

# XGBoostによる複数特徴量を用いた虹彩と目の周辺と強膜の個人認証

上野山 大介<sup>1,a)</sup> 吉浦 裕<sup>1</sup> 市野 将嗣<sup>1</sup>

受付日 2019年11月23日, 採録日 2020年6月1日

**概要:** 近年, 精度が高いことで注目されている虹彩認証は, 認証の際, 虹彩の模様が鮮明に写るように被認証者はカメラに近づき, カメラを見て, 高解像度の虹彩画像を取得する必要がある. 認証のたびに被認証者はカメラに近づかなければならないことが被認証者の負担となる. この負担を軽減する方法として, 虹彩と目の周辺を遠距離から撮影し, 認証を行う方式が提案されている. しかし先行研究では, 数多くある画像特徴量のうち, どの特徴量が認証に適しているかの十分な検討が行われていないため, 重要な特徴量を適切に利用できておらず, 本来実現可能な精度を実現できていない. また, 虹彩と同時に取得可能な強膜領域を目の周辺の一部として使用している. つまり, 強膜領域の個人性を有効に利用している既存研究は, 著者の調べた範囲では存在しない. そこで本研究では, 遠距離における虹彩認証の認証精度を向上させるために, XGBoostによる多くの特徴量を用いた虹彩と目の周辺と強膜のマルチモーダルバイオメトリック認証の手法を提案した. 評価実験の結果, 先行研究で用いられた手法よりも良い精度を示し, 提案手法の有効性を示した.

**キーワード:** バイオメトリクス, 虹彩認証, 目の周辺認証, 強膜認証, XGBoost

## Personal Authentication of Iris, Periocular and Sclera Recognition Using XGBoost

DAISUKE UENOYAMA<sup>1,a)</sup> HIROSHI YOSHIURA<sup>1</sup> MASATSUGU ICHINO<sup>1</sup>

Received: November 23, 2019, Accepted: June 1, 2020

**Abstract:** Iris biometrics has a very high level of accuracy. However, it requires a high-quality iris image, which means that the person being identified must closely approach the camera, which is highly intrusive on the person being identified and increases the burden and limits the action of users. A less intrusive approach would be to capture iris images with identification equipment situated further away, but this is liable to result in poor-quality images and lower identification accuracy. Images of the iris and the region surrounding the eye are obtained simultaneously from a greater distance, and periocular biometrics is used to compensate for the loss of iris biometrics accuracy that results from acquiring images from a greater distance. In previous study, a method that combines iris biometrics with periocular biometrics has been proposed. However, the sclera region is not used for identification effectively in previous studies because the sclera region is used as part of periocular region. Moreover, effective features have not been used for identification and previous studies do not achieve feasible accuracy because the features are not evaluated sufficiently. Therefore, we proposed using more features (more image features and sclera region) and the XGBoost algorithm to fuse the scores.

**Keywords:** biometrics, iris authentication, periocular authentication, sclera authentication, XGBoost

### 1. はじめに

近年, 携帯端末や銀行 ATM など多くの場面で, 安全性・利便性の高い個人認証が必要となっている. 現在用いられ

<sup>1</sup> 電気通信大学  
The University of Electro-Communications, Chofu, Tokyo  
182-8585, Japan  
<sup>a)</sup> d-uenoyama@uec.ac.jp

ている個人認証の方式は「所有物による認証」, 「知識による認証」, 「バイオメトリクスによる認証」の3種類に分類することができる。なかでも, バイオメトリック認証は鍵やカードを紛失することがない, 暗号やパスワードなどの記憶が不要であるため, 他の認証方式と比べて利便性の高い認証方式である。またバイオメトリック認証は偽造やなりすましが難しいという利点もあり, 安全性の高い認証方式である。

バイオメトリック認証の中でも, 虹彩認証は他の生体情報を用いた認証方式よりも精度が高い認証方式であるため注目されている。しかし, 虹彩認証の際には虹彩の様子が鮮明に写るように被認証者はカメラに近づき, カメラのレンズを見て, 高品質の虹彩画像を取得する必要がある。この認証のたびに被認証者はカメラに近づかなければならないことが被認証者の負担となる。この負担を軽減する方法として, 被認証者がカメラに近づかず, 認証機器から離れた位置で撮影を行う方法が考えられる。しかし, この方法では画質が劣化し, 認証精度が低下することが報告されている。

この問題に対し, 虹彩以外の部位を組み合わせる認証を行う方式がある [1], [2], [3]。先行研究では虹彩に加えて, 目の周辺も同時に用いる手法が提案されている。目の周辺は虹彩と近い位置に存在するため, 1度の撮影で取得することが可能である。目の周辺も同時に用いることで, 遠距離撮影による虹彩認証の精度劣化を補うことができ, トータルとして近距離での認証と同等の精度を実現できるため, 同等の精度での遠距離からの認証が実現できる。

また, 可視光画像を用いた虹彩認証では, 目の周辺領域を組み合わせるだけでなく, 強膜領域も組み合わせる認証を行う方式も提案されている。Dasら [4]は強膜領域も虹彩と同時に取得可能であり, 組み合わせることでさらなる認証精度の向上を報告した。

しかしこれらの先行研究では, 数多くある画像特徴量のうち, どの特徴量が認証に適しているかの十分な検討が行われていないため, 重要な特徴量を適切に利用できておらず, 本来実現可能な精度を実現できていない。また, 現在多くの場所で用いられている虹彩認証は近赤外画像を用い

たものであるが, 近赤外画像を用いた強膜領域の個人性を有効に利用できていない。先行研究 [3] で用いられているAdaBoostは外れ値に弱いBoosting手法であるため, 外れ値が含まれる可能性がある遠距離での認証に用いると認証精度が低下する可能性がある。

そこで本研究では, 遠距離でのマルチモーダルバイオメトリック認証の認証精度を向上させるために, 複数の特徴量をXGBoostで統合する手法を提案する。

## 2. 関連研究

### 2.1 虹彩と目の周辺を組み合わせる認証

虹彩認証は非常に精度の高い認証である一方, 遠距離で撮影した画像を用いた場合では認証精度が下がるため, 被認証者は認証機器に近づく必要があり, 利便性が低くなる。また目の周辺認証に関しては, 遠距離から撮影した画像でも認証を行うことができるという利点がある一方, 目の開き具合や表情変化にともなった目の動きによって生じる変形によって精度が低下する。

これらの問題に対して, 虹彩と目の周辺の2つを組み合わせることで, 2つの認証の精度の不足を補う方式が提案されている。表1に虹彩と目の周辺を組み合わせる認証の先行研究を示す。

先行研究の多くでは重みつけ和による統合を行っている。重みつけ和とは, 虹彩認証と目の周辺認証の類似度スコアに対して正規化を行った後, 以下の式により照合スコアを算出する手法である。

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

$$\omega_1 + \omega_2 = 1 \quad (2)$$

ここで,  $S_{iris}$  は虹彩認証の類似度スコア,  $S_{periocular}$  は目の周辺認証の類似度スコア,  $\omega_1, \omega_2$  はそれぞれのスコアに付与する重みである。Woodardら [1]は目の周辺領域から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。これらの特徴量を重みつけ和を用いて統合した。Tanら [2]は目の周辺領域からLBP, HOG, SIFTとLMF特徴量を抽出し, 虹彩領域からLog-Gaborフィルタを用いて特徴量を抽出した。

表1 虹彩と目の周辺認証の統合

Table 1 Combinations of iris and periocular authentication.

