

分類器の学習的な組み合わせによる虹彩と眼周囲情報を用いたマルチモーダル個人認証

Multimodal personal authentication using iris and periocular information by learning combination of classifiers

小川恵太[†]

Keita Ogawa

亀山啓輔[‡]

Keisuke Kameyama

1. 概要

虹彩認証では低品質な画像の場合に分類精度が大幅に低下することが報告されている。これを補うために虹彩だけでなく虹彩とともに取得できる眼周囲領域などの情報を併せて利用するマルチモーダル認証の研究が、近年活発に行われている。本研究では、虹彩と眼周囲の複数のモーダリティを利用することで、劣化した観測画像に対する分類精度の頑健性の向上を図ることを目的とした。虹彩と眼周囲のいずれかの画像が低品質であっても、虹彩分類器と眼周囲分類器のうち認証に有用である分類器を選択することで、分類精度を維持する手法を提案する。分類器の選択には、虹彩と眼周囲の各分類器の出力の一部を利用し、分類に有用な分類器を適応的に選択する MultiModalSelector を提案し用いる。実験では、虹彩分類器と眼周囲分類器のうち分類に有用な分類器を適応的に選択することで、高い分類精度を維持できることを示した。

2. 序論

2.1. 研究背景と目的

虹彩認証は撮影状況によっては虹彩のテクスチャが低品質になることがあり、低品質な虹彩画像を用いた場合、分類精度が大幅に低下する [1]。このことに対して、虹彩とともに取得できるまぶたやまつげなどの眼周囲領域の情報を利用して認証することが考えられている [2]。しかし、眼周囲においても髪の毛やメガネなどの遮蔽物が写ってしまうなど、条件が悪化した場合には分類精度が低下する [3]。

本研究では、虹彩と眼周囲の2つのモーダリティを利用し、虹彩と眼周囲の一方が低品質な画像であっても分類精度を維持する手法の開発を目的とする。また評価基準としては認証精度ではなく分類精度に着目した。

2.2. 本研究の成果

本研究の主な成果は以下のものである。

- 提案する MultiModalSelector は、虹彩と眼周囲のいずれかが低品質な画像であっても、虹彩分類器と眼周囲分類器のうち分類に有用であるものを選択し、分類精度が低下していない分類器を利用することで分類精度を維持することができることを示す。
- MultiModalSelector は、一般的な機械学習に基づくクラス分類手法で実装することが可能であることを示す。

3. 関連研究

3.1. 虹彩と眼周囲領域

図1に個人の認識に用いる眼周囲画像の例を示す。眼球は主に3つ領域に分けることができる。黒く見えている円形の領域を瞳孔、その周りのドーナツ型の部分を虹彩、虹彩の外側の白い領域を強膜と呼ぶ [4]。




図1 眼周囲画像の例

3.2. 虹彩認証と眼周囲認証

虹彩認証は、眼周囲画像を取得し、虹彩の検出、虹彩の正規化、特徴抽出を行い、分類器を用いた認識によって認証を行う。眼周囲認証は眼周囲画像自体を入力とし、特徴抽出を行い、分類器を用いた認識によって認証を行う。虹彩認証と眼周囲画像はそれぞれ活発に研究が行われている [5][6]。

3.3. 虹彩と眼周囲のマルチモーダル認証

近年、より頑健な認証を達成するために虹彩と眼周囲の情報融合によるマルチモーダル認証の研究が活発に行われている [1]。虹彩と眼周囲の融合の研究においては、虹彩と眼周囲のスコアレベルの融合 [7] や機能レベルの融合 [1] などの研究が行われている。

3.4. 複数の分類器を組み合わせたパターン分類の方法

パターン認識一般において複数の分類器を組み合わせ、分類に利用する手法としては、アンサンブル学習 [8] の方法の1つの bagging [8] や、複数の分類器を入力空間に対する局所的な専門家 (expert) として切り替えて用いる手法の Mixture of Experts [9] 等が知られている。

3.5. 課題

眼周囲認証と虹彩認証はいずれも実用的に利用できる認証方法であるが観測された画像が劣化していた場合に分類精度は低下する [1][3]。眼周囲と虹彩それぞれの特徴や分類結果に重み付けを行い融合する手法でも観測された画像が劣化していた場合には、学習時に獲得された固定の重みは適切ではなく、精度を低下させる可能性がある。そこで運用時に観測された画像が劣化しているかどうかを検出し、劣化している情報の利用を抑えることで全体としての認証精度を低下させない手法が必要となっている。

