のスコアごとに、学習データの重みを考慮して最適な閾値を求め、その大小関係によって以下の出力をする弱識別器  $h_t$  を作成する。ここの  $t$  とは、その弱識別器が作成された学習ステップのインデックスを表している。

$$h_t = \begin{cases} +1 & (\text{本人と判定したデータ}) \\ -1 & (\text{他人と判定したデータ}) \end{cases} \quad (5)$$

最初の学習ステップ  $t = 1$  では、学習データの初期重みに基づき、誤り率（各学習ステップにおいて誤識別したデータの重みの合計）が最も低い弱識別器を最初を選択される弱識別器  $h_1$  とする。 $t \geq 2$  の学習ステップにおいては下記の (4) の重み更新された重みに基づき、作成された弱



識別器の中から誤り率が最も低い弱識別器  $h_t$  をその学習ステップにおける弱識別器として選択する。

### (3) 弱識別器の学習条件

AdaBoost の各学習ステップにおいて誤識別したデータの重みの合計を誤り率  $\varepsilon$  とする。

弱識別器  $h_t$  の信頼度  $\alpha_t$  は次式で求める。

$$\alpha_t = \frac{1}{2} \log \frac{1 - \varepsilon}{\varepsilon} \quad (6)$$

各学習ステップで選択された弱識別器の信頼度を読み取ることによって、どのような部位に重みがついているのかを分析することができる。

### (4) 学習データの重み更新

AdaBoost では、弱識別器の信頼度（重要度） $\alpha_t$  に基づいて学習データの重みが更新される。本研究では、次の式を用いて重みの更新を行う。

$$D_{t+1}(i) = \begin{cases} D_t(i) \exp(-\alpha_t) & (\text{正照合データ}) \\ D_t(i) \exp(\alpha_t) & (\text{誤照合データ}) \end{cases} \quad (7)$$

ここでの  $t$  は学習ステップのインデックス、 $i$  は学習データのインデックス、 $D_t(i)$  は  $t$  番目の学習ステップにおける  $i$  番目の学習データの重みを表す。最後に、すべてのデータに対する初期重みの和が 1 となるように正規化を行う。

### 【フェーズ 3：強識別器】

最終的に選択された複数の弱識別器を組み合わせることによって強識別器が作成される。この強識別器は（選択された弱識別器の出力） $\times$ （各弱識別器の信頼度）をすべて加算し、識別スコア  $H(x)$  を算出する。以下に式を示す。ここで  $x$  は全入力データのうちの某一データを表す。

$$H(x) = \sum_{t=1}^{t'} \alpha_t h_t(x) \quad (8)$$

## 4. 評価実験

### 4.1 実験概要

本研究における実験概要を学習、テストそれぞれについて、図 6、図 7 に示す。本実験では左目と右目の画像両方から虹彩と目の周辺領域の特徴量を抽出した。また、目の周辺領域の画像を後述する複数種類の粒度で分割し、特徴量を抽出した。

強識別器の学習の際は、学習データを用いて特徴量ごとにスコアを算出し、3.3 節で示したように各特徴量に対応した弱識別器を設計した。その後、AdaBoost のアルゴリズムを用いて学習ステップごとに弱識別器（特徴量）を選択し、最終的に有効な特徴量だけを組み合わせた強識別器を作成した。テストの際には、学習で作成された強識別器とテストデータを用いて認証精度を評価した。最後に、提案手法を従来手法である重み付け和による統合手法と比較した。




図 6 実験概要（学習）

Fig. 6 Outline of experiment (train).




図 7 実験概要（テスト）

Fig. 7 Outline of experiment (test).

