

令和5年度卒業論文  
FaceNetを用いた牛顔画像による個体識別の  
ハイパーパラメータチューニング

宮崎大学工学部情報システム工学科

戸高海輝

指導教員 椋木 雅之 教授

## 概要

本論文では、牛顔画像による個体識別の精度を上げるハイパーパラメータチューニングについて、探索的に調査した。個体識別の技術としては、深層学習の1種である FaceNet を用いた。牛顔画像による個体識別の先行研究として、時任の研究がある。この研究は深層学習による個体識別技術として FaceNet を用い、FaceNet の牛への適用可能性を調査したものである。FaceNet の評価結果として、SVM を用いた従来手法より高い識別性能が得られるとしている。しかし、この研究では FaceNet の学習を1通りの設定でしか行っておらず、学習時のハイパーパラメータを調整すれば、より精度の高い個体識別が実現できると考えた。「CNN モデル」「データ拡張」「学習率」「トリプレットの選択法」の4つのハイパーパラメータを取り上げ、これらのチューニングにより、牛顔画像による個体識別の精度向上を試みた。実験の結果、CNN モデルを「ResNet34」、データ拡張を「左右反転+回轉變換+CutOut+ぼかし」、学習率を「0.001」、トリプレットの選択法を「ハードネガティブ」にした場合に 0.95266 の精度が得られた。これはチューニング前の基準値での精度 0.92633 より 0.026 ポイント向上しており、ハイパーパラメータチューニングの効果を示すことができた。

## 目次

1. はじめに .....	1
2. 顔画像による個体識別 .....	4
2.1 牛個体識別の必要性 .....	4
2.2 牛個体識別の従来研究 .....	4
2.3 FaceNet .....	5
3. ハイパーパラメータチューニング .....	8
3.1 ハイパーパラメータとは .....	8
3.2 ハイパーパラメータチューニングの従来手法 .....	8
3.3 チューニング対象となるハイパーパラメータ .....	10
3.3.1 CNN モデル .....	10
3.3.2 データ拡張 .....	11
3.3.3 学習率 .....	13
3.3.4 トリプレットの選択法 .....	13
4 実験 .....	15
4.1 評価方法 .....	15

4.2 パラメータチューニングの基準値.....	16
4.3 CNN モデルの評価 .....	17
4.4 データ拡張の評価 .....	18
4.5 学習率の評価.....	20
4.5 トリプレットの選択法の評価.....	22
4.6 考察 .....	23
5 結論.....	24
謝辞.....	25
参考文献 .....	26

## 1.はじめに

農業において畜舎内の個体識別は重要な課題の一つである。個体識別は牛の健康管理や繁殖管理など様々な場面で利用されている。従来は個体識別に耳標や RFID タグなどが用いられることが多かった。しかし、耳標は汚れや牛の動きで読み取りにくかったり、破損・欠落によって利用できない場合がある。RFID タグは、タグの埋め込みで牛にストレスを与える上、タグ自体や読み取り装置のコストが問題となっている。

このような問題を解決するために、画像認識技術が用いられることが増えてきている。近年、深層学習による画像認識技術は高い精度を実現している。

顔画像による個体識別手法の 1 つに FaceNet[1]がある。FaceNet とは Google が 2015 年に開発した顔識別手法である。顔画像から特徴量を抽出し、その特徴量をもとに顔の識別を行う。FaceNet は人間の顔識別において高い性能を示している。

FaceNet を用いた牛顔画像による個体識別の先行研究として、時任[2]がある。この研究は深層学習による顔識別技術として FaceNet を用い、FaceNet の牛への適用可能性を調査したものである。FaceNet の評価結果

として、SVM を用いた従来手法より高い識別性能が得られるとしている。しかし、この研究では FaceNet の学習を 1 通りの設定でしか行っていない。学習時の各種パラメータを調整すれば、より精度の高い個体識別が実現できると考えられる。

