

令和7年度 卒業論文

# 牛顔画像を用いた個体識別における MagFace による悪条件画像の自動抽出

宮崎大学 工学部 工学科 情報通信工学プログラム  
60220086  
有馬 巧海

指導教員 棕木 雅之教授

令和8年2月6日

## 概要

本研究では、深層学習による顔画像識別において「識別に適さない」と判断する悪条件画像を自動的に抽出する手法を構築した。さらに、それらの画像が共通して持つ特徴を明らかにし、個体識別の精度の向上を図った。

畜産現場における個体管理の効率化に向け、顔画像を用いた牛の個体識別技術が注目されている。しかし、実環境で撮影された画像には撮影時の環境や被写体の状態などの要因により、識別精度を著しく低下させる「悪条件画像」が含まれる。このような画像はそもそも識別に適さないため、自動的に排除する仕組みが望まれている。

本研究は悪条件画像を自動抽出するために、顔画像の品質評価と特徴抽出を同時に行うMagFaceを採用した。MagFaceによって算出される特徴量ノルムが画像の品質と相関することを利用し、ノルムが低い画像を悪条件画像として自動抽出した。さらに、抽出された画像を除外して個体識別の精度を測定することで本手法の評価を行った。

実験の結果、特徴量ノルムに基づき悪条件画像を精度よく分離できることを確認した。悪条件画像の分析の結果、ノルムが低くなる要因として、「顔と背景のコントラスト差が極端に低いこと」「学習データと評価データ間におけるの鼻紐の装着状態の差異」「学習データの不足によるモデルの過学習」の3点が特定された。また悪条件画像を除いて個体識別を行うことで精度向上が確認できた。

本手法により、データセットから不適切な画像を自動的に排除することが可能となった。今後は特定された要因に基づき、撮影環境の改善やデータ拡張を行うことで、さらなる識別精度の向上が期待される。

# 目次

第1章	はじめに.....	1
第2章	牛顔個体識別と悪条件画像.....	2
2.1	牛顔個体識別.....	2
2.2	悪条件画像.....	3
2.3	悪条件画像に関する従来研究.....	3
第3章	MagFaceによる悪条件画像の自動抽出.....	5
3.1	深層学習における悪条件画像.....	5
3.2	Arcface.....	5
3.3	MagFace.....	6
3.4	悪条件画像の自動抽出法.....	7
3.5	MagFaceの学習.....	7
3.6	自動抽出結果.....	9
第4章	悪条件画像の分析.....	12
4.1	悪条件画像の要因の考察.....	12
4.2	顔と背景のコントラスト差.....	12
4.3	学習時と識別時の鼻紐の有無.....	15
4.4	学習データの偏り.....	17
4.5	悪条件画像の分析結果に関する考察.....	20
第5章	悪条件画像の自動抽出による識別性能評価実験.....	21
5.1	実験設定.....	21
5.2	閾値の変化に伴う識別精度の推移.....	21
5.3	特徴量ノルムと推論スコアに基づく抽出手法の比較.....	23

第6章 おわりに.....	27
謝辞.....	28
参考文献.....	29

## 第1章 はじめに

個体識別は、畜産分野において疾病管理や成長履歴の正確な把握などの観点から極めて重要な課題である。従来、この個体識別には耳標などの装着具が主に用いられてきた。しかし、耳標には破損や紛失のリスク、あるいは汚損によって読み取りが困難になるなどの問題が指摘されている。こうした背景から、近年では家畜管理の効率化と生産性向上を目指し、情報通信技術の活用が進められている。特に牛の顔画像を用いた個体識別に関する研究は、個体ごとの固有の特徴を素早く容易に抽出できる手法として注目されている。

牛の顔画像を用いた個体識別は、人の顔認識と同様に、深層学習を用いることで比較的容易に実現可能である。しかしながら、実環境で撮影された画像を用いた場合、識別精度が必ずしも十分に高いとは言えない。

本論文では撮影時の環境や被写体の状態によって識別に悪い影響を与えている画像を悪条件画像とする。谷山[1]の研究では、顔の向きが異なる画像や、ぼやけた画像を悪条件画像として扱っている。さらに、悪条件画像とされる画像をデータセットから取り除いた上で、顔個体識別精度への影響を評価している。具体的には、顔の向きや画像の鮮明さといった条件に基づいて画像を分別し、悪条件画像を除外した場合と除外しない場合の識別精度を比較している。その結果、顔の向きを限定することによる識別精度の上昇は見込めたが、ボケ画像除去による改善は見込めなかった。この結果から、人の想定する悪条件画像だけでなく、深層学習において有効な画像特徴量が抽出できている画像にどのような傾向があるか考え、優良な画像に絞って評価することが重要であると考えられる。

このような課題に対して、本研究では顔認識分野で提案されている MagFace に着目する。MagFace は、画像特徴量のノルムを画像品質の指標として利用し、高品質な画像ほど大きなノルムを持つように学習する手法である。この性質を利用することで、従来の主観的な基準ではなく、特徴表現に基づいた画像品質の評価および選択が可能になると考えられる。

本研究の目的は、牛の顔画像を用いた個体識別において MagFace を適用し、画像特徴量のノルムに基づいて高品質な画像を選択することで、顔個体識別精度の向上を図ることである。具体的には、MagFace を用いて学習させ、特徴量ノルムに対して閾値を設けることで悪条件画像を自動抽出する。次に、抽出された悪条件画像がどのような傾向を持つかについて分析を行う。さらに、悪条件画像を取り除いたデータセットを用いて個体識別性能を評価することにより、悪条件画像を明確化するとともに顔画像識別の精度向上を図る。

本論文の構成は以下のとおりである。第2章では、牛の個体識別および顔認識に関する関連研究について述べる。第3章では、MagFace を用いた悪条件画像の自動抽出手法について説明する。第4章では、抽出した悪条件画像の傾向について画像の明度、学習データ画像の鼻紐の有無、学習データ量の3つの観点で分析を行う。第5章では、本研究で用いた学習モデルの識別精度評価を行い、学習モデルについて考察する。第6章では本研究のまとめと今後の課題について述べる。

## 第2章 牛顔個体識別と悪条件画像

### 2.1 牛顔個体識別

畜牛において牛個体識別は牛の健康管理や生産から流通までの各段階の管理などを行うために重要な課題となっている。日本の畜牛では、牛トレーサビリティ制度[2]によって10桁の個体識別番号とその番号が記載された「耳標」（図2.1）の装着が義務付けられている。この識別番号をもとに個体の性別や血統、飼育場所などが管理されている。

個体識別には、耳標の読み取りの他にRFIDタグを装着して、それを読み取ることで情報を取得する方法もある。しかし、これらの手法はそれぞれ課題がある。耳標は障害物や牛同士の接触によって破損や脱落、汚損などにより識別番号の確認ができなくなるリスクを常に抱えている。また、RFIDタグは装着時に牛へ痛みやストレスを与えるだけでなく、タグ自体のコストや読み取り設備の費用による農家への負担も課題となる。