### 4.2 前処理

#### ● 目、虹彩の検出

まず虹彩などの特徴を正確に抽出するため、あらかじめ目の周辺領域をある程度絞る必要がある。本研究では、Haar-like 特徴量と呼ばれる明暗の矩形パターンを用いて算出された多数の特徴量を用いて作成した識別器を利用して、目の検出を行った。本実験では、CASIA-Iris-Distance [20] の対象画像に対して、OpenCV [21] で実装されている Haar-like 特徴で学習済みの識別器を用いて左右の目の領域を別々に検出を行った。

#### ● 正規化

ここでは、先行研究である Tan らの手法 [3] を参考に、虹彩の検出に成功した画像に対し正規化を行った。

まず、各画像の虹彩の半径を  $r_{iris}$ 、正規化後の虹彩の半径を  $r_{norm}$  として、

$$S_f = \frac{r_{norm}}{r_{iris}} \quad (9)$$

を求めた。この比率を基に、元画像のサイズを Bicubic 法を用いて縮小し、各画像の虹彩の半径が  $r_{norm}$  となるように正規化を行った。その後、虹彩の中心が画像の中心となるように、画像サイズ  $6r_{norm} \times 4r_{norm}$  で切り出しを行った。

本実験では正規化後の虹彩の半径が  $r_{norm} = 64$  となるように画像を拡張し、画像サイズが  $384 \times 256$  画素となるように切り出した。




図 8 目の周辺画像の分割 (左目)

Fig. 8 Explanation of partition of periocular image (left eye).

表 3 目の周辺認証に使用する特徴量 3 種

Table 3 Three types of features used for periocular authentication.

| 特徴量名 | 特色                |
|------|-------------------|
| LBP  | 照明変化に強い           |
| HOG  | 幾何学変換・照明変化に強い     |
| SIFT | 回転・スケール変化・照明変化に強い |

#### ● 画像の分割

図 8 に本実験における画像分割の例を示す。図 8 の (a) は分割を行っていない元画像である。(b) は横方向に 2 分割、(c) は縦方向に 2 分割、(d) は縦横にそれぞれ 2 分割をした画像となっている。

### 4.3 虹彩認証

今回は、OSIRIS version 4.1 [22] と呼ばれる Daugman の虹彩認証アルゴリズムを実装したソフトウェアを用いて実験を行った。前処理で虹彩周辺を切り出した画像から、特徴量として Iriscode を抽出した。その後、Iriscode どのようなハミング距離をスコアとして算出した。

また、前処理で作成された分割画像からは完全な虹彩画像が得られないため、虹彩認証に関しては分割前の元画像のみを用いて認証した。

### 4.4 目の周辺認証

本研究では、多くの先行研究で用いられている 3 種類の特徴量を使用した。表 3 にそれぞれの特徴量とその特徴を示す。

それぞれの画像特徴量抽出は OpenCV [21] で実装されているプログラムを用いて行った。また、本実験ではそれぞれのスコアとして、LBP 特徴量は各画像から算出した 768 次元の特徴ベクトル間のマンハッタン距離を、HOG 特徴量は、算出した 4,860 次元の特徴ベクトル間のマンハッタン距離を求めた。

また SIFT 特徴量に関しては、画像間の対応点が多いほど類似性が高く、また対応点間の距離が近いほど類似性が

高いと考えられる。そこで以下の式を用いてスコアを算出した。

$$S = N * \frac{1}{\frac{\sum_{j=1}^N d_j}{N}} \quad (10)$$

ここで、 $S$  は SIFT 特徴量のスコアを、 $N$  は画像間の対応点の数、 $d_j$  は画像間の  $j$  番目の対応点間の距離を表している。

### 4.5 統合手法

#### 4.5.1 重みつけ和

本実験において、 $F$  種類の特徴量の重みつけ和による統合スコア  $S$  は以下のように算出した (4 種類の特徴量を統合する場合は  $F = 4$ 、8 種類の特徴量を統合する場合は  $F = 8$  である)。ただし、 $f$  個目の特徴量に対する特徴量の重みとスコアをそれぞれ  $\omega_f$ 、 $S_f$  とする。

$$S = \omega_1 S_1 + \omega_2 S_2 + \cdots + \omega_F S_F$$

$$\omega_1 + \omega_2 + \cdots + \omega_F = 1 \quad (11)$$

$\omega_1 + \omega_2 + \cdots + \omega_F = 1$  の条件の下で、 $0 \leq \omega_f \leq 1.0$  の範囲で、各特徴量に対するスコアの重み  $\omega_1, \omega_2, \dots, \omega_F$  をそれぞれ 0.1 刻みで変更して重みの組合せを探索し、訓練誤差 (EER (Equal Error Rate)) が最も低くなる重みの組合せを利用した。