論文著者	データセット	虹彩特徴量	目の周辺特徴量	統合手法
Woodard [1]	MBGC	Gabor	LBP	重みつけ和
Tan [2]	UBIRIS.v2, FEGC, CASIA v4-distance	Log Gabor	LBP, HOG, SIFT, LMF	重みつけ和
Raja [5]	自作データセット	BSIF+SRC	BSIF+SRC	重みつけ和
Ahuja [6]	MICHE II, VISOB	CNN, SIFT	CNN	重みつけ和
Raghavendra [7]	自作データセット	LBP+SRC	LBP+SRC	重みづけ和
Ahmed [8]	MICHE II	1D Log-Gabor	MB-TLBP	重みつけ和
Raffei [9]	UBIRIS.v2, UBIPr	1D Log-Gabor	RIULBP	重みつけ和
大石ら [3]	CASIA v4-distance	Daugman	LBP, HOG, SIFT	AdaBoost

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る。Rajaら [5] 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つけ和で統合した。Ahujaら [6] は Convolutional Neural Network (CNN) を用いて目の周辺領域と虹彩領域から特徴抽出を行い、各スコアを算出し、重みつけ和を用いて統合した。Raghavendraら [7] は目の周辺領域から得られた 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、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つけ和で組み合わせる。Ahmedら [8] は目の周辺領域から MB-TLBP 特徴量、虹彩領域から 1D Log-Gabor を用いて特徴量を抽出し、各スコアを重みつけ和で統合した。Raffeiら [9] は目の周辺領域から RIULBP 特徴量、虹彩領域から 1D Log-Gabor を用いて特徴量を抽出し、各スコアを重みつけ和で統合した。しかし、これらの重みつけ和による統合はスコア空間において識別境界が線形となるため、スコア分布が複雑である場合、本人と他人の判定を誤る可能性が高い。また、組み合わせる特徴に有効でないものが含まれると精度が低下する可能性がある。

大石ら [3] は虹彩認証と目の周辺認証の統合手法に、Boosting の代表的手法である AdaBoost を用いる方法を提案した。Boosting は逐次的に学習データの重みを変化させながら複数の弱識別器で学習し、それらを統合した識別器 (強識別器) で最終的な識別をする手法である。この手法を用いる利点が 2 つある。

- 様々な特徴量を組み合わせる場合、特徴空間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となると考えられる。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することができる。

大石らは AdaBoost による統合が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、虹彩と目の周辺認証の統合における Boosting の有効性を示した。この AdaBoost は誤分類したデータの重みを重くすることで、弱識別器の学習において以前までで誤分類したデータを次の学習で重点的に行う。そのため、外れ値が含まれるデータを用いるとその外れ値を重点的に学習してしまい、適切な識別境界面が作成できなくなる。本研究で行う遠距離のマルチモーダルバイオメトリック認証の場合、遠距離で撮影したことによる画質の低下や光などのノイズが発生し、外れ値を多く含む恐れがあり、外れ値に弱い AdaBoost を

用いると誤りが多くなる可能性がある。

## 2.2 強膜認証

強膜認証とは人間の強膜の領域を用いて認証を行う方式である。強膜領域の血管構造は各個人に固有のものであり、加齢による劣化も少なく、個人認証に用いるのに適している。可視光を用いて撮影することで取得することが可能であり、虹彩領域が使用できないときに用いられる認証の 1 つとしてあげられている。

強膜認証は血管パターンを用いる方法と画像特徴量を用いる方法がある。Zhouら [10] は虹彩から血管の分岐までの距離と角度、分岐の角度の 3 つの値を特徴量として用いた。その結果、可視光画像の強膜だけを用いた認証が虹彩認証と同等以上の精度を示し、強膜認証が生体認証に有効であることを示した。

Dasら [11] は LDP・SIFT・LBP の 3 つの画像特徴量を特徴量として用いた。これらの特徴抽出によって得た値と登録しているパターンのハミング距離を求め、この値がしきい値以下であれば本人、しきい値以上であれば他人と判定する。Dasら [4] は可視光画像を用いた虹彩と目の周辺、強膜の 3 つの部位を組み合わせる認証を提案した。各部位を個別に前処理し、センサレベルでの部位の統合、および、各部位から取得した特徴とそれらを組み合わせる特徴を特徴レベルでの統合を行い、SVM で学習した後、それぞれで分類を行った。それらを SVM の事後確率に基づいた統合を行い、最終的な分類をした。その結果、提案手法が問題に応じて最適な部位および統合の組合せを選択することを示した。

現在多くのところで使用されている虹彩認証は近赤外画像を用いたものであるが、近赤外画像における強膜領域のみに注目し、そこにどれくらいの個人性が含まれているかを調査した既存研究は、著者の調べた範囲では存在しない。

## 2.3 分割画像を用いた認証

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。目の周辺には目頭や目尻、まぶたなど、明らかに個人性が存在するほか、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、白川ら [12] は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、画像の領域分割を行い、各領域からそれぞれ特徴量を別々に抽出した。

分割の方法として、大まかに目頭や目尻、上まぶたや下まぶたなどの情報を重点的に得るために、大きく上下、または左右に 2 分割をした。また、さらに狭い範囲だけに注目するために、4 分割をした画像からも特徴量を抽出した。しかし、広い領域分割にすると本人データから取得される特徴量の値と他人データから取得される特徴量の値との差が小さくなり、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。一方、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恐れがある。そこで、複数の領域分割を組み合わせることで、広い領域分割から得られない情報を細かい領域分割から得られる情報で補う。また、細かい領域分割から得られない情報を広い領域分割から得られる情報で補う。

その結果、従来手法と比較して精度が向上したことを示した。また、複数の領域分割を組み合わせることで、さらに精度が向上することも示した。

### 3. 提案手法

本研究の提案手法は複数特徴量を用いた認証と XGBoost を用いた特徴量の統合で構成される。それらの詳細を以下に示す。

#### 3.1 複数特徴量を用いた認証

先行研究では、数多くある画像特徴量 (LBP, HOG, SIFT など) のうち3つ程度しか使用しておらず、それ以上の画像特徴量を使用する検討がされていない。そのため、重要な特徴量を適切に利用できておらず、本来実現可能な精度を実現できていない。利用する特徴量にはそれぞれ特性があり、識別を行う画像によって向き不向きが存在する。そのため、識別に有効な特徴量を選択することで、さらに精度を向上させることが可能である。また、近赤外画像を用いた認証の際、虹彩および目の周辺と同時に取得可能な強膜領域を目の周辺領域の一部として使用している、つまり、強膜の個人性を有効に利用している既存研究は、著者の調べた範囲では存在しない。

そこで本研究では、目の周辺認証に用いられる画像特徴量をさらに加えること、および、虹彩と目の周辺認証に強膜認証を加えることで、マルチモーダルバイオメトリック認証の認証精度向上を目指す。また、得られた複数の特徴量から有効な特徴量を自動的に選択することで、さらなる認証精度向上を目指す。

#### 3.2 XGBoost を用いた特徴量の統合

##### 3.2.1 XGBoost の適用方法の概要

本研究では、虹彩認証と目の周辺認証と強膜認証の統合手法に、近年様々なところで有効性を示している XGBoost [13] を用いる。虹彩認証と目の周辺認証の統合に XGBoost を用いる利点を以下に示す。

- (1) XGBoost は弱識別器として決定木を用いているため、特徴量空間上における外れ値に対する堅牢性が高いアルゴリズムである [14]。
- (2) 虹彩認証と目の周辺認証と強膜認証の統合では、数多くの特徴量を用いて認証することが考えられる。XGBoost を用いることで、それらの特徴量の中から自動的に有効な特徴量を選択することが可能である。

- (3) 様々な特徴量を組み合わせる場合、特徴空間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となると考えられる。XGBoost は非線形または区分線形の識別面が作成可能である。

- (4) 弱識別器の個数によって認証精度と認証時間を制御可能である。高い認証精度を求める場合には弱識別器を増やし、短時間で認証を行う場合には弱識別器の個数を減らすことで対応が可能である。

これらの利点のうち、(2)、(3)、(4) は従来研究の Adaboost でも実現可能であるが、(1) は XGBoost だけで実現可能な利点である。

XGBoost の弱識別器である決定木は、分岐に利用する特徴量を選ぶことで作成される。この操作が特徴量選択に対応する。分岐ごとに特徴量の条件が決められており、その分岐をたどることによって、使用する特徴量の組が決められていく。決定木の最終ノードに至るまでの経路が画像ごとに異なるため、画像ごとに異なる分岐 (特徴量) の組合せで識別している。