このような物理的手法による問題を解決するために、深層学習による画像認識技術を用いた顔画像による個体識別が注目されている。顔画像から個体の特定が可能になれば耳標の状態に関わらず牛へのストレスなく牛の個体管理を行うことができると期待されている。

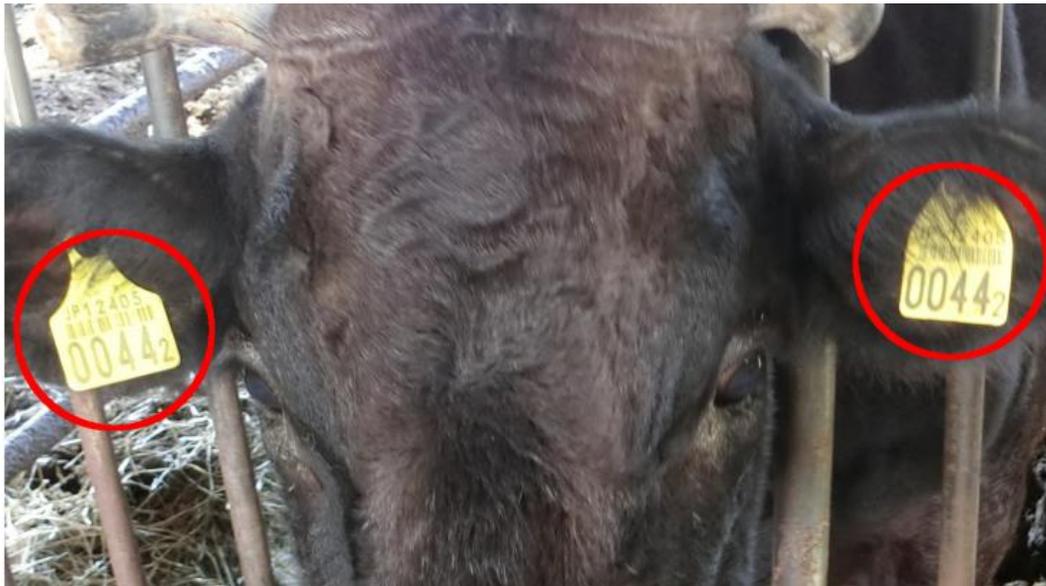


図 2.1 耳標

## 2.2 悪条件画像

実環境の畜舎において学習および識別に用いる画像を撮影する場合、牛の不規則な動きや照明環境の変化といった様々な要因によって画像品質が損なわれる。こうした画像品質の低下は、個体識別の精度と信頼性を著しく阻害するため、本節ではまず「悪条件画像」の定義を明確にし、その検証の必要性について述べる。

本研究では撮影時の環境や被写体の状態によって画像認識における特徴抽出に悪影響をもたらし、誤識別の原因となり得る画像を「悪条件画像」と定義する。

本来、深層学習を用いた識別モデルは、画像に含まれる微細な特徴を抽出することで高い精度を実現する。しかし、動物の突発的な行動や劣悪な撮影環境下で得られた画像は、個体差を識別するために必要な視覚的特徴が欠落、あるいは変質している場合が多い。このような画像を排除せずに評価用データに用いた場合、不十分な特徴から無理に判定を下すことになり、誤識別を招く。識別結果を利用する観点からは、誤った識別結果を出力するよりも、このような画像を除外して識別結果そのものを出力しない方が有用な場面が多い。

このように、個体識別の信頼性の向上のためには、全ての画像を一律に扱うのではなく、特徴抽出の段階で困難が生じる画像を適切に判別し、誤識別の原因となる画像を除外する制御が不可欠である。すなわち、不適切なデータによる無理な判定を避ける仕組みを構築することが、結果として高度な個体識別精度を担保することに繋がる。したがって、どのような画像が精度低下の要因となるのか、その性質を具体的に検証し、自動で抽出する手法を確立することは、高度な個体識別精度を実現する上で極めて重要な意義を持つ。

## 2.3 悪条件画像に関する従来研究

悪条件画像が識別精度に与える影響については、これまでも様々な観点から調査が行われてきた。

まず、個体識別における変動要因の一つとして、顔の向きが挙げられる。Zhi Weng ら[3]は、牛の顔が正面から逸脱することで目や鼻といった重要部位の位置関係が変化し、安定した特徴抽出を阻害することを指摘した。ここでは、顔の向きが正面から外れることを精度低下の主要な要因として捉えている。彼らはこの課題に対し、多スケールの特徴を融合させる Res52Net を提案し、向きの変化を含む複雑なデータセットにおいても 94.53% という高い精度を達成した。家畜の顔の向きに関する課題は、Ling Sun ら[4]も報告している。彼らは、家畜が撮影時に非協力的なため、収集される画像が「任意の方向を向いていること」が性能を著しく低下させると述べ、これを解決すべき悪条件として扱った。これに対し、顔検出と同時に回転角度を検知して正規化を行う LAD-RCNN を提案し、角度による影響を抑えることにより顔検出において 95% 以上の精度で顔の向きの影響を抑制できることを示した。

また、こうした精度の劣化は顔の向きだけに留まらない。Mingjie He ら[5]は、人の顔認識分野において、実環境では表情の変化、照明条件の変動、および一部の遮蔽といった多様な悪条件が複雑に絡み合っていると述べている。これらが個体識別を困難にする重大な要因で

あることを指摘しており、高度な識別性能を実現する上での大きな課題として共通の認識となっている。

次に、画像の不鮮明さを改善することで精度向上を図る研究がある。立山[6]の研究では、牛の動きや撮影時のブレなどによって生じる「ボケ」が悪条件となる特徴であるとし、CycleGANを用いたボケ除去処理を導入した。これにより、ボケ画像を含むデータセットにおいて低下する識別精度を改善できることを明らかにした。

しかしながら、これらの特定の物理的要因を排除・改善する手法には課題も残されている。牛の個体識別における悪条件画像の「除去」そのものに着目した谷山[1]の研究では、「顔が正面を向いていないこと」および「画像がぼやけていること」の2点を識別に不適な「悪条件画像」として定義している。実験の結果、顔の向きを正面に限定した場合には一定の精度向上が確認されたものの、その改善幅は限定的であった。さらに、ボケ画像を除去した実験においては、有意な精度向上は見られなかったという結果を報告している。

以上の従来研究を総合すると、顔の向き、ボケ、照明、遮蔽といった要素が各研究で「識別を困難にする特徴」として検証されてきたことが分かる。しかし、谷山の研究結果が示すように、人間が物理的・視覚的な基準で定義した悪条件を除去するだけでは、深層学習の精度改善には十分ではない可能性が示唆されている。これは、人間が直感的に判断する画像品質と、個体を特定するために必要とする情報が一致していない可能性が考えられる。