#### 4.5.2 AdaBoost

本実験では、強識別器の作成に用いる学習ステップ回数 (弱識別器の個数) は最大 100 個とした。最終的に訓練誤差 (EER) が最も低くなる個数を強識別器として利用した。

### 4.6 実験の組合せ

表 4 に実験で利用する目の種類 (片目/両目) と使用画像 (分割画像) の組合せ、特徴量の数、スコア統合手法についてまとめる。使用する画像として記述している (a) から (d) のラベルは図 8 と対応している。実験 1 は 2.3 節で述べた重みつけ和による先行研究の手法であり、実験 2 はその拡張である。実験 3 と 4 は大石らによる AdaBoost を用いた先行研究の手法である。

表 4 における領域特徴量とは、各領域から抽出された特徴量の総数を指す。例として実験 9 では、片目の領域分割によって得られた画像数が元画像を含めて (元画像の 1 枚) + ((b) の 2 枚) + ((c) の 2 枚) + ((d) の 4 枚) = 9 枚あり、虹彩認証の特徴量である Iriscode は元画像からのみ抽出することを考慮すると、 $4 \times 1$  (元画像 (1 枚) から Iriscode, LBP, HOG, SIFT を抽出) +  $3 \times 8$  (残りの分割画像 (8 枚) から LBP, HOG, SIFT を抽出) = 28 個の領域特徴量が取得できる。また、実験 10 では両目の領域分割によって得られた画像から特徴量を抽出するため、 $28 \times 2$  (両目分) = 56 個の領域特徴量が取得できる。



表 4 分割画像の組合せと特徴量数, 統合手法

Table 4 Combination of divided images and number of features, Integration method.

| 実験番号 | 使用する目 | 使用する画像<br>(分割画像) | 領域<br>特徴量 | スコア<br>統合手法 |
|------|-------|------------------|-----------|-------------|
| 1    | 片目    | (a)              | 4         | 重みつけ和       |
| 2    | 両目    | (a)              | 8         | 重みつけ和       |
| 3    | 片目    | (a)              | 4         | AdaBoost    |
| 4    | 両目    | (a)              | 8         | AdaBoost    |
| 5    | 片目    | (a)+(b)+(c)      | 16        | AdaBoost    |
| 6    | 両目    | (a)+(b)+(c)      | 32        | AdaBoost    |
| 7    | 片目    | (a)+(d)          | 16        | AdaBoost    |
| 8    | 両目    | (a)+(d)          | 32        | AdaBoost    |
| 9    | 片目    | (a)+(b)+(c)+(d)  | 28        | AdaBoost    |
| 10   | 両目    | (a)+(b)+(c)+(d)  | 56        | AdaBoost    |

#### 4.7 データセット

本研究では, データセット CASIA-Iris-Distance を用いて実験を行った.

このデータセットは, 近赤外線カメラを用いて 2.4m から 3.0m の距離で顔領域を撮影した画像で構成されている. 今回は収録されている眼鏡をかけていない被験者 122 人の画像から 1 人あたり 8 枚 (学習データ: 4 枚, テストデータ: 4 枚) を利用した.

#### 4.8 評価手法

実験結果に対し, ROC (Receiver Operating Characteristic) カーブ, EER, CMC (Cumulative Match Characteristic) カーブ, 識別率を用いて精度評価を行った. ROC カーブは, 各軸に FRR (False Rejection Rate: 本人を誤って拒否する割合), FAR (False Acceptance Rate: 他人を誤って受け入れる割合) の 2 つの指標をとる. ROC カーブは原点側に寄っている曲線を描くほど精度が高い評価指標である. また, FAR と FRR が等しくなったときの値を EER と呼ぶ. CMC カーブは, 強識別器が出力する本人同士のスコアが上位何番目までに出現するかを表したカーブである. CMC カーブは全体的に上側に寄っている曲線を描くほど精度が高い評価指標である. また, 識別率とは, 本人同士のスコアが最も高くなっているパターンの割合のことである.