##### 3.2.2 XGBoost の学習方法

XGBoost では弱識別器として決定木を作成し、それらの結果を統合することで最終的な識別結果を得る。 $t$  個目の決定木の学習では、 $1 \sim (t-1)$  個目の決定木で学習できなかった部分、つまり、予測値と目的変数の誤差を学習する。この学習を繰り返すことによって、予測値を目的変数に近づける。以下に弱識別器である決定木の学習方法を示す。

ここで、学習データとしては  $n$  個のサンプル  $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)$  が与えられているとする。 $\mathbf{x}_i = (x_{i1}, \dots, x_{im})^T$  は  $m$  個の特徴を持った  $i$  番目のサンプル、 $y_i$  はデータ  $\mathbf{x}_i$  の目的変数、 $\hat{y}_i$  はデータ  $\mathbf{x}_i$  に対する予測値である。また、 $y_i$  は本人同士であれば 1、他人同士であれば 0 を表し、 $\hat{y}_i$  は本人同士では 1 に近い、他人同士では 0 に近い、0 から 1 までの値をとる。したがって、誤った予測をするほど、予測値  $\hat{y}_i$  と目的変数  $y_i$  の差は大きくなる。

##### (1) 弱識別器の学習

###### ● 弱識別器の設計

XGBoost では弱識別器として決定木が用いられる。そこで、「各決定木の分岐の作成」を「特徴量の選択」に対応付けさせた。すなわち、 $t$  個目の決定木を作成する際、 $t-1$  個目までの決定木で学習できなかった部分を補うような特徴量が選択され、効率的な特徴量の統合が可能となる。具体的には、各分岐ごとに最適な閾値を求め、その大小関係により出力を変化する  $k$  番目の弱識別器  $f_k(\mathbf{x}_i)$  を  $K$  個使用すると、予測値  $\hat{y}_i$  は以下の式で表せる。

$$\hat{y}_i = \sum_{k=1}^K f_k(\mathbf{x}_i), f_k \in F \quad (3)$$

ここで、 $F = \{f_k(\mathbf{x}_i) = \omega_{q(\mathbf{x}_i)}\} (q: \mathbb{R}^m \rightarrow T, \omega \in \mathbb{R}^T)$  は決定木の集合、 $q$  は  $\mathbf{x}_i$  を対応する葉にマッピングする各決定木の構造、 $T$  は決定木の葉の数を表し、各決定木  $f_k$  は独立した決定木の構造  $q$  と葉の重み  $\omega$  で構成される。本実験では、式 (3) をロジスティック変換することで  $\hat{y}_i$  の値を 0 から 1 までの値に変換する [15]。また、各決定木の最終ノードに至るまでの経路は入力データごとに異なるため、画像ごとに利用する特徴量を変更して識別することが可能である。

● 損失関数

本研究の XGBoost の損失関数には交差エントロピーを用いた。交差エントロピーは以下の式で表される。

$$l(y_i, \hat{y}_i) = -y_i \log \hat{y}_i - (1 - y_i) \log(1 - \hat{y}_i) \quad (4)$$

式 (4) によると、目的変数と予測値との誤差が一致するほど 0 に近くなり、目的変数と予測値の誤差が大きくなると損失関数の値も大きくなる。

● 弱識別器の構築

Boosting は 1 ~ (t - 1) 番目の弱識別器の結果を利用して、t 番目の弱識別器を構築する手法である。そのため、XGBoost では損失関数  $l$  を用いることで、式 (5) のように定式化することができる。

$$\begin{aligned} \min_{f_t} \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) &\equiv \min_{f_t} \sum_{i=1}^n l\left(y_i, \sum_{k=1}^t f_k(\mathbf{x}_i)\right) \\ &\equiv \min_{f_t} \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(\mathbf{x}_i)) \end{aligned} \quad (5)$$

この式 (5) を式変形することで、t 個目の決定木  $f_t(\mathbf{x}_i)$  の最終ノード  $j$  の最適な重み  $\omega_j^*$  を求めることができる。

$$\omega_j^* = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (6)$$

ここで、 $I_j$  は最終ノード  $j$  に属するサンプルの集合、 $g_i$  は損失関数  $l$  の一次勾配、 $h_i$  は損失関数  $l$  の二次勾配、 $\lambda$  は L2 正則化項の重みである。

また同様に式 (5) を式変形することで、分岐に用いるのに最適な特徴量を求めることができる。

$\mathbf{x}_i = (x_{i1}, \dots, x_{im})^T$  のあらゆる特徴量のうち、式 (7) の値が最も大きくなる特徴量を選択して、分岐を行う。この操作が「特徴量の選択」と対応付けしている。

$$\frac{1}{2} \left\{ \frac{(\sum_{i \in I_L} g_i)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{(\sum_{i \in I_R} g_i)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{(\sum_{i \in I_S} g_i)^2}{\sum_{i \in I_S} h_i + \lambda} \right\} \quad (7)$$

ここで、 $I_L$ 、 $I_R$  はノード分岐した後に左側のノードに属するサンプルの集合と右側に属するサンプルの集合である。また、 $I_S = I_L \cup I_R$  である。式 (7) は分

岐前と分岐後の目的関数の差を表しており、最も目的関数を小さくするように分岐を作成する。

したがって、式 (6)、(7) を用いることで、各弱識別器を繰り返し学習することができ、それらを統合した強識別器の構築が可能である。

(2) 強識別器

最終的に作成された複数の弱識別器を組み合わせることで強識別器が作成される。この強識別器は弱識別器である決定木の出力をすべて加算し、識別スコア  $H(\mathbf{x}_i)$  を算出する。弱識別器の個数が  $K$  個のときの識別スコアは式 (8) のように求める。

$$H(\mathbf{x}_i) = \sum_{k=1}^K f_k(\mathbf{x}_i) \quad (8)$$

この値としきい値との大小関係によって本人他人を判定する。

4. 評価実験

4.1 実験概要

本実験では、目の周辺領域から虹彩と目の周辺、強膜の特徴量を取得し、識別に用いた。特徴量としては、虹彩認証では Daugman のアルゴリズムにより算出したアイリスコード、目の周辺認証では先行研究で用いられた LBP, HOG, SIFT, LDP, SURF, ORB, BRISK の合計 7 種類の画像特徴量、強膜認証では先行研究で用いられた LDP, SURF に加え、目の周辺認証の先行研究で用いられた LBP, HOG, SIFT の合計 5 種類の画像特徴量を用いて画像どうしを比較し、類似度スコアを算出した。その後、特徴量ごとに照合した類似度スコアを並べた特徴ベクトルを求めた。この特徴ベクトルは特徴量の種類数分の次元を持ち、本人同士の照合によって求めた類似度スコアを並べた特徴ベクトルの分布と、他人同士の照合により求めた類似度スコアを並べた特徴ベクトルの分布を分類するために学習用データを用いて XGBoost の学習を行い、識別器を作成した。XGBoost は Chen ら [16] が作成したツールを用いた。そして作成した識別器にテスト用データを適用することで、識別器の汎化性能を評価した。

4.2 前処理

前処理として、目の周辺画像の抽出、画像の正規化、強膜領域の抽出を行った。

4.2.1 目の周辺画像の抽出

顔全体を撮影した画像を用いる場合、目の周辺領域を抽出する方法が確立していない。そこで前処理として、目の周辺画像の切り出しを行う。まず OpenCV [17] で実装されている目検出アルゴリズムを用いて、左右の目領域を個別に検出する。次に検出した領域から Circular-Hough 変換を用いて瞳孔を検出し、検出した瞳孔が画像の中心になる