## 第3章 MagFaceによる悪条件画像の自動抽出

### 3.1 深層学習における悪条件画像

2.3節で述べたように、先行研究においては、顔向きを制限することで識別精度の向上が確認された一方で、物理的な指標に基づくボケ画像の除去では十分な精度改善が得られないという課題が示されている。

この原因として、人間が視覚的に判断する「画像の鮮明さ」という基準が、深層学習における「個体識別に有効な特徴の保持量」への影響が薄い可能性が考えられる。例えば、ぼやけて見える画像であっても、個体識別に重要な特徴が残されている場合や、一見鮮明に見える画像でも、様々な要因により特徴を抽出しにくい場合が存在する。

したがって、個体識別精度をさらに向上させるためには、人の想定した基準で画像を選別するのではなく、学習モデル自身が「個体識別に適した高品質な画像である」と判断する指標に基づき、画像を自動的に評価・選択する手法が必要不可欠である。本研究では、この課題を解決するために、モデル内部の特徴量から画像品質を推定可能なMagFaceを用いた自動抽出手法を提案する。

### 3.2 Arcface

本研究の基盤となる技術として、ArcFace[7]が挙げられる。ArcFaceは、主に顔認識分野で高い性能を示している深層距離学習の手法の一つであり、本節ではその仕組みと特徴について述べる。

深層距離学習の目的は、ネットワークによって抽出された特徴空間において、同一クラスのデータ同士は近くに、異なるクラスのデータ同士は遠くに配置されるように学習することである。ArcFaceではこの学習を角度空間で行う。具体的には、特徴ベクトル $f$ とクラスの重みベクトルの間の角度 $\theta$ に対して、加算的角度マージン $m$ を導入した $\cos(\theta + m)$ を目的関数に用いる。このマージン $m$ はすべてのデータに対して一律に固定された値として適用され、クラス境界を厳格に規定する役割を担う。一般に、マージンの値を大きく設定するほど、クラス内の凝集度とクラス間の分離性が向上し、より高い識別能力を得ることができるといえる。その一方で、マージンの増大に伴って同一クラスとしての制約が厳しくなるため、学習の収束はより困難になるという性質を持つ。そのため、識別性能と学習の安定性のバランスを考慮した適切なマージン設定が重要となる。

ArcFaceを含む多くの深層距離学習手法では、学習および識別の安定化を目的として、抽出された特徴ベクトル $f$ を $L_2$ 正規化し、単位球面上に投影して扱う。このとき、ベクトルの長さである「特徴量ノルム」は、通常すべての画像において等しくなるようスケールされる。

ArcFace では、全ての画像を等しく球面上に配置するために、正規化によって特徴量ノルムを一律に扱っているが、次節で述べる MagFace においては、この特徴量ノルムをあえて固定せずに活用する点が大きな特徴となる。

### 3.3 MagFace

本研究では、牛顔画像の特徴抽出に用いる手法として MagFace[8]を採用する。MagFace は、ArcFace などの従来の角度マージンベースの損失関数を拡張した手法であり、特徴ベクトルのノルムを画像品質の指標として学習に組み込んだものである。

3.2 節で述べた通り、従来の ArcFace 等の手法では、すべての特徴ベクトル  $f_i$  ( $i = 1 \dots N; N$  は学習データ数) を単位球面上に投影するために、特徴量ノルムを一律の値にスケールして学習を行う。これに対し、MagFace はノルム  $a_i = \|f_i\|$  を固定値でなく変数として扱い、損失関数内でノルム  $a_i$  に適応したマージン  $m(a_i)$  と正則化項  $g(a_i)$  を導入する点が大きな特徴である。MagFace の損失関数  $L_{Mag}$  は以下の式(3.1)で定義される。

$$L_{Mag} = -\frac{1}{N} \sum_{i=1}^N \log L_{cos}(a_i, \theta_{y_i}) + \lambda g(a_i) \quad (3.1)$$

ここで、 $y_i$  は  $i$  番目のデータの正解クラス、 $\theta_{y_i}$  は特徴ベクトル  $f_i$  とクラス  $y_i$  の重みベクトルのなす角、 $\lambda$  は正規化項の重みを制御するハイパーパラメータである。

$L_{cos}$  は角度空間での損失を表し、スケール値  $s$  を含んだ以下の形式で記述される。

$$L_{cos}(a_i, \theta_{y_i}) = -\log \frac{e^{s(\cos(\theta_{y_i} + m(a_i)))}}{e^{s(\cos(\theta_{y_i} + m(a_i)))} + \sum_{j \neq y_i} e^{s \cos \theta_j}}$$

前述の通り、MagFace におけるマージン  $m(a_i)$  は、特徴量ノルム  $a_i$  に応じて変化する。具体的には以下の式(3.2)で定義される。

$$m(a_i) = \frac{m_u - m_l}{u_a - l_a} (a_i - l_a) + m_l \quad (3.2)$$

ただし、 $m_u$  及び  $m_l$  はそれぞれマージンの上限値と下限値を表し、 $u_a$  及び  $l_a$  はノルムの上限値と下限値を表す。この設計により、ノルムが大きい場合にはより大きなマージンが適用され、クラス内の凝集度が極限まで高められる。逆に、ノルムが小さい場合には小さなマージンが適用され、学習時の制約が緩和される。

$g(a_i)$  はノルムを制御する凸関数であり、具体的には以下の式(3.3)で定義される。

$$g(a_i) = \frac{a_i}{u_a^2} + \frac{1}{a_i} \quad (3.3)$$

正則化項  $g(a_i)$  は、すべての画像に対して損失が最小となるようにノルムを上限値  $u_a$  付近へ引き上げようと作用する。しかし、実際は、角度損失との兼ね合いにより、ノルムの大きさは最適化の過程で以下のように決定される。

識別が容易な高品質な画像は、大きなマージンを課されても正解クラスへと収束できるため、正則化項の作用に従って大きなノルムを持つようになる。一方で、識別に適さない低品質な画像は、大きなマージンによる収束が困難であるため、損失を抑えるためにマージンが小さくなり、小さなノルムを持つ状態で最適化が停止する。

この性質により、学習後のモデルから得られる特徴ベクトルのノルムを算出するだけで、その画像が個体識別に適しているかを品質として定量的に評価することが可能となる。

### 3.4 悪条件画像の自動抽出法

本研究の手法では、まず MagFace を用いて牛顔画像の学習を行い、得られた各画像の特徴量ノルムに対して閾値を設定する。この閾値を下回る画像を「悪条件画像」として自動的に除外することで、深層学習にとって「個体識別が可能な特徴を保持しているか」という観点に基づいた高品質なデータの選別を実現する。

MagFace のネットワーク構造は、特徴ベクトルを生成するバックボーン (backbone) と、学習時に個体を分類するヘッド (head) によって構成される。本研究では、バックボーンとして EfficientNet-B0 を採用している。