[†] 筑波大学 理工情報生命学術院 システム情報工学研究群

[‡] 筑波大学 システム情報系

3.6. 本研究の目的

本研究では、眼周囲と虹彩を併用するマルチモーダル認証において眼周囲分類器と虹彩分類器を利用し、虹彩と眼周囲のいずれかが低品質な画像である場合でも、信頼性の高い分類器の結果を適応的に選択する手法の開発を目的とする。

4. 提案手法

4.1. 全体の流れ

図 2 は提案方式の流れである。




図 2 提案方式の流れ

提案手法を用いた個人に相当するクラスの分類は5つのフェーズに大きく分けることができる。まずは、個人を認識すべき眼周囲画像を取得し、下記の1~5のフェーズの処理を行う。

- (1) 眼周囲領域が含まれる画像から虹彩を検出する。
- (2) 検出された虹彩画像を正規化する。
- (3) 虹彩分類器に正規化された虹彩画像を入力し、入力画像の虹彩クラス確率ベクトルを得る。
- (4) 眼周囲分類器に眼周囲画像を入力し、入力画像の眼周囲クラス確率ベクトルを得る。
- (5) 虹彩分類器と眼周囲分類器の信頼性を判断する MultiModalSelector により、両分類器の出力の一部を利用して信頼性の高い分類結果を選択する。

4.2. 虹彩の検出と正規化

眼周囲画像から虹彩を検出するには、まず瞳孔を検出し、その瞳孔の中心を基準に虹彩の検出を行う。虹彩の形が円形でなかったり、被認証者が非協力的な環境であっても虹彩を検出できるように楕円によるマッチングで虹彩の検出を行う。その後、座標変換を利用し、ドーナツ型の虹彩を開いて瞳孔の開き方によらない一定の長方形に変換し、正規化虹彩画像を得る [5]。

4.3. 虹彩分類器と眼周囲分類器

虹彩分類器と眼周囲分類器は入力画像を登録されたクラスのいずれかに分類する。いずれの分類器も畳み込みニューラルネットワーク (CNN) などの教室付学習により実現する。眼周囲分類器は眼周囲画像を入力とし、虹彩分類器は、4.2 節で作成した正規化虹彩画像を入力画像とする。出力は、登録されたクラス数の要素を持つベクトルであり、入力画像が属するクラスに相当する要素が最大となるよう学習させる。以下、これらモダリティを担当する分類器を領域分類器と呼ぶ。

4.4. MultiModalSelector

MultiModalSelector (MMS) は、4.3 節の虹彩分類器と眼周囲分類の出力ベクトルに基づいて有用な分類器を選

択する。これは、それぞれの分類器の出力が分類結果だけではなく、分類結果の信頼性を示す特徴を保持していると考えたからである。これによりシステム全体としての最終的な分類精度を維持する。

分類器の選択においては、まず虹彩分類器と眼周囲分類器の出力 y_i, y_p をそれぞれ softmax 関数に入力する。その出力 s_i, s_p の成分を降順にソートし、それぞれ上位 n 要素からなるベクトル z_i, z_p を抜き出す。そしてベクトル z_i, z_p を結合した $2n$ 次元ベクトル I を MMS への入力とする。MMS の出力 O はどちら領域分類器を利用するかを表すスカラー値である。




図 3 MultiModalSelector を用いた領域分類器の選択

MMS は教師付き学習により実現し、学習させる際にはそれぞれの分類器に入力する画像のいずれかを故意に劣化させる。その際、分類器の出力ベクトルから劣化していない情報を入力した (信頼性の高い) 領域分類器を選択させるように学習させる。表 1 は、入力画像の劣化の組み合わせである。図 4 と図 5 は意図的に劣化させた領域画像である。

表 1 MMS を学習させる際の入力画像の劣化の組み合わせ

組み合わせ	眼周囲画像	正規化虹彩画像
1	劣化させる (Random Erase)	劣化させない
2	劣化させない	劣化させる (Gaussian Filter)




図 4 Random Erase で劣化した眼周囲画像




図 5 Gaussian Filter で劣化した正規化虹彩画像

5. 評価・実験

5.1. データセット

本論文では、近赤外 (NIR) 画像の CASIA-Iris-Lamp データセット [10] を利用して実験を行った。CASIA-Iris-Lamp データセットのうち左右の目がとも 19 枚以上存在している 135 人の眼周囲画像を 270 クラスのデータとして利用した。