ように補正を行い、600 [pixel] \* 400 [pixel] で画像の切り出しを行った。

#### 4.2.2 画像の正規化

次に切り出しを行った目の周辺画像の正規化を行う。Tanら [2] の手法を参考に、虹彩の半径の大きさを揃えた。

まず、各画像の虹彩の半径を  $r_{iris}$  [pixel]、正規化後の虹彩の半径を  $r_{norm}$  [pixel] とし、 $S_f = r_{norm}/r_{iris}$  を求めた。そして元の画像サイズ 600 [pixel] \* 400 [pixel] に対し、正規化後の画像サイズが  $S_f$  (600 [pixel] \* 400 [pixel]) となるように Bicubic 法を用いて縮小した。以上の操作により、正規化後の虹彩の半径が  $r_{norm}$  [pixel] と等しくなる。その後、画像の中心が虹彩の中心となるように補正し、画像サイズ  $6r_{norm}$  [pixel] \*  $4r_{norm}$  [pixel] で再び切り出した。

本論文では、OSIRIS の極座標表示の画像サイズから、 $r_{norm} = 64$  [pixel] とした。したがって、正規化後の画像のサイズは 384 [pixel] \* 256 [pixel] となる。

#### 4.2.3 強膜領域の抽出

目の周辺の切り出しを行った画像から虹彩領域を切り抜き、強膜領域の抽出を行う。以下に強膜領域の抽出の手順を示す。

手順 (1) 二値化を用いた強膜領域の抽出

まず初めに以下の式を用いて明るさ調整を行う。

$$\begin{aligned} & \text{(各輝度値)} \\ & = \frac{\text{(各輝度値)} - \text{(平均輝度)}}{\text{(輝度値の標準偏差)}} * 16 + 64 \quad (9) \end{aligned}$$

この式は画像の平均輝度を 64、標準偏差を 16 に変換する式である。各値は明るさ調整を行わずに分割を行った際、強膜領域の分割を行うことができた画像の平均値を用いた。

次にメディアンフィルタを用いて細かなノイズの除去を行った後、大津の二値化を行い、強膜領域のマスクを取得した。

手順 (2) 入力画像の明るさをより明るく調整

手順 (1) で領域抽出できなかった画像に対して、入力画像の明るさをより明るく調整し、手順 (1) と同様にノイズ除去を行った後に大津の二値化を行うことで強膜領域のマスクを取得した。


手順 (3) 入力画像の明るさをより暗く調整

手順 (2) で領域抽出できなかった画像に対して、入力画像の明るさをより暗く調整し、手順 (1)、(2) と同様にして強膜領域のマスクを取得した。

手順 (4) 手作業による領域抽出

手順 (1)、(2)、(3) で領域抽出できなかった画像はしきい値処理では領域抽出できないものとし、手作業によってマスクを取得した。

各手順で抽出したマスクを入力画像に適用することで強膜領域を抽出した。



(a) 入力画像 (b) 出力画像

図 1 強膜領域の抽出結果

Fig. 1 Examples of the sclera region.

以上の作業により抽出を行った結果を図 1 に示す。

### 4.3 特徴量の抽出

#### 4.3.1 虹彩認証

OSIRIS version 4.1 [18] を用いて Daugman の虹彩認証アルゴリズムを実装した。前処理により切り出した画像から、アイリスコードを特徴量として抽出する。抽出したアイリスコードからハミング距離による類似度を算出する。

#### 4.3.2 目の周辺認証、強膜認証

目の周辺認証では先行研究で用いられた 7 種類の画像特徴量 (LBP, HOG, SIFT, LDP, SURF, ORB, BRISK) を使用した。また、強膜認証では先行研究で用いられた 5 種類の画像特徴量 (LBP, HOG, SIFT, LDP, SURF) を使用した。各特徴量の類似度スコアの算出方法を以下に示す。

- LBP, LDP: ブロックサイズを 31 [pixel] \* 31 [pixel] とし、各画像から算出した特徴ベクトルどうしのマンハッタン距離を類似度スコアとした。
- HOG: セルサイズを 32 [pixel] \* 32 [pixel]、ブロックサイズを 3 セル \* 3 セルとして、算出した特徴ベクトルどうしのマンハッタン距離を類似度スコアとした。
- SIFT, SURF, ORB, BRISK: 画像間の対応点が多いほど類似度が高く、また対応点間の距離が近いほど類似度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、 $N$  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。

### 4.4 統合手法

本提案手法の有効性を確認するため、AdaBoost を用いた統合との比較を行う。

#### 4.4.1 AdaBoost

以下に本実験で用いた AdaBoost の適用方法を示す。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繰り返すことで強識別器を作成する。本実験では、強識別器の作成に用いる学習ステップの数

表 2 特徴量の組合せと統合手法  
Table 2 Combination of features and Integration method.

実験	特徴量	統合手法	特徴量数 (片目, 両目)
1	虹彩+目の周辺 (LBP, HOG, SIFT)	AdaBoost	(4, 8)
2	虹彩+目の周辺 (LBP, HOG, SIFT)	XGBoost	(4, 8)
3	虹彩+目の周辺 (LBP, HOG, SIFT, LDP, SURF, ORB, BRISK)	XGBoost	(8, 16)
4	虹彩+目の周辺 (LBP, HOG, SIFT) +強膜 (LBP, HOG, SIFT, LDP, SURF)	XGBoost	(9, 18)
5	虹彩+目の周辺 (LBP, HOG, SIFT, LDP, SURF, ORB, BRISK) +強膜 (LBP, HOG, SIFT, LDP, SURF)	XGBoost	(13, 26)

(弱識別器の個数)を最大 500 個とした。最終的には訓練誤差 (EER) が最も低くなる個数を強識別器として利用した。

#### 4.4.2 XGBoost

以下に本実験で用いた XGBoost の適用方法を示す。

##### (1) 特徴量の抽出

著者らは個人認証に用いる特徴量を抽出する。得られた特徴量ごとに類似度を求め、本人同士または他人同士でラベル付けをする。ラベルの値は本人同士は 1, 他人同士は 0 に設定した。

XGBoost は多量の特徴量を入れた場合も有効な特徴量が選択されるため、より多くの特徴量の抽出を行う。

##### (2) ハイパーパラメータの設定

用いるデータによってハイパーパラメータは変化するため、最適なパラメータを求めるパラメータチューニングを行う。チューニングを行う際には、ROC カーブの AUC がより小さくなるようなパラメータを探す。

##### (3) 弱識別器の学習

弱識別器の学習では、パラメータチューニングのときと同様に、AUC の値がより小さくなるように学習を行う。

##### (4) 強識別器の作成

本実験では、強識別器の作成に用いる学習ステップの数 (弱識別器の個数) を最大 1,000 個とした。最終的には訓練誤差 (EER) が最も低くなる個数を強識別器として利用した。

##### (5) 照合結果

XGBoost は弱識別器である決定木の出力の総和がどれほど本人らしいかを示す。値が大きいほどより本人らしいことを示す。

#### 4.5 特徴量の組み合わせ

表 2 に実験で利用した特徴量の組合せおよび統合手法を示す。実験 1 は大石らによる AdaBoost を用いた先行研究の手法である。実験 2 は先行研究の統合手法を XGBoost に変更、実験 3 は先行研究に目の周辺特徴量を増やし、実験 4 は先行研究に新たな部位として強膜を増やした。実験 5 はこれらをすべて組み合わせた提案手法である。

#### 4.6 データセット

本研究では、データセットとして CASIA-Iris-Distance [19] を用いて実験を行った。このデータセットは近赤外カメラを用いて 3m 離れた位置から顔領域を撮影した画像で構成されている。被験者 142 人、合計 2,567 枚の画像が収録されている。今回は裸眼の被験者のみを対象とし、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 (学習用データとして 4 枚、テスト用データとして 4 枚) の画像を利用した。

#### 4.7 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 カーブは本人拒否率 (FRR: False Reject Rate) と他人受入率 (FAR: False Accept Rate) を軸とし、しきい値を変化させることで曲線を描く。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 という。

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。識別率は正しく識別することができた人物の割合を示し、式 (11) で求める。

$$(\text{識別率}) = \frac{(\text{識別成功した人物の数})}{(\text{登録されている人物の総数})} * 100 [\%] \quad (11)$$

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。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:  ${}_4C_2 * 122 = 732$  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。

## 5. 結果

### 5.1 強膜領域の抽出精度

右目 976 枚, 左目 976 枚の目の周辺画像から 4.2.3 項で

表 3 強膜領域の抽出成功画像数

Table 3 EER and Identification rate for each combination.