### 3.5 MagFace の学習

本研究で使用するデータセットを表 3.1 に示す。学習は 2021 年から 2025 年 7 月にかけてみらいグローバルファーム、木城、綾、酪農公社、住吉の 5 つの農場で撮影された牛顔画像データをもとに作成された学習用データセットを用いて行う。同一個体についても撮影時期が異なる画像が含まれているため気象条件や背景情報などの環境要因や、牛の行動や成長による変化などの異なる被写体の状態が含まれたデータセットとなっている。学習データセットについては学習用(train)および検証用(valid)におよそ 9 対 1 の割合で分割して用いた。また、学習後のモデルの識別性能を評価するため、評価用データセットとして 2025 年 10 月に木城の農場で撮影された牛顔画像と 2025 年 12 月に綾の農場で撮影された牛顔画像を用いた 2 種類のデータセットを作成した。以降木城農場のデータセットをデータセット 01、綾農場のデータセットをデータセット 02 とする。各画像は撮影された動画から牛顔領域を切り出したものである。その際、連続したフレームに含まれる類似した画像を除外する処理を行った。切り出した画像は、画像サイズが  $512 \times 512$  になるようリサイズした。図 3.1 に本研究で用いる牛顔画像の例を示す。

表 3.1 各データセットの内訳

データセット	農場名	撮影時期	画像枚数	用途
学習用データセット	5つの農場	2021年~2025年7月	338462枚	学習
			37998枚	検証
データセット 01	木城農場	2025年10月	298392枚	評価
データセット 02	綾農場	2025年12月	138027枚	評価



図 3.1 使用した画像例

Magfaceの学習におけるハイパーパラメータおよび学習条件を、表 3.2 に示す。本研究では、先行研究および予備実験の結果に基づき、MagFaceの各パラメータおよび学習スケジュールを決定した。

表 3.2 ハイパーパラメータの設定値

項目	記号	設定値
スケール値	$s$	128.0
マージン上限値	$m_u$	0.5
マージン下限値	$m_l$	0.05
特徴量ノルム上限値	$u_a$	100
特徴量ノルム下限値	$l_a$	1
正規化項の重み係数	$\lambda$	2
バッチサイズ	-	100
エポック数	-	50
初期学習率	-	$2.95 \times 10^{-4}$
学習率スケジューラ	-	9エポックごとに0.5倍

### 3.6 自動抽出結果

学習済みの MagFace を用いてデータセット 01 とデータセット 02 の特徴抽出を行い、画像ごとに得られた特徴量ノルム  $a_i$  の分布を調査した。データセット 01 におけるノルム分布を図 3.2 に、データセット 02 におけるノルム分布を図 3.3 にそれぞれ示す。グラフの横軸は特徴量ノルムの値を示し、縦軸は画像数を示している。

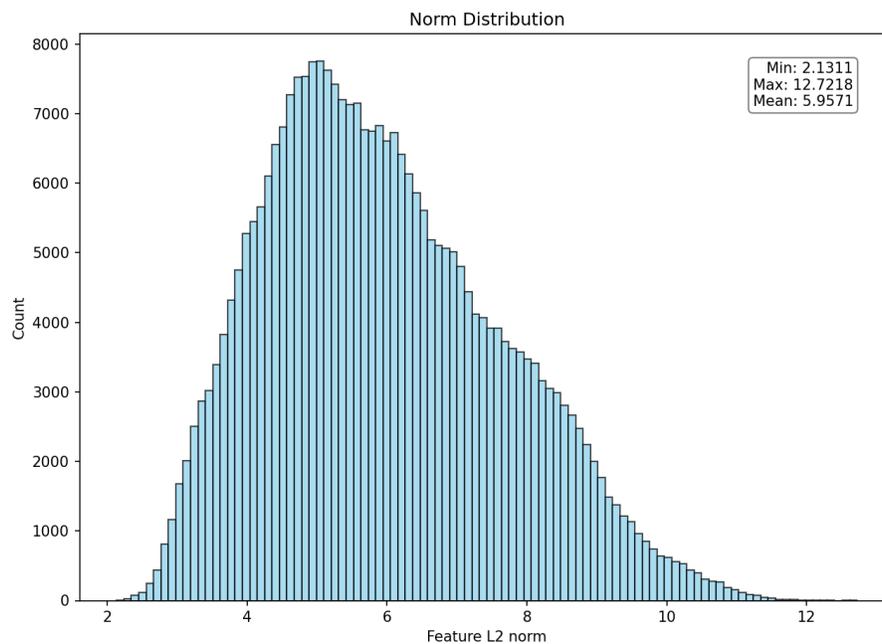


図 3.2 データセット 01 のノルム分布

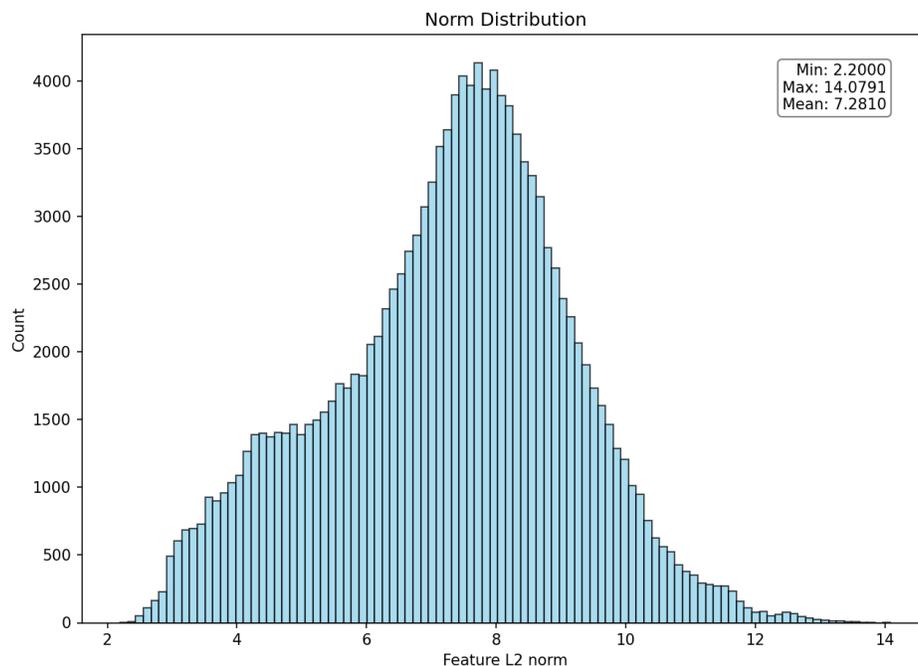


図 3.3 データセット 02 のノルム分布

図 3.2 に示す通り、データセット 01 における特徴量ノルムは最小値 2.13、最大値 12.72、平均値 5.96 の範囲に分布している。また、分布の形状としてはノルム値 4~5 付近に最も多く画像が集まる分布となっている。

