

スコア制限を用いた AOC 最小化に基づくカラーコンタクトレンズ検知モデルの学習

AOC optimization with score restriction for cosmetic contact lens detection

庄司 悠歩[†] 戸泉 貴裕[†] 佐藤 敦[†]
 Yuho SHOJI Takahiro TOIZUMI Atsushi SATO

1. はじめに

虹彩認証は識別性に優れ、電子決済や重要施設の入退管理等の高いセキュリティが必要な場面で応用されている。虹彩認証における認証阻害要因の一つにカラーコンタクトレンズ（以下、カラーコンタクトと表記）の着用があり、その検知は重要な課題となっている。撮影した目画像からカラーコンタクトを検知する手法が研究されており、特に近年では深層学習を利用した検知手法が提案されている[1]。

カラーコンタクト検知のような二値分類問題を解く深層学習モデルの学習には一般に誤差最小化に基づくバイナリクロスエントロピー（BCE）損失が用いられるが、二値分類の性能指標の一つである Area Under the Curve (AUC) スコアを最大化する損失が提案されている[2, 3]。AUC スコアはデータインバランスに依存しない指標であり、虹彩画像に比べてカラーコンタクト画像の取得が困難でデータ数が偏りやすいカラーコンタクト検知の評価に適している。

AUC を最大化する損失は訓練データの正例と負例のペアを用いて算出されるが、ペアの数は正例のデータ数と負例のデータ数の積に比例して大きくなる。このペアの一部をミニバッチで取得して学習する方法は学習の収束に時間かかり、さらにペアのうち大部分はモデルの学習への寄与が小さく学習が不安定になりやすい。

この問題を解決しモデルの学習効率と分類性能を改善するため本稿では ROC 曲線の上側の面積（Area Over the Curve, AOC）を、スコア制限を用いて最小化する損失関数を導入する。提案法は正例の最小スコアと負例の最大スコアを閾値としてハードサンプルを選択し損失を求める。これにより学習の収束効率と識別境界付近における分離性能を改善する。評価を訓練データに含まれない未知のカラーコンタクト画像に対して行い、カラーコンタクト画像と虹彩画像の分離に対する等価エラー率が、従来の誤差最小化に基づく学習方法と比較して改善する結果を示す。

2. 提案手法

2.1 AOC 最小化学習

まず従来手法である AUC スコアの算出方法及び AUC スコアを最大化する損失関数を説明する。クラス l の m 番目のデータに対するスコアを s_m^l とし、スコアが入力データに対する正例の尤度を表すとすると AUC スコアは次の式で求められる。

$$S_{AUC} = \frac{1}{N_+ N_-} \sum_{i=1}^{N_+} \sum_{j=1}^{N_-} I(s_i^+ > s_j^-) \quad (1)$$

ここで N_+ , N_- はデータ中の正例数、負例数を表し、関数 $I(\cdot)$ は引数が真のとき 1 を返す。先行研究においてモデルを AUC スコアが最大化するように最適化する、次の損失関数を最小化する学習方法が提案されている[2]。

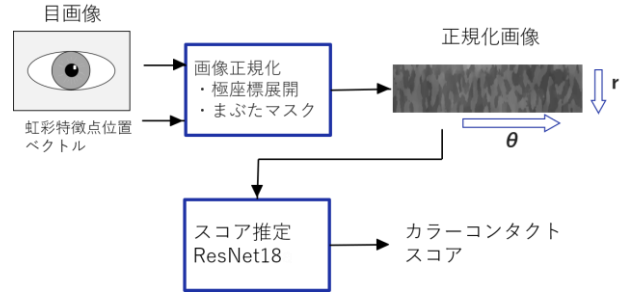


図 1 カラーコンタクト検知のブロック図

$$L_{AUC} = \frac{1}{N_+ N_-} \sum_{i=1}^{N_+} \sum_{j=1}^{N_-} \phi(s_j^- - s_i^+) \quad (2)$$