また, 本実験では試行回数を増やすためにクロスバリデーションを行った. 具体的には 1 人あたり 8 枚の画像から学習データ 4 枚テストデータ 4 枚を選択するパターン数 ( ${}_8C_4 = 70$  回) の試行を行い, 各パターンにおいて照合の組合せ総数は  ${}_{488}C_2 = 118,828$  通り (本人同士:  ${}_{4}C_2 \times 122 = 732$  通り, 他人同士: 118,096 通り) である. 今回の実験における評価は各試行の結果を平均化して算出した.

表 5 組合せごとの EER と識別率

Table 5 EER and identification rate for each combination.

| 番号 | 領域特徴量 | EER (%) |       | 識別率 (%) |       |
|----|-------|---------|-------|---------|-------|
|    |       | 左 (L)   | 右 (R) | 左 (L)   | 右 (R) |
| 1  | 4     | 2.28    | 2.29  | 91.9    | 90.2  |
| 2  | 8     | 1.60    |       | 94.6    |       |
| 3  | 4     | 2.28    | 2.01  | 89.2    | 88.9  |
| 4  | 8     | 1.41    |       | 93.9    |       |
| 5  | 16    | 1.37    | 1.45  | 93.8    | 92.7  |
| 6  | 32    | 0.86    |       | 96.6    |       |
| 7  | 16    | 1.55    | 1.52  | 92.9    | 92.8  |
| 8  | 32    | 1.02    |       | 96.0    |       |
| 9  | 28    | 1.23    | 1.15  | 94.8    | 93.7  |
| 10 | 56    | 0.70    |       | 97.4    |       |

## 5. 結果

虹彩と目の周辺認証の組合せにおいて, 分割画像から得られた特徴量を AdaBoost を用いて統合することの有効性を示すため, 検証を行った.

表 5 に 4.5 節で示した各実験番号に対応した EER と識別率の表を示す.

先行研究とその拡張手法である番号 1–4 と領域分割を利用した提案手法である番号 5–10 を比較すると, 全体として提案手法が片目だけを利用したパターン, また両目を利用したパターンどちらにおいても EER, 識別率ともに上回っていることが確認できる. たとえば, 実験 6, 8, 10 の EER と識別率は, 実験 2 の EER と識別率より良い結果である. 実験 6, 8, 10 は, 両目から図 8 に示すような分割画像を取得し, 各分割画像から得られた特徴量に対するスコアを AdaBoost を用いて組み合わせた実験である. 実験 2 は先行研究の手法として, 分割していない両目画像から得られた特徴量に対するスコアを重みつけ和で組み合わせた実験である. 特に, 両目から得られる (a)–(d) の画像をすべて利用した実験 10 が EER が 0.70%, 識別率が 97.4% と番号 1–10 の組合せにおいて最も高い精度となった.

また, 図 9, 図 10 に各実験番号に対応した ROC カーブ, CMC カーブを示した.

ROC カーブにおいて, 表 5 に示したとおり EER 付近の値は実験 10 をはじめとした提案手法による結果が最も良いことが確認できる. 実験 10 の曲線はつねに最も原点寄りに位置しており, 強識別器のスコアに対する閾値を変化させていった際にも, 従来手法と比較して高い性能を有していることが分かる.

CMC カーブにおいても, 実験 10 の曲線が上部に位置しており, 提案手法により本人同士のスコアがより高い値になるような強識別器を作成できていることを示した.




図 9 ROC カーブ

Fig. 9 ROC curve.




図 10 CMC カーブ

Fig. 10 CMC curve.

## 6. 考察

5章において表4の実験10がすべての評価指標で最良の結果となった。この結果をふまえ、領域分割して得られた特徴量のスコアを統合することの有効性に関して考察する。

ここでは、以下の2点に関して分析を行う。

- 強識別器の作成に利用された領域と特徴量の傾向
- 識別可能となった画像の一例

### 6.1 強識別器の作成に利用された領域と特徴量

AdaBoostでは前述したとおり、各学習ステップにおいて前ステップで識別できなかったデータを識別できるように弱識別器(特徴量)が選択されていく。ここで、どのような領域の特徴量がどのような順序で選択されているのか、またそれに付随してEERがどのように変化しているのか