一方、図 3.3 に示すデータセット 02 において特徴量ノルムは最小値 2.20、最大値 14.08、平均値 7.28 の範囲で分布しており、データセット 01 に比べデータセット 02 は、全体の分布として特徴量ノルムの値が大きいことが分かる。2 つ分布の形状を比較すると、データセット 01 は平均値より低い値に分布が集中しているのに対し、データセット 02 では、平均値より高い値に分布が集中しており、データセット 01 に比べ全体の分布が高ノルム側に画像が集中する傾向が見られる。

分析の対象とする「悪条件画像」の抽出基準として、各データセットの平均値を指標にし、データセット 01 ではノルム値 6.0、データセット 02 ではノルム値 7.3 を閾値とし、これらの値を下回る画像群を悪条件画像として扱う。本手法によって抽出された画像数の内訳を表 3.3 に示す。

表 3.3 評価用データセットの抽出後の画像数の内訳

データセット	閾値	品質の高い画像数	悪条件画像数	悪条件画像の割合
01	6.0	133046	165346	55.41%
02	7.3	74587	63440	45.96%

これら2つのデータセットにおいて、実際に低ノルム帯にどのような画像が含まれているか、また撮影環境や被写体の状態が具体的にどのようにノルム値へ影響を及ぼしているかについて次章で詳細な分析を行う。

## 第4章 悪条件画像の分析

### 4.1 悪条件画像の要因の考察

第3章で得られた画像ごとの特徴量ノルムを用いて悪条件画像を抽出し、画像の品質を低下させる特徴の調査を行う。

識別に悪影響を及ぼす特徴を特定するため、特徴量ノルムが極めて小さい画像、および Grad-CAM[9]を用いて深層学習モデルが識別時に注目している領域を可視化する画像をもとに、画像品質を低下させる要因を調査した。その結果、主要な要因として、「顔と背景のコントラスト差」「学習時と識別時の鼻紐の有無」「学習データの偏り」の3つの特徴に注目した。これらの項目について検証を行い、それぞれの特徴と特徴量ノルムの関係性について考察を行う。

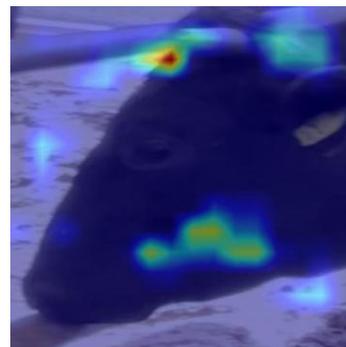
### 4.2 顔と背景のコントラスト差

悪条件画像の要因をさらに詳細に調査するため、低ノルム画像群を視覚的に分析した結果、被写体である牛の顔領域が背景と比較して極端に暗く、特徴抽出に影響を及ぼしていると考えられる画像が確認された。

中心領域と外側領域のコントラスト差が特に大きい画像について、中心領域が「極端に暗い場合」と「極端に明るい場合」の具体的な状態を確認した。図4.1(a)に示すような中心領域が暗い画像では、顔領域の細部特徴が潰れて抽出が困難になる一方、相対的に明るい背景側の特徴が優先的に抽出されることで、特徴量ノルムが低下したと考えられる。実際に同じ個体について Grad-CAM 画像について確認してみると、この個体では鼻周囲の特徴を捉える傾向が見られたが、判断根拠となる特徴を捉えられていない画像(図4.1(b))が多く確認できた。



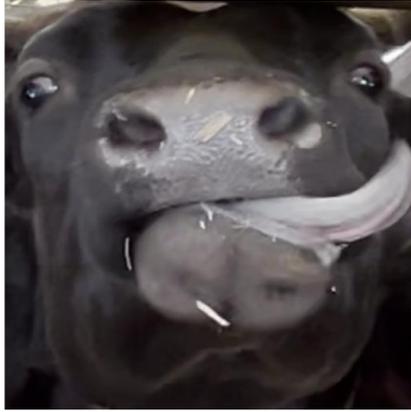
(a)悪条件画像



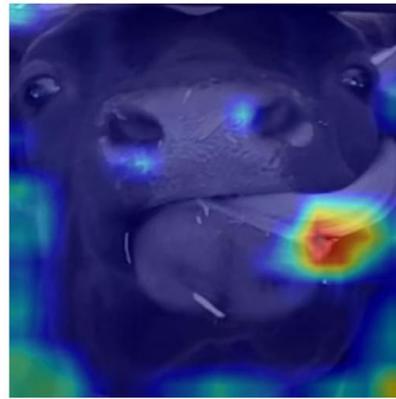
(b)Grad-CAMによる可視化画像

図 4.1 中心領域が極端に暗い画像例

一方で、図 4.2 のように中心領域が明るい画像では、牛の鼻がカメラ中央にある等の特殊な画角になっており、学習データに含まれない構図であるために MagFace によって品質が低いと判定されたことが推察される。可視化画像（図 4.2(b)）においても、個体識別を行うための判断根拠となる特徴を捉えられていないことが確認できる。



(a)悪条件画像



(b) Grad-CAM による可視化画像

図 4.2 中心領域が極端に明るい画像例

これらの視覚的分析の結果を踏まえ、顔領域と背景のコントラスト差が画像品質に与える影響を定量的に調査した。本研究で用いる顔画像は、顔の主要なパーツが中心付近に配置されている。そこで、画像の「中心領域」を画像全体の面積の約 50%にあたる中央部分とし、それ以外の外側部分を「背景領域」とした。輝度の計算には領域内の全画素の平均値を用いた。この「中心領域の輝度」から「背景領域の輝度」を引いた値をコントラスト差として定義し、特徴量ノルムとの関係を調べた。

求めたコントラスト差の値をもとに、悪条件画像と高品質画像におけるコントラスト差の分布を箱ひげ図を用いて比較した。データセット 01 の結果を図 4.3 に、データセット 02 の結果を図 4.4 にそれぞれ示す。