手順	左目 [枚]	右目 [枚]
(1)	696	688
(2)	112	144
(3)	136	118
(4)	32	26

表 4 組合せごとの EER と識別率

Table 4 EER and Identification rate for each combination.

実験	特徴量数	EER [%]		識別率 [%]	
		左目	右目	左目	右目
1	4	2.28	2.01	89.2	88.9
	8	1.41		93.9	
2	4	2.06	1.73	91.3	91.2
	8	1.21		95.6	
3	8	1.36	0.94	96.7	98.0
	16	0.52		99.2	
4	9	1.69	1.67	96.0	96.1
	18	1.14		98.3	
5	13	1.24	0.72	97.7	98.5
	26	0.41		99.5	

示した各手順で強膜領域の抽出ができた画像数を表 3 に示す。

表 3 より、手順 (1) で左目の 696 [枚] (左目の全画像数の 71.3 [%] に相当)、右目の 688 [枚] (右目の全画像数の 70.5 [%] に相当) の画像で強膜領域の抽出ができたことが分かる。また、手順 (1) で抽出できなかった画像に対して明るさ調整を行った手順 (2), (3) でさらに領域抽出を行うことができた画像数が増え、左目の 944 [枚] (左目の全画像数の 96.7 [%] に相当)、右目の 950 [枚] (右目の全画像数の 97.3 [%] に相当) の画像に対して自動的に領域抽出を行うことができた。

### 5.2 強膜領域も組み合わせた認証実験

虹彩と目の周辺と強膜認証の組合せにおいて、多くの特徴量を XGBoost 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 4 に各組合せにおける EER と識別率を示す。また、著者以外の研究グループの先行研究との比較を行った。虹彩と目の周辺認証を組み合わせている先行研究 [1], [2] に倣い、片目の虹彩と目の周辺からそれぞれ 1 種類の特徴量を抽出し、それぞれの特徴量を用いて認証を行い、類似度スコアを算出した。それらを先行研究 [1], [2] に倣い、重みつけ和で統合し、認証を行った。なお特徴量について、虹彩は虹彩認証でよく用いられているアイリスコード、目の周辺は目の周辺認証でよく用いられている LBP, HOG, SIFT を用いた。実験を行い、提案手法と比較した結果を表 5 に示す。

AdaBoost を用いた統合の実験 1 と XGBoost を用いた

表 5 提案手法と重みつけ和の比較結果

Table 5 A comparison between proposed methods using XGBoost and previous method using Weighted-sum.

統合手法	特徴量数	EER [%]		識別率 [%]	
		左目	右目	左目	右目
重みつけ和 (先行研究)	2(虹彩+LBP)	4.13	4.26	82.4	81.0
	2(虹彩+HOG)	4.83	4.22	78.0	79.8
	2(虹彩+SIFT)	2.69	2.41	86.1	88.0
XGBoost (提案手法)	13(実験 5, 片目)	1.24	0.72	97.7	98.5
	26(実験 5, 両目)	0.41		99.5	




図 2 ROC カーブ  
Fig. 2 ROC curve.

統合の実験 2 を比較した結果、XGBoost を用いた統合が AdaBoost を用いた統合よりも EER は下回り、識別率は上回っていることが確認できる。次に、実験 2 と目の周辺領域の特徴として新たに 4 種類の特徴量を加えた実験 3 の比較を行う。新たに画像特徴量を加えることで、EER は最大 0.79 [%]、識別率は最大 6.8 [%] 改善されていることが分かる。次に、実験 2 と新たな部位として強膜を加えた実験 4 の比較を行う。新たに強膜を加えることで、新たな目の周辺特徴量を加えた場合に劣るが、EER、識別率ともに改善されていることが分かる。最後に、提案手法である実験 5 と実験 1~4 の比較を行う。提案手法である複数特徴量を加え、両目から抽出したそれらの特徴量を XGBoost で統合した実験 5 が最も高い精度となった。先行研究の AdaBoost を用いた統合である実験 1 と比較した際、EER は最大 1.29 [%]、識別率は最大 9.6 [%] 改善されていることが確認できる。

表 5 より、先行研究の重みつけ和を用いた統合よりも提案手法の XGBoost を用いた統合の方が高い精度を示した。また、重みつけ和で最も精度の良い右目の (虹彩 + SIFT) の統合と比較して、提案手法の EER は 2.00 [%]、識別率は 11.5 [%] 改善されていることが確認できる。

次に、図 2, 図 3 に表 4 の各実験に対応した ROC カーブおよび CMC カーブ、図 4, 図 5 に表 5 の重みつけ和と XGBoost に対応した ROC カーブおよび CMC カーブ






図 3 CMC カーブ  
Fig. 3 CMC curve.

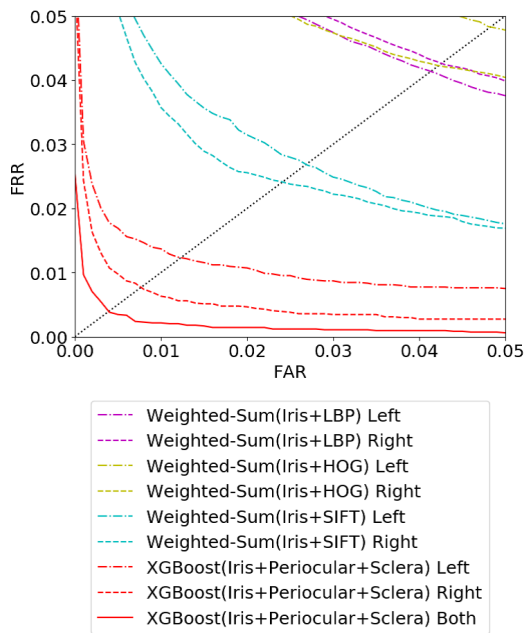


図 4 ROC カーブ (提案手法と重みつけ和の比較)

Fig. 4 ROC curve (A comparison between XGBoost and Weighted-sum).

を示す。

図 2 の ROC カーブにおいて、表 4 に示した結果と同様に実験 5 の両目で統合した結果が最も良いことが確認できた。また、実験 5 の両目で統合した曲線はほかの曲線と比べてつねに原点側に位置しており、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。図 3 の CMC カーブにおいても、実験 5 の両目で統合した曲線が つねに上部に位置している。したがって、提案手法により本人同士のスコアがより高い位置になるような強識別器を作成できていることを示した。

また図 4, 5 から、ROC カーブ、CMC カーブの両方の評価で先行研究の重みつけ和を用いた統合よりも提案手法の XGBoost を用いた統合の方が高い精度を示したことが分かる。




図 5 CMC カーブ (提案手法と重みつけ和の比較)

Fig. 5 CMC curve (A comparison between XGBoost and Weighted-sum).

## 6. 評価用データとは独立したバリデーションデータを用いた評価実験

### 6.1 実験概要

評価用データとは独立したバリデーションデータを用いてハイパーパラメータのチューニングを行った。チューニングを行ったハイパーパラメータを用いてテストを行い、提案手法と先行研究で用いられた AdaBoost と比較した。実験では表 6 に示す組合せを用いた。

CASIA-Iris-Distance の被験者 122 人をサブセット 1 (61 人) とサブセット 2 (61 人) に分割した。このサブセット 1 と 2 に被験者の重複はない。また、試行回数を増やすため、クロスバリデーションを行った。クロスバリデーションはサブセット 1 でハイパーパラメータをチューニングし、サブセット 2 でテストした場合とサブセット 2 でハイパーパラメータをチューニングし、サブセット 1 でテストした場合の合計 2 回行った。被験者 1 人あたり 8 枚の画像を使用したため、各サブセットの画像数は 488 枚となった。今回の実験における評価は各試行の結果を平均化した。実験結果に対し、ROC カーブ、EER、CMC カーブ、識別率を用いて精度評価を行った。

### 6.2 実験結果

表 7 にバリデーションデータを用いた評価実験の EER と識別率を示す。

表 7 に示した各組合せの結果を比較すると、提案手法である虹彩と目の周辺 7 種類、強膜 5 種類を XGBoost を用いて統合した場合が最も精度が良いことが分かる。また、

表 6 特徴量の組合せ

Table 6 Combination of features.