表 6 実験10で選択された弱識別器

Table 6 The weak classifier selected in Experiment 10.

| 順位 | 目 (L/R) | 領域     | 特徴量          |
|----|---------|--------|--------------|
| 1  | R       | (c-下)  | SIFT         |
| 2  | L       | (b-右)  | HOG          |
| 3  | L       | (c-下)  | SIFT         |
| 4  | L       | (c-上)  | SIFT         |
| 5  | R       | (a)    | Iriscode(虹彩) |
| 6  | L       | (b-左)  | SIFT         |
| 7  | R       | (a)    | SIFT         |
| 8  | L       | (d-左下) | SIFT         |
| 9  | R       | (d-左下) | HOG          |
| 10 | L       | (d-右上) | SIFT         |
| 11 | R       | (d-左下) | LBP          |
| 12 | R       | (d-右下) | SIFT         |
| 13 | R       | (d-左上) | LBP          |
| 14 | R       | (d-左下) | SIFT         |
| 15 | R       | (c-上)  | SIFT         |




図 11 弱識別器の個数と訓練誤差 (EER)

Fig. 11 Number of weak classifiers and training error (EER).

を分析した。今回の実験精度が最良であった実験10について各学習ステップで選択された弱識別器(特徴量)15個とそれに対応した弱識別器(特徴量)の個数とEERの関係を示したグラフの一例を表6と図11に示した。

- 選択されている分割領域の傾向

表6より、前半の順位に選択されている領域が図8の(a)–(c)に示したような広い領域となっており、後半の順位に選択されている領域は(d)のような狭い領域となっていることが確認できる。また、図11より、実験10のEERは全体的に減少傾向にあるが、前半ではEERが大きく下がり、後半へ向かうにつれてその減少量は少なくなっていることが分かる。これより、より広い領域の情報は大きな識別の軸となっており、細かい領域の情報がその精度を補う役割を持っていると考えられる。一方で(a)のみを用いて特徴量の抽出、統合を行った実験4は実験10と比較してEERの減少が遅くなっていることが確認できる。また、弱識別器が15個のときのEERの値に関しては、実験4よりも実験10のほうが小さい値である。これは弱識

表 7 実験 4 で選択された弱識別器

Table 7 The weak classifier selected in Experiment 4.

| 順位 | 目 (L/R) | 特徴量           |
|----|---------|---------------|
| 1  | R       | SIFT          |
| 2  | L       | Iriscode (虹彩) |
| 3  | R       | HOG           |
| 4  | R       | Iriscode (虹彩) |
| 5  | L       | SIFT          |
| 6  | L       | SIFT          |
| 7  | L       | LBP           |
| 8  | L       | Iriscode (虹彩) |
| 9  | L       | Iriscode (虹彩) |
| 10 | L       | HOG           |
| 11 | R       | Iriscode (虹彩) |
| 12 | R       | HOG           |
| 13 | L       | SIFT          |
| 14 | R       | LBP           |
| 15 | L       | Iriscode (虹彩) |

別器の個数を増やしても細かい領域の情報を利用できないためであると考えられ、ここにおいても領域分割を利用することの有効性が確認できる。

- 選択されている特徴量の傾向

表 6 より、選択されている特徴量としては大部分が SIFT 特徴量であるが、図 11 の実験 10 の EER より、その他の特徴量が選択された際にも EER が低下していることが確認できる。たとえば、2 個目に HOG 特徴量が選択された際に 5 個目 Iriscode が選択された際に EER が明確に減少していることが確認できる。これより、領域分割によって得られた分割画像から LBP, HOG, SIFT などの複数種類の画像特徴量を抽出することは有効であると考えられる。