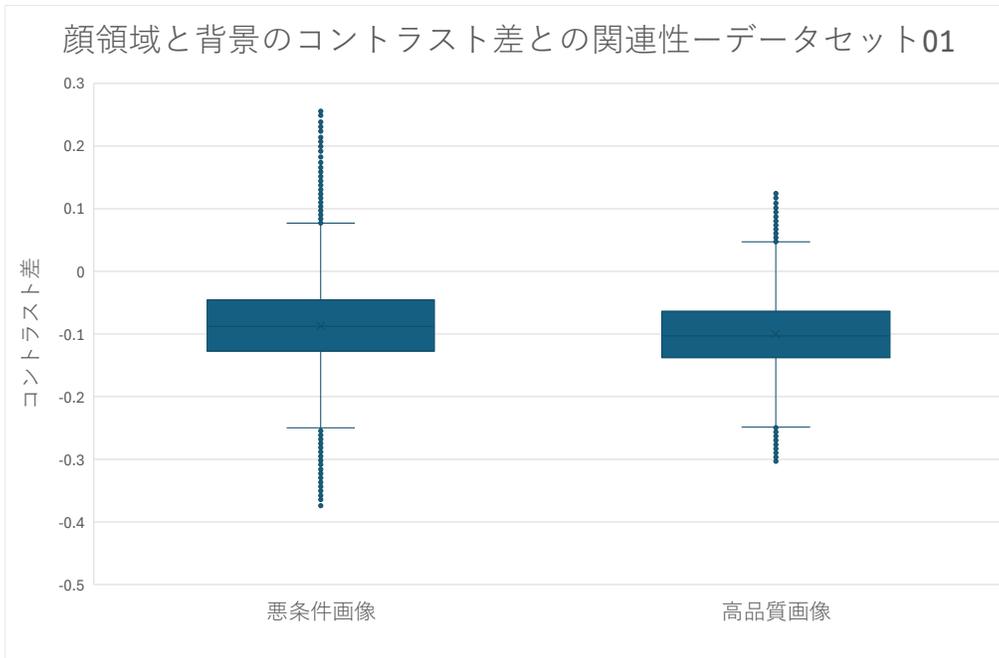


図 4.3 データセット 01 における画像品質別のコントラスト差の分布

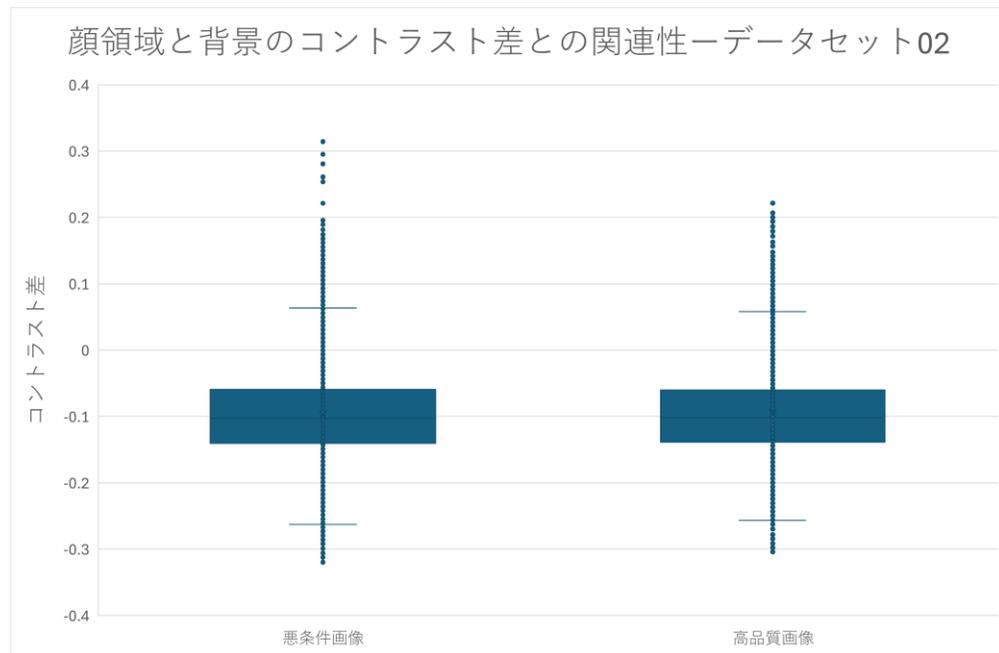


図 4.4 データセット 02 における画像品質別のコントラスト差の分布

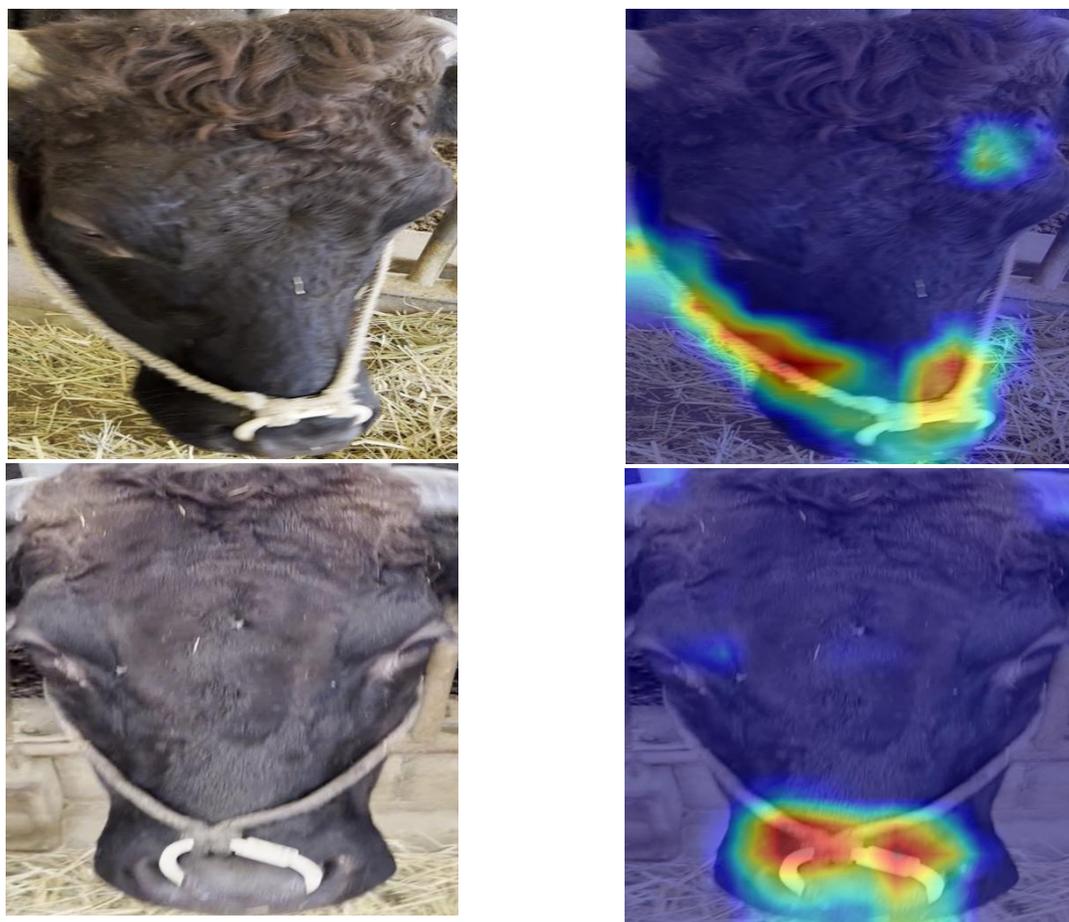
図 4.3 および図 4.4 より、いずれのデータセットにおいても、コントラスト差の大部分は高品質画像と共通の範囲内に分布しており、MagFace による品質判定が一定の輝度変動に対して頑健であることが示唆された。一方で、データの分布範囲に注目すると、高品質画像に比