そこで、本研究では時任の研究[2]を踏まえ、牛顔画像による個体識別の精度を上げるハイパーパラメータチューニングについて探索的に調査する。ハイパーパラメータとは機械学習アルゴリズムの挙動を設定するパラメータを指す。このハイパーパラメータの値に応じてモデルの精度やパフォーマンスが大きく変わることがある。例えば、ACM Conference on Recommender Systems (RecSys) 2019 のベストペーパーに選出された文献[3]において、十分にチューニングされた古典的な手法が近年提出された多くの深層ニューラルネットワークをベースとした手法を上回る性能を達成したことで、チューニングの重要性が再認識されることとなった。近年ではハイパーパラメータを自動的に最適化する手法も多くなっている。しかし自動最適化は、機械学習モデルの性能を示す損失関数の評価コストの高さ、探索空間の複雑性から非常に時間がかかるという問題がある。そのため本研究では、ハイパーパラメータチューニングを手動で行う。具体的にはチューニングするハイパーパラメー

タを事前に決定し、探索的に調査していく。

本論文の構成は次のとおりである。第2章では、顔画像による個体識別の従来手法について述べるとともに、本研究で用いる FaceNet について説明する。第3章ではハイパーパラメータチューニングの従来手法と、本研究で対象とするハイパーパラメータについて説明する。第4章ではハイパーパラメータの値を変えながら精度を探索的に評価していく。最後に第5章では、結論と今後の課題を述べる。

## 2. 顔画像による個体識別

### 2.1 牛個体識別の必要性

牛の個体識別は農業において重要な課題の1つであり、牛の健康管理や繁殖管理などに欠かせないものである。牛の一生を通じて健康状態や生産性を正確に追跡することができるとともに、繁殖計画の策定や管理のための基礎データを提供することができる。このような情報を利用することで農業経営者は最適な繁殖管理策を採用でき、生産性の向上やコストの削減に寄与することができると考えられる。

牛の個体管理について、牛トレーサビリティ制度により、牛管理者に対して国内で飼育されている牛の個体識別情報の届け出が義務化されている。牛トレーサビリティ制度とは、牛や牛肉に関する問題が発生した際に、それらの追跡を可能にし、国産牛肉の安全・安心を確保することを目的に制定された制度である。届け出が必要な個体識別情報には10桁の個体識別番号、性別や種別、出生から飼養地までの情報などが含まれている。

### 2.2 牛個体識別の従来研究

牛個体識別の手法の1つに、画像認識を利用したものがある。森尾ら[4]は、ホルスタイン牛の体の斑紋画像を使った個体識別を行っている。



KL 展開により作成した固有空間上でユークリッド距離により識別することで、画像撮影時の牛の姿勢及び照明条件が変化しない状況において 100%の識別を行うことができた。近年は、深層学習を用いた牛個体識別も行われている。Xu ら[5]は、牛顔画像による個体識別の枠組みである CattleFaceNet を提案した。CattleFaceNet では、RetinaFace[6]のバックボーンに軽量の MobileNet[7]を用いたもので牛顔検出を行い、ArcFace[8]を顔識別に使用している。これらの組み合わせにより、91.3%の個体識別精度を得た。

本研究では時任[2]の研究をもとに牛個体識別を行う。時任は、FaceNet に 531 頭、50,856 枚の牛顔画像を学習させて、牛顔画像による個体識別器を構築した。この個体識別器により、94.8%の精度で個体識別が行えることを示した。

## 2.3 FaceNet

画像認識による顔識別手法の 1 つに、時任[2]の研究でも用いられた FaceNet[1]がある。FaceNet とは Google が 2015 年に開発した顔識別手法である。FaceNet は顔画像から特徴量を抽出し、その特徴量をもとに顔の識別を行う。

FaceNet は 3 つのステージから構成されている。1 つ目のステージは、

顔画像から特徴量を抽出するための畳み込み層（Convolutional Neural Network;CNN）である。2つ目のステージは、特徴量を正規化し、顔の識別に適した特徴量に変換するための全結合層である。3つ目のステージは、特徴量をもとに顔の識別を行うための Triplet loss 層である。

Triplet loss 層は、類似した画像間の距離を近づけ、類似していない画像間の距離を離すことを目的とする。Triplet loss はアンカー画像、正解画像、不正解画像の3つの画像から構成される（図1）。