- 選択済み特徴量の再選択

今回の評価実験で、AdaBoost による特徴量の選択では、重みが異なる選択済みの特徴量を再選択することを可能としている。実験 4 で選択された弱識別器を表 7 に示す。表 7 より、左目の SIFT が順位 5 と順位 6 で選ばれていることが分かる。このときの EER の値について見てみると、図 11 の実験 4 の EER において、弱識別器の個数が 5, 6 付近においても EER の減少が続いており、この選択は有効であることが分かる。左目の SIFT 特徴量のスコアのヒストグラムに順位 5 と順位 6 の弱識別器の閾値を記載した図を図 12 に示す。横軸がスコアで、縦軸が各スコアの出現頻度の割合を表しており、本人のスコアと他人のスコアを表示している。この図を見ると、順位 5 の弱識別器は、本人を正しく本人と判別するような閾値となっていることが分かる。一方、順位 6 の弱識別器は、順位 5 の弱識別器で誤判別した他人を正しく他人と判別するような閾値となっている。このように、前の弱識別器で誤




図 12 左目 SIFT 特徴量のスコアと弱識別器の閾値の関係

Fig. 12 Scores of left eye's SIFT and weak classifier.

判別した人物を正しく判別するように動作しており、重みが異なる選択済みの特徴量を再選択することは有効であると考えられる。

## 6.2 識別可能となった画像の一例

従来手法で識別できず、提案手法で正しく本人であると識別できた人物の目画像の実例を図 13 に示す。画像 (a) は表 6 で示した弱識別器を選択するために用いた学習データの一部である。また、画像 (b) は、性能を評価するために用いたテストデータの一部である。画像 (a) と画像 (b) は同一人物の目画像であり、図 13(a) の学習データに対応したテストデータが図 13(b) である。

学習データとして利用した画像 (a) のように目の開き具合が変化すると、同一人物の画像であっても目全体の形状が変化する。このため、画像全体から一律に特徴量を抽出している従来手法では、個人の特徴をとらえることが難しくなる。これに対して提案手法では、表 6 から確認できるように、目の下部の特徴を重視した識別を行う。目の下部は、まばたきなどを行っても比較的形状が変化しない。粒度が異なる特徴抽出領域を設定し、それらの分割画像を適応的に選択して利用することで、目形状の変化に比較的ロバストな部位の特徴を反映した強識別器を作成できたと考えられる。テストデータに着目すると、画像 (a) とは目の開き具合が異なるテストデータ画像 (b) に対して、従来手法では、この画像を他人と誤判定していた。一方、提案手法では目形状の変化に比較的ロバストな部位の特徴を利用しているため、正しく本人と判定していると考えられる。

## 7. 結論と課題

本研究では、両目の虹彩、目の周辺とその分割画像から得られる特徴量それぞれを AdaBoost を用いて統合する手法を提案した。EER, 識別率などを用いた評価実験の結果、従来手法と比較して精度が向上し、異なる粒度の領域から得られる特徴量を組み合わせることで、さらに精度が






図 13 識別可能となった画像

Fig. 13 Images that became identifiable.

向上することを示した。

今後の課題としては、今回はまぶたをほぼ閉じている画像や眼鏡を装着している画像を実験対象としなかったが、実用性を考慮してより多様な環境下においても運用できる手法の検討をすることがあげられる。また、他のデータセットを用いた性能評価を引き続き行っていく。

謝辞 本研究は JSPS 科研費 16K18103 の助成を受けたものです。

## 参考文献

- [1] 梅岡良行, 金子直史, 斉藤友彦, 鷺見和彦: 虹彩認証における画像解像度と認証精度の関係, 信学技報 IEICE Technical Report BioX2014-5 (2014).
- [2] Woodard, D.L., Pundlik, S. and Miller, P.: On the Fusion of Periocular and Iris Biometrics in Non-ideal Imagery, *International Conference on Pattern Recognition* (2010).
- [3] Tan, C.W. and Kumar, A.: Human identification from at-a-distance images by simultaneously exploiting iris and periocular features, *International Conference on Pattern Recognition* (2012).
- [4] 大石真太郎, 白川功浩, 市野将嗣, 吉浦 裕: 利用者の負担軽減に向けた両目の虹彩及びその周辺画像による認証方式, コンピュータセキュリティシンポジウム 2016 論文集 (2016).
- [5] バイオメトリクスセキュリティコンソーシアム: バイオメトリクスセキュリティハンドブック, オーム社 (2005).
- [6] Daugman, J.: How iris recognition works, *IEEE Circuits and Systems for Video Technology* (2004).
- [7] Park, U., Jillela, R., Ross, A. and Jain, A.: Periocular Biometrics in the visible spectrum, *IEEE Trans. Information Forensics and Security* (2011).
- [8] Sambit, B., Pankaj, K. and Banshidhar, M.: A novel phase-intensive local pattern for periocular recognition under visible spectrum, *Biocybernetics and Biomedical Engineering* (2015).
- [9] Ojala, T., Pietikainen, M. and Harwood, D.: A comparative study on texture measures with classification based on featured distributions, *Pattern Recognition* (1996).
- [10] Navneet, D. and Triggs, B.: Histograms of oriented gradients for human detection, *Computer Vision and Pattern Recognition* (2005).
- [11] Lowe, D.G.: Distinctive Image Features from Scale-Invariant Keypoints, *International Journal of Computer*