べて悪条件画像はより広い範囲に分散している。特に中心領域と背景領域のコントラスト差が極端に大きい画像においては、悪条件画像として抽出される明確な傾向が確認できた。

以上の分析から、中心領域と背景領域の極端なコントラストの乖離や、特異な画角は、悪条件画像として判定される決定的な要因となり得ることが明らかになった。

### 4.3 学習時と識別時の鼻紐の有無

Grad-CAM 画像から得られる特徴として一部の個体は識別時に鼻紐や鼻輪部分を識別の判断根拠としている様子が確認された。この特徴が見られた画像例を図 4.5 に示す。



(a)悪条件画像

(b)Grad-CAM による可視化画像

図 4.5 鼻紐、鼻輪を識別の判断根拠とする画像例

一方で牛が鼻紐を装着しているか否かは撮影日によって異なる場合があり、学習時と識別時で画像に含まれる特徴が異なることで個体識別において悪影響を及ぼす要因になり得ると考えた。そこで、評価時と学習時における鼻紐の有無の一致率を調べ、画像品質との関連性を調査した。具体的には個体ごとに「識別に用いたデータの撮影日の鼻紐の有無」と「学習に用いたデータの撮影日ごとの鼻紐の有無」が一致している割合を算出した。なお、算出にあたってはデータの信頼性を確保するため、学習用データの撮影日数が7日以上存在する個体を対象として調査を行った。この一致

率と、各個体の悪条件画像割合をグラフにプロットすることで、学習時と識別時の鼻紐の状態の差が画像品質に与える影響を確認する。データセット 01 の結果を図 4.6、データセット 02 の結果を図 4.7 に示す。両図とも、縦軸は学習データの鼻紐の有無が評価用データと一致している割合（0～1）、横軸は各個体における悪条件画像の割合（0～100%）を示している。また、データが重複している箇所については、密度に応じて色が濃く表示されている。

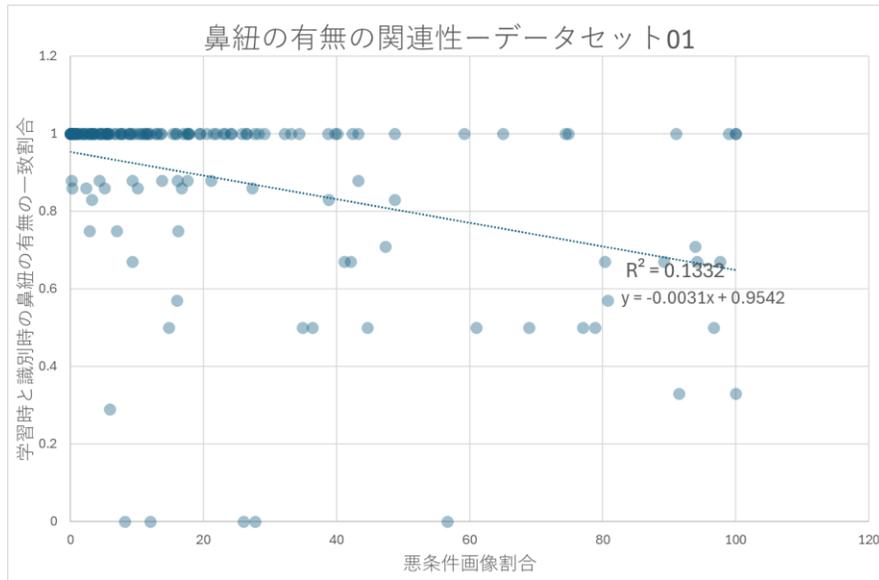


図 4.6 データセット 01 における鼻紐の有無と悪条件画像の関連性

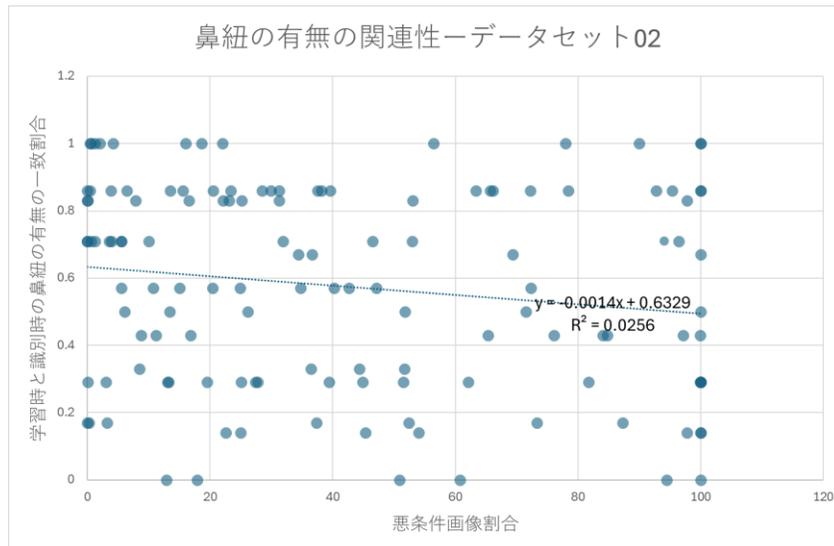


図 4.7 データセット 02 における鼻紐の有無と悪条件画像の関連性

図 4.6 より、データセット 01 において鼻紐の有無の一致率が 1（すべての学習データと状態が一致）である個体は、悪条件画像割合が小さい領域に分布する傾向が見られた。このことから、学習

時と識別時の鼻紐の状態が完全に一致している場合には、画像品質が高く評価される傾向があるといえる。しかし、一致率が1であっても悪条件画像割合が高い個体や、逆に一致率が低くても悪条件画像割合が小さく抑えられている個体も存在している。

一方、図 4.7 に示すデータセット 02 では、データセット 01 に比べて分布が全体に分散している。統計的には、決定係数 $R^2 = 0.0256$ 、近似曲線 $y = -0.0014x + 0.6329$ となり、強い相関は認められない。しかし、近似曲線の傾きが負を示していることから、鼻紐の一致率が低下するにつれて悪条件画像の割合が緩やかに増加するという、一定の負の傾向が確認できる。

本実験を通じて、識別時の鼻紐の有無が学習時の状態と一致している個体ほど画像品質が高く評価され、逆に学習時と状態が異なる個体ほど「悪条件画像」と判定されやすくなるという一定の傾向を確認することができた。これにより、データセットによって分布の広がりや影響の度合いに差はあるものの、鼻紐の状態変化は画像品質を変動させる要因の一つであるといえる。

#### 4.4 学習データの偏り

抽出された悪条件画像のうち、特徴量ノルムが極めて小さい画像を目視で確認したところ、画像自体には品質を著しく低下させる物理的な特徴が一部しか見当たらないにもかかわらず、多くの画像が悪条件画像と判定されている個体を確認された。こうした画像の例を図 4.8(a)、その Grad-CAM 画像を図 4.8(b)に示す。図 4.8(b)を確認すると、何らかの特徴を捉えている様子が伺える。このような識別を阻害する要因が見当たらないにもかかわらず低ノルムと判定される事例が他の個体でも確認された。