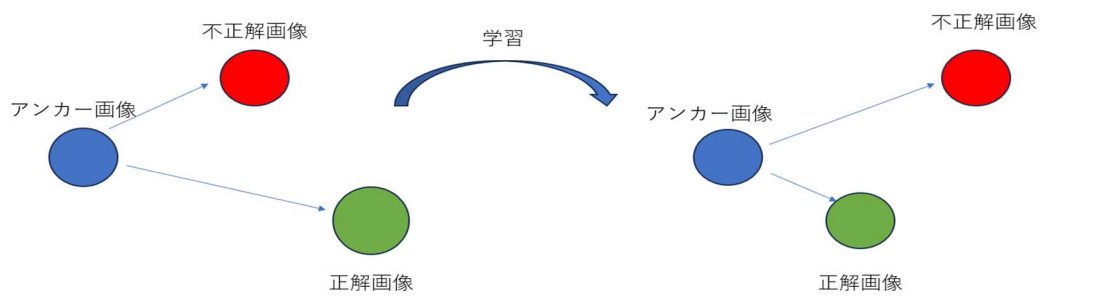


図1：トリプレット・ロス

アンカー画像を基準とする、正解画像はアンカー画像と同じクラスに属する画像である。不正解画像は、アンカー画像とは異なるクラスに属する画像である。学習の際には、アンカー画像から正解画像への距離（ポジティブ距離）がアンカー画像から不正解画像への距離（ネガティブ距離）よりも小さくなるように学習を行う。具体的には事前に定めたパラメータ（マージン）に基づいて、ポジティブ距離がネガティブ距離よりマージン幅以上に小さくなるようにする。これによりアンカー画像と正

解画像の類似度が高く、アンカー画像と不正解画像の類似度が低くなる。Triplet loss は距離関数としてユークリッド距離を用いることが一般的である。

識別時には、既知の牛の顔画像を最低一枚用意し、未知の牛の顔画像との距離を求め、距離があらかじめ定めた閾値以内であれば同じ牛個体と判定する。これにより、一度 Facenet の学習を行えば、識別したい各牛個体について、顔画像を最低一枚用意すれば、識別が行える。

本研究では深層学習による顔認識技術として Facenet を用い、顔認識の精度を上げるハイパーパラメータチューニングについて探索的に調査する。

## 3. ハイパーパラメータチューニング

### 3.1 ハイパーパラメータとは

ハイパーパラメータとは機械学習アルゴリズムの挙動を設定するパラメータを指す[9]。代表的なものとして、エポック数、学習率、閾値、ミニバッチサイズ、層の数、一層あたりのニューロン数、などが挙げられる。2.3章で述べたマージンもハイパーパラメータの1種である。このハイパーパラメータの値に応じてモデルの精度やパフォーマンスが大きく変わることがある。

### 3.2 ハイパーパラメータチューニングの従来手法

一般に、機械学習モデルの性能を十分に引き出すためには、モデルのハイパーパラメータを適切に設定する必要がある[10]。そのため、様々なアプローチによりハイパーパラメータのチューニングが行われている。

ハイパーパラメータチューニングの代表的なアプローチの1つにグリッドサーチがある。グリッドサーチとは、与えられたハイパーパラメータの候補の値の全組合せでモデル構築をして、最良の値を求める手法である。例えば、A、B 2つのハイパーパラメータがあり、Aは {1,2,3}、Bには {T,F} の値をとり得るとする。グリッドサーチではこれらの値のすべての組み合わせを使ってモデル構築を行い結果を検証する。この例の

場合は6通りのモデルをすべて構築し、最良の組み合わせを求める。グリッドサーチは、調整するハイパーパラメータの数が少ない場合やある程度の「あたり」がついている場合に使用することが多い手法である。全組合せのモデルの構築を行うので、大規模データなど構築時間が長い場合は、グリッドサーチの使用は現実的ではない。

グリッドサーチが適用できない場面で、代替策として使われる手法としてランダムサーチがある。ランダムサーチは、ハイパーパラメータの候補の値をランダムに組み合わせてモデルを構築し、その中で最良の値を求める手法である。ランダムサーチの場合は試行するハイパーパラメータの組み合わせの数を指定する。これによりハイパーパラメータの可能な組み合わせの数が多くても対応することが可能になる。しかし、ランダムに検証するため結果が運任せになってしまう。