組合せ	特徴量	特徴量数 (片目, 両目)
1	虹彩+目の周辺 (LBP, HOG, SIFT)	(4, 8)
2	虹彩+目の周辺 (LBP, HOG, SIFT, LDP, SURF, ORB, BRISK)	(8, 16)
3	虹彩+目の周辺 (LBP, HOG, SIFT) +強膜 (LBP, HOG, SIFT, LDP, SURF)	(9, 18)
4	虹彩+目の周辺 (LBP, HOG, SIFT, LDP, SURF, ORB, BRISK) +強膜 (LBP, HOG, SIFT, LDP, SURF)	(13, 26)

表 7 評価用データとは独立したバリデーションデータを用いた評価実験の EER と識別率

Table 7 EER and identification rate for experimentation using validation data.

組み合わせ	特徴量数	EER [%]				識別率 [%]			
		XGBoost		AdaBoost		XGBoost		AdaBoost	
		左目	右目	左目	右目	左目	右目	左目	右目
1	4	2.55	2.09	2.18	2.14	80.4	82.4	84.7	82.5
	8	1.31		1.32		91.1		89.5	
2	8	2.01	1.68	1.85	1.65	85.8	84.2	77.9	83.7
	16	1.11		1.11		93.5		89.3	
3	9	2.25	1.88	2.04	1.55	84.0	84.2	84.6	84.3
	18	1.07		1.06		93.0		92.1	
4	13	1.74	1.38	1.79	1.33	89.7	88.7	81.5	88.6
	26	0.88		0.95		95.2		94.1	

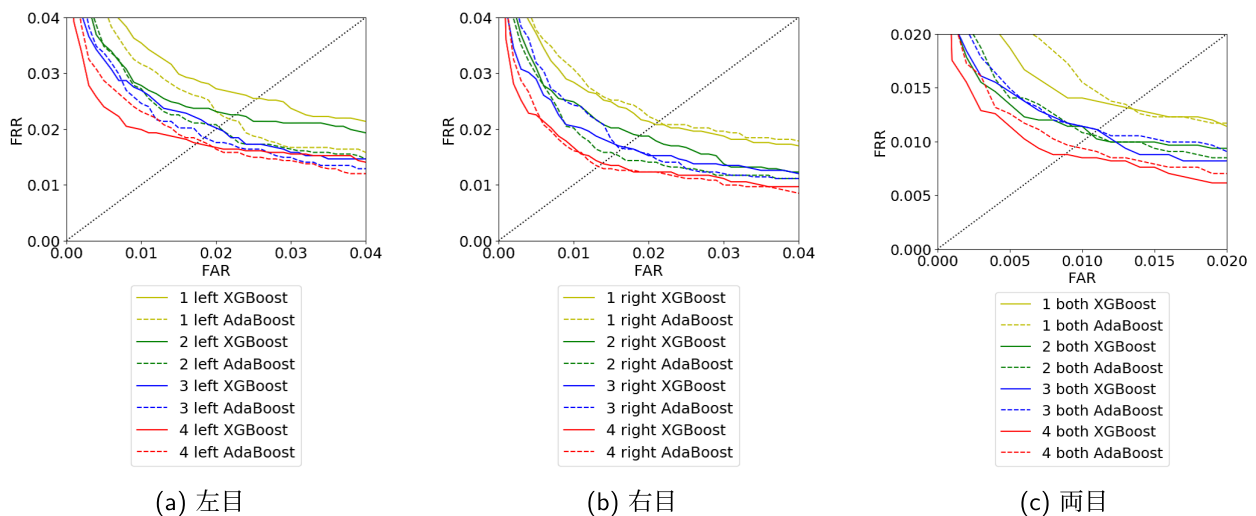


図 6 評価用データとは独立したバリデーションデータを用いた実験の ROC カーブ

Fig. 6 ROC curve for the experiment using validation data.

先行研究 [3] である虹彩と目の周辺 3 種類を AdaBoost を用いた場合と比較して, EER は 0.44 [%], 識別率は 5.7 [%] 改善されていることが分かる。

また, 図 6, 図 7 に各組合せに対応した ROC カーブおよび CMC カーブを示す。表 7 に示した各組合せの結果を比較すると, ROC カーブおよび CMC カーブより, 両目の虹彩と目の周辺 7 種類, 強膜 5 種類を XGBoost を用いて統合した提案手法が最も良いことが確認できた。また, 先行研究 [3] である虹彩と目の周辺 3 種類を AdaBoost を用いた場合と比較して, 提案手法の ROC カーブは原点側

に, CMC カーブでは上側に位置しているため, ROC カーブおよび CMC カーブからも精度改善されていることが分かる。

## 7. 考察

表 4 より実験 5 が最良であることを示した。この結果をふまえ, 以下の 5 点に関して考察する。

- XGBoost の有効性
- 強膜領域の抽出精度
- 強膜領域の有効性




図 7 評価用データとは独立したバリデーションデータを用いた実験の CMC カーブ  
 Fig. 7 CMC curve for the experiment using validation data.




図 8 実験 1 と 2 とときの XGBoost と AdaBoost の訓練誤差 (EER)  
 Fig. 8 The EER in Experiment 1 and 2.

- 複数特徴量を用いることの有効性
- CASIA-Iris-Distance における State-of-the-art の手法との比較

### 7.1 XGBoost の有効性

先行研究で用いられた AdaBoost は外れ値のようなノイズに弱いですが、提案手法で用いた XGBoost は複数のパラメータをチューニングすることで、そのような外れ値に対して堅牢性を高めることが可能である。そこで、XGBoost と AdaBoost の識別境界面に着目し、本提案手法の有効性を確認する。

まず、図 8 に実験 1 の AdaBoost と実験 2 の XGBoost の訓練誤差 (EER) を示す。

図 8 より、AdaBoost の EER は弱識別器の個数が 10 個付近から一定の値を示していることが分かる。一方、XGBoost の EER は 10 個付近まで急激に低下した後、弱識別器の個数が増えるにつれてゆるやかに低下していることが分かる。したがって、弱識別器の個数が 10 個前後の部分で 2 つの統合手法の違いが現れていると考えられる。

そこで、弱識別器の個数が 10 個前後の識別境界面を確認する。

図 9 に実験 1 と実験 2 において弱識別器を 7, 17, 27 個使用したとき、それぞれで選択された各統合手法の識別境界面を示す。横軸が虹彩、縦軸が HOG の特徴量、円の大きさが AdaBoost の重みの大きさを表し、黄色の線が XGBoost、紫色の線が AdaBoost の識別境界面を示す。

図 9 より、AdaBoost はつねに外れ値の部分に重みづけをしていることが分かる。また、弱識別器の個数が 17 個以上のときから、識別境界面が変化していないことが分かる。したがって、AdaBoost は外れ値の部分に重みを付加し続けたことにより、精度が改善されなくなったことが結果からも考えられる。

一方、XGBoost は弱識別器の個数が増えても識別境界面が変化し続けていることが分かる。XGBoost は外れ値に影響されることなく識別境界面を作成し、弱識別器の個数を増やすことで、さらなる精度の改善を行うことができたと考える。

### 7.2 強膜領域の抽出精度

図 10, 図 11 に手順 (4) の手作業で強膜領域の抽出を行った画像の例を示す。図 10 (b) より、二値化による領域抽出ではまつ毛が写っている部分のみが強膜領域と判断されていることが分かる。強膜領域と肌などの領域の画素値の差が小さく、同一の領域として扱われたため、まつ毛が写っている暗い部分のみが強膜領域と判断されたと考えられる。図 11 (b) より、強膜領域に髪の毛が含まれていることが分かる。入力画像に含まれている髪の毛の部分は強膜領域よりも暗いため、髪の毛の部分も強膜領域として判断されたと考えられる。したがって図 10, 11 のような画像は、二値化による強膜領域抽出ができないと考えられる。