5.2. 虹彩の検出と正規化

図6は検出された虹彩であり、図7は正規化された虹彩画像である。補間方法はbicubic補間[11]を利用した。




図6 虹彩の検出結果(正規化前)



図7 正規化後

5.3. 虹彩分類器と眼周囲分類器による認識

虹彩分類器と眼周囲分類器としてそれぞれCNNモデルであるNeural Residual Network 18(Resnet18)[12]とVisual Geometry Group 16(VGG16)[6]を利用した。分類器の学習では、訓練(train)データ1080枚(各クラス4枚)、検証(validation)データ540枚(各クラス2枚)で学習させた。epochは100回とし、損失関数はクロスエントロピー誤差とした。表2はそれぞれの領域分類器の学習(train)、検証(val)、テスト(test)データに対する正解率を示す。

表2 学習済み領域分類器の正解率

分類器の種類	train	val	test
虹彩分類器	100.00%	95.93%	93.33%
眼周囲分類器	100.00%	99.63%	98.67%

5.4. MultiModalSelector

MMSは、多層パーセプトロン(NN)、Support Vector Machine(SVM)[13]、Random Forest(RF) classifier[14]の一般的な機械学習に基づくクラス分類手法を用いて構築した。MMSは、訓練(train)データ1350枚(各クラス5枚)、テストデータ2700枚(各クラス10枚)を利用する。

5.5. 実験の条件

表3に示すようにテスト時の劣化した方の画像の劣化度を5段階に変化させて実験を行った。「劣化画像利用時の分類器の分類精度」は、劣化した画像を入力とした際の領域分類器の概ねの分類精度である。実験1の劣化画像利用時の分類器が「分類精度100%」とあるのは、劣化していない画像を用いたことを表す。

表3 実験の種類

実験番号	劣化画像利用時の分類器の分類精度
実験1	100%(劣化なし)
実験2	80%前後
実験3	50%前後
実験4	20%前後
実験5	1%前後

図8と図9は実験2で用いた劣化した領域画像の例であり、図10と図11は実験5で用いた劣化した領域画像の例である。



図8 遮蔽物に相当する欠損により劣化させた眼周囲画像(分類精度80%前後)




図9 ぼかしにより劣化させた正規化虹彩画像(分類精度80%前後)



図10 遮蔽物に相当する欠損により劣化させた眼周囲画像(分類精度1%前後)




図11 ぼかしにより劣化させた正規化虹彩画像(分類精度1%前後)

5.6. 評価基準

実験の評価基準としてはMMSの領域分類器の選択精度と全体としての分類精度の2つを使う。

選択精度 P_s は、式(1)で定義される。

$$P_s = \frac{\text{MMSが正しく分類器を選択した回数}}{\text{全分類回数}} \times 100 \quad (1)$$

分類精度 P_c は、式(2)で定義される。

$$P_c = \frac{\text{分類に成功した回数}}{\text{全分類回数}} \times 100 \quad (2)$$

利用する分類手法は、下記の「ランダム」と「選択精度100%」の2つの手法を追加して比較した。

ランダム. MMSを利用せず、ランダムに分類器を選択する。

選択精度100%. MMSを利用せず、劣化していない画像を入力とする分類器を100%の確率で選択する。

5.7. 選択精度の実験結果

図12は、実験2～実験5の選択精度100%とMMS(SVM、RF、NN-6-20or50-80)の選択精度(P_s)のグラフである。NN-6-20or50-80は、アーキテクチャが6層の多層パーセプトロンで、劣化画像利用時の分類器の分類精度が20%または50%で、入力次元が80次元の場合である。横軸は、劣化画像利用時の領域分類器の分類精度であり、縦軸は選択精度(P_s)である。

MMSは、画像の劣化が大きい実験の時には選択精度が高くなっており、いずれかの入力画像の劣化が大きい時に正しく信頼性の高い(劣化していない画像を入力した)分類器を選択できていることを示している。




図 12 選択精度

5.8. 分類精度の実験結果

図 13 は、実験 1～実験 5 の選択精度 100%と MMS(SVM、RF、NN-6-20or50-80) の分類精度 (P_c) のグラフである。横軸は、劣化画像利用時の領域分類器の分類精度であり、縦軸は分類精度 (P_c) である。