ハイパーパラメータを探索的に求める手法として、ベイズ最適化がある。ベイズ最適化とは、不確かさを利用して次に探索を行うべき値を探していく最適化アルゴリズムの1種である。ベイズ最適化は「探索」と「活用」の2つの戦略を使って最適化を順次的に行う。活用とは、以前にやってみてよい結果が出たため、継続してその近辺を調べてみることである。対して探索は、もっと良い結果があると考えて、あえて異なる

部分を調べることを指す。ベイズ最適化では「前回の結果を踏まえて次をバランスよく試す」ことが可能である。

本論文では、モデルの構築に時間がかかり、ハイパーパラメータの可能な組み合わせが多いため、グリッドサーチは使えない。また、ハイパーパラメータをすべてランダムに決めてもハイパーパラメータの良い組み合わせが得られる可能性が低い。そこで、手動で「ベイズ最適化」を使って、探索的にハイパーパラメータチューニングを行っていく。

### 3.3 チューニング対象となるハイパーパラメータ

本論文でチューニングするハイパーパラメータは「CNN モデル」、「データ拡張」、「学習率」、「トリプレットの選択法」の4つである。これらのハイパーパラメータを順に探索的にチューニングしていく。以下にてそれぞれのハイパーパラメータについての説明となぜその値を変更するのかを述べていく。

#### 3.3.1 CNN モデル

CNN モデルとは、畳み込み層とプーリング層をもつニューラルネットワークである。FaceNet では、特徴抽出を行う畳み込み層（2.3 章の1つ目のステージ）として、任意の CNN モデルを使用することができる。本論文では、この CNN モデルとして、「resnet18」「resnet34」「resnet50」

「resnet101」「mobilenetv2」の5つを比較する。

Resnet とは残差ブロックと呼ばれる畳み込み層と skip connection を組み合わせたものを繰り返して構成されるモデルのことで、残差ブロックを導入したことによって、層をより深くすることができ、精度向上につながった。18などの数字はモデルの層数を表す。本論文では、ResNetの代表的な層数である18,34,50,101層のものを扱う。

Mobilenetv2 はモバイル端末でも使用できるほど計算量やメモリ使用量が小さく、精度と計算負荷のトレードオフを調整することができるアーキテクチャである。このモデルは CattleFaceNet[5]において高い精度を得ることができたため本論文でも使用する。

### 3.3.2 データ拡張

データ拡張[11]とは、機械学習で学習する際、十分に学習用データが存在していない、もしくは手持ちの学習用データが偏っている場合、過学習を防ぎ汎化性能を向上させるために、手持ちの学習用データに何らかの処理を施してデータを増やすことである。過学習とは学習用データに機械学習モデルが適合しすぎることにより、テストデータに対する適合率が下がることである。

本論文で調査した手法は「ぼかしを入れる」「アフィン変換を行う」

「色変換を行う」「CutOut」の4つである。「ぼかしを入れる」とは、学習時にガウシアンフィルタをかける手法のことであり、ガウシアンフィルタの大きさおよびぼかしの強さを調整することができる。本論文では、ガウシアンフィルタの大きさを3、ぼかしを行うためのカーネルを作成するために使用される標準偏差の範囲を0.1~2.0と定めた。「アフィン変換」とは、画像を回転させたり、平行移動させたり、拡大縮小をする手法である。本論文では回転角度を $\pm 10$ 度、平行移動量を縦横ともに $\pm 10\%$ 、画像の拡大縮小率の変動幅は0.9倍~1.1倍、横軸に平行なせん断の範囲 $\pm 0.1$ を範囲とする。「色変換」とは、明るさの変動やコントラスト、彩度、色相を変更する手法である。明るさの変動は0.7倍~1.3倍の範囲で、コントラストは0.5倍~1.5倍の範囲で、彩度は0.5倍~1.5倍の範囲で、色相は $\pm 0.2$ の範囲で変動させている。「CutOut」とは、画像中のランダムな位置において矩形領域で画像をマスクする手法である。ランダム消去される確率を50%、入力画像に対する消去領域の割合の範囲を2%~33%、消去領域の縦横比の範囲を0.3倍~3.3倍を範囲とする。この4つを対象にした理由は本研究の学習データの中には正面を向いていなかったり、画面のサイズが統一されていなかったり、回転しているデータなどもあるため、データ拡張は形状変換または濃度変換のも