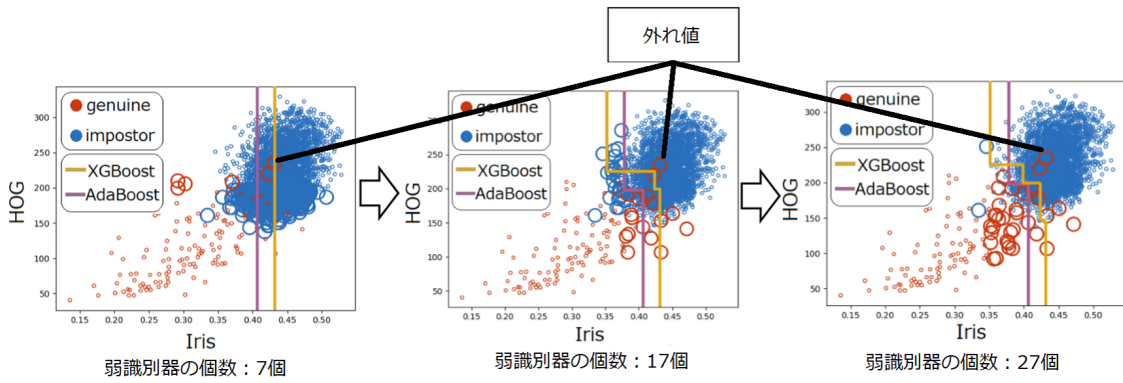



図 9 実験 1, 2 のときの各統合手法の識別境界面

Fig. 9 The boundary of XGBoost and AdaBoost in Experiment 1 and 2.



(a) 入力画像 (b) 手順(1)の出力 (c) 手順(4)の出力

図 10 手作業による強膜領域抽出の例 1

Fig. 10 Examples 1 of the sclera region extracted by hand.



(a) 入力画像 (b) 手順(1)の出力 (c) 手順(4)の出力

図 11 手作業による強膜領域抽出の例 2

Fig. 11 Examples 2 of the sclera region extracted by hand.

表 8 強膜認証に用いた各特徴量の EER と識別率

Table 8 An example of table.

特徴量	EER [%]		識別率 [%]	
	左目	右目	左目	右目
LBP	10.0	10.0	37.8	37.2
HOG	10.0	10.0	42.9	46.3
SIFT	9.7	9.8	49.6	48.3
LDP	10.0	10.0	35.8	38.3
SURF	8.4	8.3	60.0	61.2

その解決方法の1つとして、強膜領域と非強膜領域の識別に機械学習を用いる [20] などを新たに検討する必要があると考える。

### 7.3 強膜領域の有効性

近赤外画像を用いた個人認証に強膜領域が有効であるかを考察する。考察するにあたり、強膜領域から抽出した各特徴量単体の精度を表 8 に示す。

表 8 より、近赤外画像を用いた強膜認証の EER は 10 [%] 前後、識別率は 35~60 [%] を示した。また、このときの CMC カーブを図 12 に示す。




図 12 強膜認証の CMC カーブ

Fig. 12 CMC curve in sclera authentication.

図 12 より、順位を重ねるにつれて累積識別率が向上し、最も精度の良い SURF の 5 位識別率は約 75 [%] を示した。したがって、強膜単体の認証では精度が劣るものの、ほかの特徴と組み合わせることで精度を向上させる可能性があると考えられる。

表 4 の実験 2 と実験 4 の精度比較より、新たに強膜を加えたことで精度が改善されていることが分かる。この結果は、虹彩と目の周辺認証では識別できなかった画像の識別を強膜認証が可能にしたことにより、さらなる精度改善を行うことができたと考える。

### 7.4 複数特徴量を用いることの有効性

XGBoost の各学習ステップにおいて、各弱識別器でどのような特徴量が選択されているのか、分析を行った。分析を行うにあたり、最も精度が良かった実験 5 の両目で統合した場合の弱識別器の個数に対する EER を図 13 に示す。

図 13 より、はじめの 10 個ほどの弱識別器が精度に大きな影響を与えていることが分かる。そこで、その精度に大きな影響を与えた弱識別器で用いられた部位の傾向を確かめる。表 9 に弱識別器の順位に対する虹彩、目の周辺、強膜が選ばれた割合を示す。弱識別器の順位が 3 位以内の場合、1~3 番目の弱識別器の中で選択された部位の割合を

示す。

表 9 より、精度が大きく改善された 10 位以内の部分で強膜領域が約 17 [%] 選択されていることから、強膜領域は精度向上の一端を担っていることが分かる。したがって、近赤外画像を用いた認証において、強膜領域を用いること

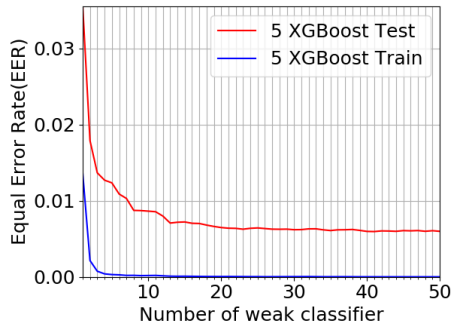


図 13 実験 5 の両目で統合した場合の EER  
Fig. 13 The EER in Experiment 5.

表 9 選択された部位の傾向

Table 9 The part of body selected in Experiment 5.

弱識別器の順位	Iris [%]	Periocular [%]	Sclera [%]
3 位以内	15.04	67.17	17.79
5 位以内	9.43	68.59	21.99
8 位以内	9.49	72.13	18.38
10 位以内	9.82	72.94	17.24

表 10 選択された目の周辺特徴量の傾向

Table 10 The image feature of periocular selected in Experiment 5.

弱識別器の順位	LBP [%]	HOG [%]	SIFT [%]	LDP [%]	SURF [%]	ORB [%]	BRISK [%]
3 位以内	21.85	8.72	12.38	5.81	38.11	10.55	2.58
5 位以内	18.90	6.08	15.73	9.72	39.00	8.39	2.18
8 位以内	22.14	7.89	16.32	8.83	31.28	11.32	2.22
10 位以内	25.16	7.50	14.66	8.39	32.81	9.55	1.93

表 11 選択された強膜特徴量の傾向

Table 11 The image feature of sclera selected in Experiment 5.

弱識別器の順位	LBP [%]	HOG [%]	SIFT [%]	LDP [%]	SURF [%]
3 位以内	20.73	4.47	26.42	5.69	42.68
5 位以内	11.34	5.15	33.61	9.07	40.82
8 位以内	11.06	8.70	33.48	9.14	37.61
10 位以内	9.97	9.84	30.70	8.55	40.93

表 12 AdaBoost で選択された特徴量の傾向

Table 12 The feature selected in Experiment 1.

弱識別器の順位	Iris [%]	Periocular		
		LBP [%]	HOG [%]	SIFT [%]
3 位以内	44.76	11.43	2.38	41.43
5 位以内	39.71	17.14	2.86	40.29
8 位以内	33.21	19.64	6.24	40.71
10 位以内	32.86	18.57	7.57	41.00

は有効であると考えられる。また、目の周辺領域が約 70 [%] 選択され、虹彩や強膜領域の特徴よりも目の周辺領域の特徴が有効であることを示し、XGBoost がそれらを優先的に選択したことにより、さらに精度向上したと考える。

次に、目の周辺領域および強膜領域それぞれで選択された特徴量の割合を表 10、表 11 に示す。また提案手法との比較のため、虹彩と目の周辺 3 種類を AdaBoost で統合した実験 1 で選択された特徴量の割合を表 12 に示す。

表 10、11 より、目の周辺認証では SURF、LBP、SIFT の順で、強膜認証では SURF、SIFT、LBP の順で多く用いられていることが分かる。また表 12 より、先行研究では局所特徴量である SIFT は約 40 [%] 前後用いられていることが分かる。一方、提案手法は、表 9、10、11 より、目の周辺認証および強膜認証を合わせると、局所特徴量は全体の 60 [%] 前後用いられていることが分かる。目は各個人で形が異なるため、大域特徴量を用いることで識別することが可能である。しかし、まばたきなどにより目の形状が変化する画像を識別する際は誤って識別する可能性が高くなる。大域特徴量が苦手とする画像に対して、SURF や SIFT などの局所特徴量を用いたことにより、より多くの画像を識別することが可能になったと考える。

そこで、先行研究では同一人物と識別できなかったが、提案手法を用いたことで識別可能になった画像の例を図 14 に示す。また、図 14 の画像の強膜領域から取得し、認証に用いられた SIFT のキーポイントを図 15 に示す。図 15

表 13 State-of-the-art の手法との比較

Table 13 A comparison between proposed methods and a state-of-the-art method.