実験 1～実験 5 において一般的な機械学習に基づく分類手法で実現された MMS の使用により、虹彩と眼周囲のいずれかの画像が著しく劣化していたとしても、94%以上の分類精度の維持を達成した。また、表 2 のテスト結果と同様な分類精度となり、分類精度が維持できていることがわかる。




図 13 分類精度

6. 結論

実験で得られた結論を示す。

- MMS は劣化度が大きくなるにつれて選択精度が高くなることで分類精度の維持を達成した。また MMS は一般的な機械学習に基づくクラス分類手法で実装可能であることを示した。また MMS は劣化していない画像を利用する分類器を選択するだけでなく、分類に有用である分類器を選択することで全体の分類精度の向上に貢献することを示した。
- MMS は固定の重みを利用するスコアレベルの融合手法と比べ分類精度を維持し、入力画像の劣化度の変化による分類精度の変動を抑えることがわかった。またスコアレベルの融合手法では、複数回の実験を繰り返し、最適な重みを導く必要があるが、MMS は一度の学習で分類器の選択則を獲得することができる。

7. 今後の課題

本研究では、画像の劣化に部分的に遮蔽を行う Random Erase と Gaussian Filter によるぼけを利用した。しかし、実際に利用する際はメガネや髪の毛など学習時にはないノイズが存在する。そのため実世界で存在する画像の劣化条件で評価をする必要がある。また、虹彩と眼周囲どちらも劣化している状態での認証精度の維持を図る必要がある。

参考文献

- [1] Zhang, Q., Li, H. and Sun, Z.: Deep Feature Fusion for Iris and Periocular Biometrics on Mobile Devices, *IEEE Trans. Inf. Forensics Sec*, Vol. 13, No. 11, pp. 2897–2912 (2018).
- [2] Amani, A., Muhammad, H., Hatim, A. and Aqil, A.: ConvSRC: SmartPhone-based periocular recognition using deep convolutional neural network and sparsity augmented collaborative representation, *J. Intelligent & Fuzzy Systems*, Vol. 38, No. 3, pp. 3041–3057, (2020).
- [3] Park, U.: Periocular Biometrics in the Visible Spectrum, *IEEE Trans. Inf. Forensics Sec*, Vol. 6, No. 1, pp. 96–106 (2011).
- [4] Kumar, V., Asati, A. and Gupta, A.: An Iris Localization Method for Noisy Infrared Iris Images, *IEEE ICSPA 2015*, pp. 208–213 (2015).
- [5] Daugman, J. G.: High Confidence Visual Recognition of Persons by a Test of Statistical Independence, *IEEE Trans. PAMI*, Vol. 15, No. 11, pp. 1148–1161 (1993).
- [6] Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *Int'l Conf on Learning Representations*, pp. 1–14 (2015).
- [7] Woodard, D. L., Pundlik, S., Miller, P., Jillela, R. and Ross, A.: On the Fusion of Periocular and Iris Biometrics in Non-ideal Imagery, *2010 ICPR*, pp. 201–204 (2010).
- [8] Gaikwad, D. and Thool, R. C.: Intrusion Detection System Using Bagging Ensemble Method of Machine Learning, *2015 Int'l Conf on Computing Communication Control and Automation*, pp. 291–295 (2015).
- [9] Yuksel, S. E.: Twenty Years of Mixture of Experts, *IEEE Trans.NN&LS*, Vol. 23, No. 8, pp. 1177–1193 (2012).
- [10] Tan, T.: CASIA Iris Image Database, <http://biometrics.idealtest.org/>.
- [11] Keys, R. G.: Cubic Convolution Interpolation for Digital Image Processing, *IEEE Trans.ASSP*, Vol. ASSP-29, No. 6, pp. 1153–1160 (1981).
- [12] He, K., Zhang, X., Ren, S. and Sun, J.: Deep Residual Learning for Image Recognition, *Proceedings of the IEEE Conf.CVPR*, pp. 770–778 (2016).
- [13] Noble, W. S.: What is a support vector machine?, *Nature Biotechnology*, Vol. 24, p. 1565–1567 (2006).
- [14] Ham, J., Chen, Y. and Crawford, M. M.: Investigation of the Random Forest Framework for Classification of Hyperspectral Data, *IEEE Trans.GS&RS*, Vol. 43, No. 3, pp. 492–501 (2005).