*Vision*, Vol.60 (2004).

- [12] Tan, T., Zhang, X., Sun, Z. and Zhang, H.: Noisy iris image matching by using multiple cues, *Pattern Recognition Letters* (2012).
- [13] Raghavendra, R., Raja, K., Yang, B. and Busch, C.: Combining iris and periocular recognition using light field camera, *Asian Conference on Pattern Recognition* (2013).
- [14] Raja, K.B., Raghavendra, R. and Busch, C.: Binarized statistical features for improved iris and periocular recognition in visible spectrum, *International Workshop on Biometrics and Forensics* (2014).
- [15] Ahmed, N.U., Cvetkovic, S., Siddiqi, E.H., Nikiforov, A. and Nikiforov, I.: Combining iris and periocular biometric for matching visible spectrum eye images, *Pattern Recognition Letters* (2017).
- [16] Mikaelian, A., Alonso-Fernandez, F. and Bigun, J.: Periocular recognition by detection of local symmetry patterns, *Workshop Insight on Eye Biometrics* (2014).
- [17] Ahuja, K., Islam, R., Barbhuiyaa, F.A. and Dey, K.: Convolutional neural networks for ocular smartphone-based biometrics, *Pattern Recognition Letters* (2017).
- [18] Santos, G. and Hoyle, E.: A fusion approach to unconstrained iris recognition, *Pattern Recognition* (2012).
- [19] Joshi, A., Gangwar, A. and Saquib, Z.: Person recognition based on fusion of iris and periocular biometrics, *International Conference on Hybrid Intelligent Systems* (2012).
- [20] CASIA Iris Image Dataset v4.0, available from <http://biometrics.idealtest.org/>.
- [21] OpenCV, available from <http://opencv.jp>.
- [22] OSIRIS version 4.1, available from <http://svnext.it-sudparis.eu/>.



白川 功浩

2016 年電気通信大学情報理工学部総合情報学科卒業。2018 年同大学大学院情報理工学研究科情報学専攻博士前期課程修了。バイオメトリクスに関する研究に従事。



吉浦 裕 (正会員)

1981 年東京大学理学部情報科学科卒業。日立製作所を経て、2003 年より電気通信大学勤務。現在、情報理工学研究科教授。情報セキュリティ、プライバシー保護の研究に従事。博士（理学）。

日立製作所社長技術賞（2000 年）、情報処理学会論文賞（2005 年、2011 年）、システム制御情報学会産業技術賞（2005 年）、IEEE IHH-MSP best paper award（2006 年）、日本セキュリティ・マネジメント学会論文賞（2010 年、2016 年、2017 年）、IFIP I3E best paper award（2016 年）等受賞。電子情報通信学会、日本セキュリティ・マネジメント学会、人工知能学会、システム制御情報学会、IEEE 各会員。本会フェロー。



市野 将嗣 (正会員)

2003 年早稲田大学理工学部電子・情報通信学科卒業。2008 年同大学大学院理工学研究科博士課程修了。2007 年日本学術振興会特別研究員。2009 年早大大学院基幹理工学研究科研究助手。2010 年同大メディアネットワーク

センター助手。2011 年電気通信大学大学院情報理工学研究科助教。2016 年同大学院情報理工学研究科准教授。バイオメトリクス、ネットワークセキュリティに関する研究に従事。博士（工学）。電子情報通信学会会員。