のが効果的であると考えためである。

### 3.3.3 学習率

学習率とは最適化手法に用いられるハイパーパラメータであり、「勾配に沿って一度にどれだけ降りていくか」を決めるものである。最適化手法とはモデルの精度を上げるために損失関数を最小化させる手法のことである。本研究では「Adam」という最適化手法を使用する。

Adam[12]とは、慣性項（モーメンタム）により学習の安定化を図るとともに、各パラメータ個別の学習率を調整する最適化手法である。学習率をどれくらいにするかは非常に重要で、学習率が小さすぎると学習の進みが遅くなり、学習率が大きすぎると最適解付近を往復してしまう。本論文では「0.005」「0.001」「0.0005」「0.0001」「0.00005」で調査する。

### 3.3.4 トリプレットの選択法

本論文では、トリプレットの選択法として、ハードネガティブとセミハードネガティブを扱う。FaceNetでは、アンカー画像から不正解画像までの距離である「ネガティブ距離」からアンカー画像から正解画像までの距離である「ポジティブ距離」を引いた値が、異なるクラスやグループのサンプル間の距離を調整するためのパラメータである「マージン」より少ないトリプレットのみを学習に使用していた。これをハード

ネガティブという。これに対してセミハードネガティブとはハードネガティブの条件に加えてポジティブ距離がネガティブ距離より小さい場合という条件を付けたものである[13]。ハードネガティブよりもセミハードネガティブの方が学習に使うトリプレットを減らし、学習が効率的になると考えられる。そのためこの両者を比較する。

## 4 実験

### 4.1 評価方法

「CNN モデル」「データ拡張」「学習率」「トリプレットの選択法」の4つハイパーパラメータを探索的にチューニングして、牛顔画像を学習し、精度評価を行う。本研究ではモデルの性能を評価するために Accuracy（精度）という評価指標を用いる。Accuracy の定義は以下のとおりである。

$$\text{Accuracy} = \frac{(\text{True\_positive} + \text{True\_negative})}{\text{すべてのデータ}}$$

True\_positive=（本当は同じ牛に対して同じ牛と予測したケース）

True\_negative=（本当は異なる牛に対して異なる牛と予測したケース）

学習用データには牛 349 頭、112,952 枚の顔画像が含まれている。評価用データには、学習用データとは異なる牛 81 頭、49,302 枚の顔画像が含まれている。評価用データは牛の顔が映っている 1 つの動画を前半と後半に分け 1 フレームごとに画像に変換したものである。評価の際には前半と後半から顔画像を 1 枚ずつ取り、同じ牛同士の組み合わせ 3000 組、異なる牛同士の組み合わせ 3000 組により精度評価する。以降のすべての実験において、同じ 6000 組の組み合わせで評価を行う。評価用データの画像からすべての組を取り出し、各モデルに与えて特徴量を算出す

る。得られた特徴量間のユークリッド距離が閾値以下であれば同じ牛、閾値より大きければ異なる牛として判定する。テストデータ 6000 組のデータを 10 個に分割し、そのうちの 9 個を使い、残り 1 個の精度を求める。これを 10 通り行い、その平均の値を評価結果とする。

## 4.2 パラメータチューニングの基準値

本研究では、GitHub で公開されている FaceNet のプログラム[14]を改変してパラメータチューニングを行う。[14]のプログラムのハイパーパラメータのデフォルト値を使った結果を、チューニング前の基準値とする。ハイパーパラメータのデフォルト値を表 1 に示す。この時、Accuracy は 0.92633 となった。

表 1：本論文の基準となる値を求めるために使用したハイパーパラメータとその精度

ハイパーパラメータ	値
CNN モデル	ResNet18
データ拡張	左右反転、回轉變換
学習率	0.005
エポック数	100
トリプレットの選択法	ハードネガティブ
Accuracy	0.92633