ϕ は単調増加関数であり、本実験では次の式で表されるロジスティック損失関数を用いる。

$$\phi = \log(1 + e^x) \quad (3)$$

L_{AUC} はデータ中のすべてのペアを用いて算出されるためデータ数が増えると学習の収束に時間がかかるようになる。

次に AOC スコアの算出方法を説明し、スコア制限を用いて AOC スコアを最小化する損失関数 L_{AOC} を提案する。ROC 曲線の上側の面積 AOC は AUC スコアと同様に 0 から 1 の間の値を取り、小さいほど分類器の判別性能が良いことを表す。AOC スコアを求める式は、

$$S_{AOC} = \frac{1}{N_+ N_-} \sum_{i=1}^p \sum_{j=1}^n I(s_i^+ < s_j^-) \quad (4)$$

と表される。ここで正例スコアの集合 P と負例スコアの集合 N はそれぞれ

$$P = \{s_i^+ | i = 1, \dots, p; s_i^+ < s_{max}^-\}$$

$$N = \{s_j^- | j = 1, \dots, n; s_{min}^+ < s_j^-\}$$

であり、 s_{min}^+ は正例の最小スコア、 s_{max}^- は負例の最大スコアを表す。AOC スコアは式(4)が示すように負例の最大スコアよりも小さい正例のスコア、正例の最小スコアより大きい負例のスコアを用いて算出される。AOC スコアの算出方法と同様に訓練データ中のハードサンプルを選択して AOC スコアを最小化する次の損失関数 L_{AOC} を提案する。

$$L_{AOC} = \frac{1}{N_+ N_-} \sum_{i=1}^p \sum_{j=1}^n \phi(s_j^- - s_i^+) \quad (5)$$

ここで ϕ はロジスティック損失関数を用いる。 L_{AOC} は正例の最小スコアと負例の最大スコアを閾値としてモデルの学習に重要なハードサンプルを選択し算出される。これにより学習に用いるペアの数を、 L_{AUC} を求める場合と比較して $\frac{pn}{N_+ N_-}$ 倍に削減し、モデルの学習効率と正例と負例に対する分離性能を改善することができる。

[†] 日本電気 NEC Corporation

2.2 カラーコンタクト検知手法

図 1 はカラーコンタクト検知のブロック図である。目画像と虹彩円の中心位置と半径を用いて、前処理としてまぶた領域のマスク処理とカラーコンタクト領域の極座標展開を行う。この画像を CNN モデルの ResNet18 に入力し、シグモイド関数により正規化された 1 次元のスコアを出力する。このスコアはカラーコンタクト画像である尤度を表す。

3. 実験

本章では撮影により収集したカラーコンタクト画像を用いて、提案手法の検知性能の評価を行う。提案手法との比較を行うため、既存の損失関数である AUC 最大化損失、BCE 損失を用いて学習したモデルも同様に評価する。便宜上、AUC 最大化損失と BCE 損失により学習したモデルをそれぞれ AUC モデル、BCE モデルと呼ぶ。また等価エラー率(EER)は偽陽性率 (FPR) と偽陰性率 (FNR) が等しくなるように閾値を決めたときのエラー率である。

3.1 学習条件

ResNet18 を提案法の損失関数 L_{AOC} (式(5))を用いて学習する。閾値となる正例の最小スコアと負例の最大スコアの初期値はそれぞれ 0 と 1 とする。最適化手法は確率的勾配降下法とし学習率を 0.001, 荷重減衰を 0.0001, モーメントを 0.9, バッチサイズを 256 とし合計 50,000 イテレーション学習する。データ拡張は輝度変化, 左右反転を行う。輝度の変化のレンジは $\pm 50\%$ とし, 左右反転を行う確率は 50% とする。500 イテレーション毎に損失の平均値を求め, 最も小さいときのモデルを用いて評価を行った。

3.2 データセット

訓練データとしてカラーコンタクト画像 10321 枚, 虹彩画像 55175 枚を用いてモデルの学習を行った。カラーコンタクト画像データは 33 名の画像から構成されており, 含まれるカラーコンタクトの種類は 33 種類である。虹彩画像データは撮影により収集した 200 名, 公開データセット CASIA-Iris-Thousand[4] の 1,000 名, CASIA-Iris-Lamp[4] の 410 名の合計 1,610 名の左右の目画像から構成されている。訓練データの内 2 割を検証用データとし, ハイパーパラメータの調整及び学習の収束の評価を行った。