	使用したモダリティ	EER [%]	FAR [%]	GAR [%]
State-of-the-art [21]	顔+左目 (虹彩)+右目 (虹彩)	0.24	0.06	99.50
提案手法	左目 (虹彩, 目の周辺, 強膜)+右目 (虹彩, 目の周辺, 強膜)	0.73	0.06	95.84




図 14 識別可能となった画像の例  
Fig. 14 Example of classified images.




図 15 強膜領域の SIFT のキーポイント  
Fig. 15 Key points of SIFT in sclera regions.

より, SIFT のキーポイントは下瞼などに配置されており, 目の開きに影響されない部分から多く取得されていることが分かる. この傾向は, 強膜の SURF や目の周辺領域の SIFT, SURF でも確認された. したがって, 図 14 に示す目の開き方が異なる同一人物でも, 局所特徴量を多く用いることで, 安定した認証を行うことができたと考えられる.

### 7.5 CASIA-Iris-Distance における State-of-the-art の手法との比較

本節では, CASIA-Iris-Distance データセットを用いた State-of-the-art の手法 [21] との比較を行った.

文献 [21] では顔と左目の虹彩から特徴量を抽出し, 特徴レベルの統合を行った. その後, 顔と左目, 右目, 特徴レベルの統合から得られた 4 つのスコアをスコアレベルの統合をし, 最後に結果レベルの統合を行うことで識別を行っている.

文献 [21] の文献に合わせ, CASIA-Iris-Distance の 90 人の被験者を使用し, 被験者 1 人あたり学習に 5 枚, テストに 5 枚の画像を用いて実験を行った. また試行回数を増やすため, クロスバリデーションを 10 回行った. そして, EER, FAR, GAR で評価した. ここで GAR [%] は  $100 - \text{FRR} [\%]$  で表され, 本人同士の組合せのうち, 正しく照合した割合を表す.

表 13 に State-of-the-art の手法の評価プロセスで実験を行った結果を示す. また, 先行研究 [21] の結果に合わせ, GAR は FAR が 0.06 [%] のときの値を示す. 表 13 より, 提案手法は State-of-the-art の手法よりわずかに劣り,

EER は 0.49 [%] 上回り, GAR は 3.66 [%] 下回っていることが分かる.

## 8. 結論と課題

本論文では, 遠距離でのマルチモーダルバイオメトリック認証の認証精度を向上させるために, 複数の特徴量を XGBoost で統合する手法を提案した. EER や識別率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, より多くの特徴量を XGBoost で統合することで, さらに精度が向上することを示した.

今回は近赤外カメラで撮影した画像を用い, 一般的なカメラで撮影可能な可視光画像を実験対象としなかった. そこで, 今後の課題として, より一般的な環境である可視光画像を用いた性能評価を行うことがあげられる. また, 本研究は裸眼の画像のみを対象としたため, 眼鏡などを着用している画像を用いた際, 認証精度にどの程度影響を及ぼすかを検討する必要がある. さらに実験の結果より, 左右の目で精度の差が見られた. この精度の差の原因について考察する必要がある.

謝辞 本研究は JSPS 科研費 19K04370 の助成を受けたものです.

### 参考文献

- [1] 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*, pp.201–204 (2010).
- [2] Tan, C. and Kumar, A.: Human identification from at-a-distance images by simultaneously exploiting iris and periocular features, *International Conference on Pattern Recognition*, pp.553–556 (2012).
- [3] 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*, Vol.2016, No.2, pp.208–215 (2016).
- [4] Das, A., Pal, U., Ferrer, M.A. and Blumenstein, M.: A decision-level fusion strategy for multimodal ocular biometric in visible spectrum based on posterior probability, *IEEE International Joint Conference on Biometrics*, pp.794–798 (2017).
- [5] 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*, pp.794–798 (2014).
- [6] Ahuja, K., Islam, R., Barbhuiyaa, F.A. and Dey, K.: Convolutional neural networks for ocular smartphone based biometrics, *Pattern Recognition Letters*, Vol.91, pp.17–26 (2017).

- [7] Raghavendra, R., Raja, K.B., Yang, B. and Busch, C.: Combining Iris and Periocular Recognition Using Light Field Camera, *IAPR Asian Conference on Pattern Recognition*, pp.155–159 (2013).
- [8] Ahmed, N.U., Cvetkovic, S., Siddiqi, E.H., Nikiforov, A. and Nikiforov, I.: Using fusion of iris code and periocular biometric for matching visible spectrum iris images captured by smart phone cameras, *International Conference on Pattern Recognition*, pp.176–180 (2016).
- [9] Raffei, A.F.M. et al.: Fusion Iris and Periocular Recognitions in Non-Cooperative Environment, *Indonesian Journal of Electrical Engineering and Informatics (IJEI)*, Vol.7, No.3, pp.543–554 (2019).
- [10] Zhou, Z., Du, E.Y., Thomas, N.L. and Delp, E.J.: A New Human Identification Method: Sclera Recognition, *IEEE Trans. Systems, Man, and Cybernetics - Part A: Systems and Humans*, Vol.42, No.3, pp.571–583 (2012).
- [11] Das, A., Pal, U., Ballester, M.A.F. and Blumenstein, M.: A new efficient and adaptive sclera recognition system, *IEEE Symposium on Computational Intelligence in Biometrics and Identity Management*, pp.1–8 (2014).
- [12] 白川功浩, 吉浦 裕, 市野将嗣: 虹彩および目の周辺の分割画像を用いた認証方式, *情報処理学会論文誌*, Vol.59, No.9, pp.1726–1738 (2018).
- [13] Chen, T. and Guestrin, C.: XGBoost: A Scalable Tree Boosting System, *Proc. 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining*, pp.785–794 (2016).
- [14] Nielsen, D.: Tree boosting with XGBoost, *NTNU Norwegian University of Science and Technology*, pp.785–794 (2016).
- [15] XGBoost Parameters, available from (<https://xgboost.readthedocs.io/en/latest/parameter.html>).
- [16] XGBoost, available from (<https://xgboost.readthedocs.io/en/latest/index.html>).
- [17] OpenCV, available from (<http://opencv.jp>).
- [18] OSIRIS version 4.1, available from ([http://svnnext.it-sudparis.eu/svnview2-eph/ref\\_syst//Iris.Osiris.v4.1/](http://svnnext.it-sudparis.eu/svnview2-eph/ref_syst//Iris.Osiris.v4.1/)).
- [19] CASIA Iris Image Dataset v4.0, available from (<http://biometrics.idealtest.org>).
- [20] Luo, B., Shen, J., Cheng, S., Wang, Y and Pantic, M.: Shape Constrained Network for Eye Segmentation in the Wild, *The IEEE Winter Conference on Applications of Computer Vision*, pp.1952–1960 (2020).
- [21] Ammour, B., Bouden, T and Boubchir, L.: Face-Iris Multimodal Biometric System Based on Hybrid Level Fusion, *41st International Conference on Telecommunications and Signal Processing (TSP)*, pp.1–5 (2018).



上野山 大介

2019年電気通信大学情報理工学部総合情報学科卒業。現在、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。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、同大学大学院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 IJH-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年早稲田大学大学院基幹理工学研究科研究助手。2010年同大学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。