### 4.3 CNN モデルの評価

本論文のチューニング対象である CNN モデル「ResNet18」  
「ResNet34」「ResNet50」「ResNet101」「MobileNetv2」を使用して学習  
し、それぞれの Accuracy を評価した。各モデルの精度を表 2 に示す。

表 2：CNN モデルの評価結果

CNN モデル	精度(Accuracy)
Resnet18	0.92633
Resnet34	0.92883
Resnet50	0.91800
Resnet101	0.92283
Mobilenetv2	0.91660

## 評価

ResNet は層数を増やすほど精度が向上すると考えていたが精度が高かったのは ResNet34、ResNet18、ResNet101 の順であった。ResNet の層を増やしても精度に大きな変化はなかった。学習時間は、Mobilenetv2、ResNet18、ResNet34 の順に短かった。データ拡張以外の実験では一番精度の高かった ResNet34 を用いる。

### 4.4 データ拡張の評価

本論文のチューニング対象であるデータ拡張「ぼかしを入れる」「アフィン変換を行う」「色変換を行う」「CutOut」を追加して学習し、それぞ

れの Accuracy を評価した。結果を表 3 に示す。(学習時間を考慮して、この実験では CNN モデルとして ResNet18 を用いた。)

表 3 : データ拡張の評価結果

データ拡張	精度 (Accuracy)
左右反転、回轉變換	0.92633
+ぼかし	0.92766
+アフィン変換	0.92633
+色変換	0.88716
+CutOut	0.92966
+CutOut+ぼかし	0.93033
+CutOut+ぼかし+アフィン変換	0.92616

## 評価

チューニング前の基準値では、左右反転と回轉變換のデータ拡張がされている。表 3 はこれらのデータ拡張に、本論文でチューニング対象とするデータ拡張を追加した結果である。データ拡張を 1 つずつ追加した場合、「CutOut」「ぼかし」で精度が向上しており、「アフィン変換」では

変わらず、「色変換」では低下した。データ拡張は、組み合わせることで精度が変化する。「CutOut」と「ぼかし」の両方を追加した場合、更に精度が向上したが、「アフィン変換」も追加すると精度が低下した。これらの結果から、データ拡張では、左右反転+回轉變換+CutOut+ぼかしの組み合わせを今後の実験で使用する。

#### 4.5 学習率の評価

本論文のチューニング対象である学習率「0.005」「0.001」「0.0005」「0.0001」「0.00005」を使用して学習し、それぞれの Accuracy を評価した。これまでの評価は100エポックで学習していたがエポック数を増やせば学習の回数が増え、精度が向上すると考えた。エポック数を500で学習させた精度の推移を図1に示す。精度が急激に上がるのは100エポック前で完了しており、その後は値が増減している。よって学習率の評価では500エポックまでで最高値の精度を評価結果とする。






図 1 : 500 エポックまで学習をした精度

学習率を変化させて学習した結果を表 4 に示す。

表 4 : 学習率を変えて 500 エポックまで学習した評価結果

学習率	精度(Accuracy)	最高精度が出たときのエポック数
0.005	0.94416	111
0.001	0.95266	392
0.0005	0.95233	468
0.0001	0.94783	488
0.00005	0.94683	465

## 評価

一番精度が高かったのは学習率が 0.001 の時で精度は 0.95266 であった。学習率を増やしても減少させても精度が低下することから本実験では学習率 0.001 が最良と考えられる。表 4 より、最高精度が出たエポック数は、どの学習率でも 100 エポック以降となっている。精度向上のためには、ある程度多くのエポック数で学習させる必要があることが分かった。

### 4.5 トリプレットの選択法の評価

トリプレットの選択法として基準値である「ハードネガティブ」と「セミハードネガティブ」を比較した。結果を表 5 に示す。

表 5：トリプレットの選択法による評価結果

トリプレットの選択法	精度(Accuracy)
ハードネガティブ	0.95266
セミハードネガティブ	0.94916

## 評価

トリプレットの選択法をセミハードネガティブに変更すれば精度が上がると思っていたが、セミハードネガティブに変更したときの方が精度

が落ちた。

## 4.6 考察

本研究でのハイパーパラメータのチューニング結果と精度を表6にまとめると、基準値での精度が0.92633であったのに対し、ハイパーパラメータチューニングの結果、0.95266の精度を得られ、0.026ポイント精度が向上した。時任[2]の実験とは、使用したデータ等が異なっており、単純な比較はできないが、ハイパーパラメータチューニングの効果を示すことができた。