テストデータセットにはカラーコンタクト画像 400 枚と虹彩画像 450 枚を用いた。カラーコンタクト画像は撮影により収集した 25 名の画像から構成されており, 含まれるカラーコンタクトの種類は訓練データに含まれる種類とは異なる 100 種類である。虹彩画像は公開データセット MMU-Iris を用いた。

3.3 実験結果

図 2 に提案法と AUC 最大化手法の, 検証データに対する学習イテレーション回数と AUC スコアの関係を示す。提案法で学習した場合の方が, AUC 最大化手法で学習した場合より二値分類の性能指標である AUC スコアの収束が速いことが確認できる。提案法によりモデルの学習に重要な識別境界付近のハードサンプルを選択して学習することで, モデルを安定して効率よく学習することができる。

図 3 にテストデータに対する提案法 (AOC) と AUC モデル, BCE モデルによる DET 曲線及び等価エラー率を示




図 2 検証データに対する学習回数と AUC スコアの比較

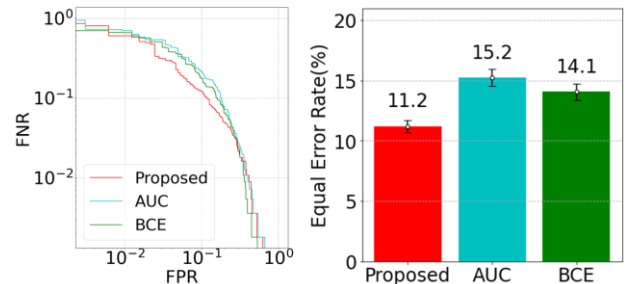


図 3 テストデータに対する DET 曲線と EER の比較

す。まず等価エラー率で比較を行うと提案法のエラー率が 11.2%でもっとも低く, AUC モデルの 15.2%や BCE モデルの 14.1%と比べて精度が改善していることが確認できる。次に FPR が 10%, 1% となるときの FNR の比較をそれぞれ行うと, FPR が 10% のとき, 提案法, AUC モデル, BCE モデルの FNR はそれぞれ 12.2%, 21.2%, 17.7% となり, FPR が 1% のときは 60.0%, 70.1%, 66.2% となった。提案法により複数の閾値に対する FNR が改善していることが確認できる。また AUC スコアを用いて学習手法の比較を行うと, 提案法, AUC モデル, BCE モデルはそれぞれ 94.4, 93.7, 93.9 となり, 提案法の AUC スコアが最も高く識別性能を改善できることが確認できる。

4. おわりに

本稿では ROC 曲線の上側の面積である AOC を, スコア制限を用いて最小化する学習方法を提案した。提案法は正例の最小スコアおよび負例の最大スコアに基づき識別境界付近のデータを選択して AOC を最小化することで, 識別境界付近における分離性能を改善する。提案手法を虹彩認証における認証阻害要因の一つであるカラーコンタクトの検知に適用したところ, 等価エラー率が従来の学習方法による場合と比較して 14.1% から 11.2% に改善され, 分離性能の向上が確認できた。

参考文献

- [1] D. Yadav, N. Kohli, M. Vatsa, R. Singh, and A. Noore. Detecting textured contact lens in uncontrolled environment using densepad. CVPRW (2019).
- [2] Wei Gao and Zhi-Hua Zhou. On the consistency of auc pairwise optimization. In IJCAI (2015).
- [3] Zhuoning Yuan, Yan Yan, Milan Sonka, and Tianbao Yang. Robust deep AUC maximization: A new surrogate loss and empirical studies on medical image classification. arxiv (2020)
- [4] Center for Biometrics and Security Research." <http://www.cbsr.ia.ac.cn/english/IrisDatabase.asp>(accessed June, 2022)