表6：本研究でのハイパーパラメータのチューニング結果と精度

ハイパーパラメータ	値
CNN モデル	ResNet34
データ拡張	左右反転 + 回転変換 + CutOut + ぼかし
学習率	0.001
エポック数	500
トリプレットの選択法	ハードネガティブ
精度 (Accuracy)	0.95266

## 5 結論

本研究では、FaceNet を用いた牛顔画像における個体識別において、ハイパーパラメータチューニングによる精度向上を試みた。その結果、本研究において最も Accuracy が高くなるハイパーパラメータは「CNN モデル ResNet34」「データ拡張 ぼかし+CutOut」「学習率 0.001」「トリプレットの選択法 ハードネガティブ」の組み合わせであった。これにより精度を 0.92633 から 0.95266 に 0.0263 ポイント向上させることができた。

今後の課題としては、調査したハイパーパラメータの種類（例えば、オプティマイザーやデータ拡張の種類や組合せなど）を増やすことが挙げられる。

## 謝辞

本研究を行うにあたり、多大な助言と支援をいただいた椋木雅之教授に感謝いたします。そして、研究の相談や議論を通して、多くの知識や示唆をいただいた椋木研究室の皆様にお礼申し上げます。

## 参考文献

- [1] Schroff Florian, et al., “FaceNet: A Unified Embedding for Face Recognition and Clustering”, IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp 815-823,2015
- [2] 時任大輝, “FaceNet を用いた牛の個体識別”,宮崎大学工学部情報システム工学科令和 4 年度卒業論文, 2023
- [3] M.F. Dacrema, P. Cremonesi,D. Jannach, “Are we really making much progress? a worrying analysis of recent neural recommendation approaches,” ACM Conference on Recommender Systems, pp.101–109,2019
- [4] 森尾吉成,池田善郎,”KL 展開を利用した斑紋による乳牛の個体識別”,農業機械学会誌,vol.64,no.2,pp84-92, 2002
- [5] Beibei Xu,et al.,” CattleFaceNet: A cattle face identification approach based on RetinaFace and ArcFace loss”, Computers and Electronics in Agriculture vol.193, 106675, 2022
- [6] J. Deng, J. Guo, E. Ververas, I. Kotsia, S. Zafeiriou,”Retinaface: Single-shot multi-level face localisation in the wild” ,IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR),2020

- [7] Andrew G. Howard, et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications", arXiv:1704.04861v1 2017
- [8] Deng, Jiankang, et al., "ArcFace: Additive Angular Margin Loss for Deep Face Recognition", IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018
- [9] 機械学習におけるハイパーパラメータとは？概要やチューニング方法を解説 | TRYETING Inc. (トライエティング)  
<https://www.tryeting.jp/column/6830/>
- [10] M. Feurer, F. Hutter, "Hyperparameter optimization," Automated Machine Learning, pp.3–33, 2019
- [11] データ拡張 (Data Augmentation) 徹底入門！Python と keras でデータ拡張を実装しよう  
[https://www.codexa.net/data\\_augmentation\\_python\\_keras/](https://www.codexa.net/data_augmentation_python_keras/)
- [12] Diederik P. Kingma, et al., "ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION", arXiv:1412.6980v9, 2017
- [13] Deep Metric Learning の定番?! Triplet Loss を徹底解説  
<https://qiita.com/tancoro/items/35d0925de74f21bfff14>
- [14] GitHub - tamerthamoqa/facenet-pytorch-glint360k: A PyTorch

implementation of the 'FaceNet' paper for training a facial recognition model with Triplet Loss using the glint360k dataset. A pre-trained model using Triplet Loss is available for download.

<https://github.com/tamerthamoqa>

[/facenet-pytorch -glint360k?tab=readme-ov-file](https://github.com/tamerthamoqa/facenet-pytorch-glint360k?tab=readme-ov-file)