(a)悪条件画像



(b)Grad-CAM による可視化画像

図 4.8 外見上の欠陥が見られない低ノルム画像の例

これらの個体を詳細に調査した結果、該当個体の学習時の画像数や撮影日数が少ないという共通点が見出された。そこで個体ごとの学習データの画像数および撮影日数を集計し、各個体の全画像に対する悪条件画像の抽出割合との関連性を調査する。

まず、学習データの画像枚数と悪条件画像の割合の関係について、個体ごとの分布を確認した。データセット 01 の結果を図 4.9、データセット 02 の結果を図 4.10 に示す。両図とも縦軸に悪条件画像割合、横軸に学習データの画像数を取り作成した散布図である。

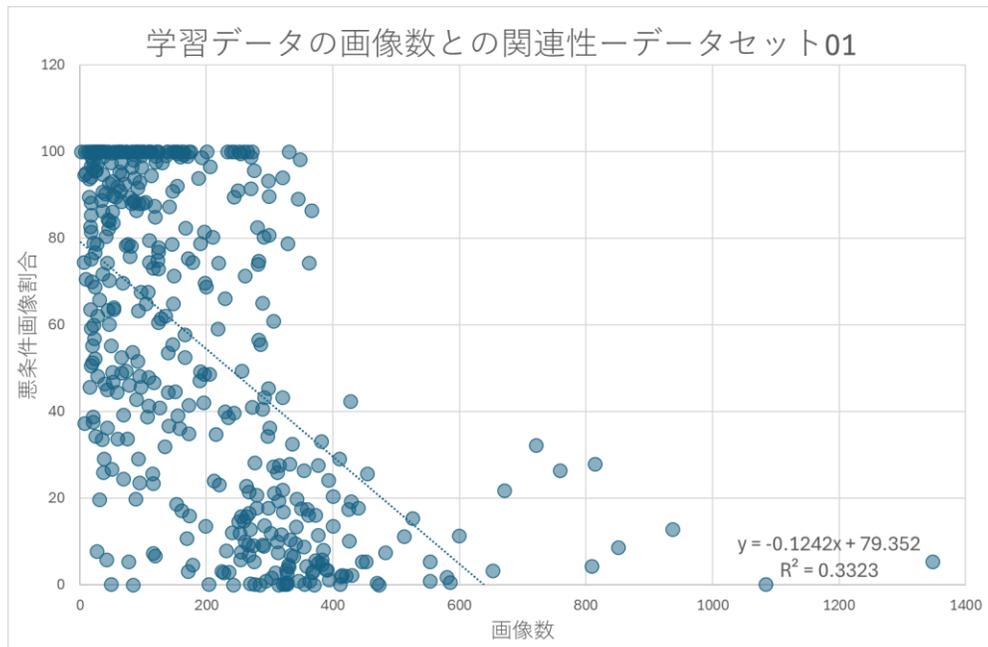


図 4.9 データセット 01 における学習データの画像数と悪条件画像割合の関連性

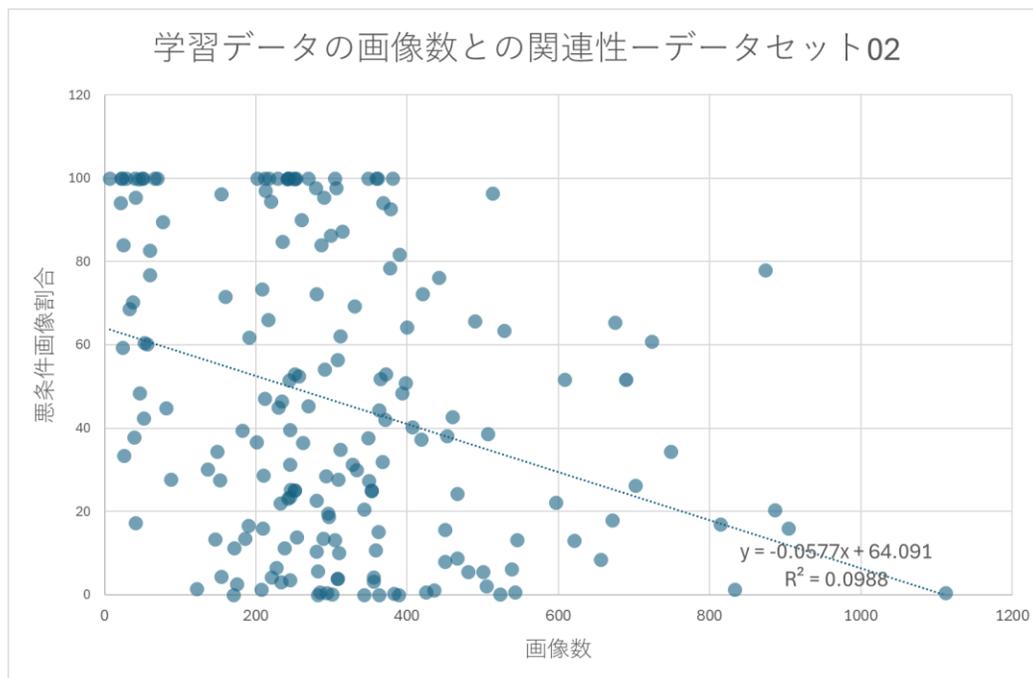


図 4.10 データセット 02 における学習データの画像数と悪条件画像割合の関連性

図 4.9 および図 4.10 より、いずれのデータセットにおいても学習画像数が少ない個体ほど悪条件画像と判定される割合が高くなる傾向がある。一方で、画像数が 300 枚付近を境として、悪条件画像の割合が低い値へと集中し始める分布が確認できる。特に、画像数が 600 枚を超える個体では、ほとんどの個体において悪条件画像の割合が極めて低い値に収束していることが分かる。ただし、画像数が 300 枚前後の個体であっても、依然として悪条件画像の割合が 100%に達している例も一定数存在している。

これらの結果から、学習データの画像数が増加するにつれて画像品質は安定し、高品質と判定される割合が高まることが伺える。しかし、画像数のみが品質を決定する一義的な要因ではなく、他の物理的要因等によって、画像数に関わらず品質が容易に変動し得ることが考えられる。

次に、学習データの撮影日数と悪条件画像割合の関連性について確認する。撮影日が異なることで、気象条件や背景情報の変化、さらには牛の成長に伴う容貌の変化など、多様な状態の画像が学習データに含まれることになる。これにより、識別に有効な汎用的特徴を獲得しやすくなり、結果として特徴量ノルムの値も大きくなることが期待できる。

画像数と同様に、個体ごとの撮影日数と悪条件画像割合を散布図にまとめた。データセット 01 の結果を図 4.11、データセット 02 の結果を図 4.12 にそれぞれ示す。

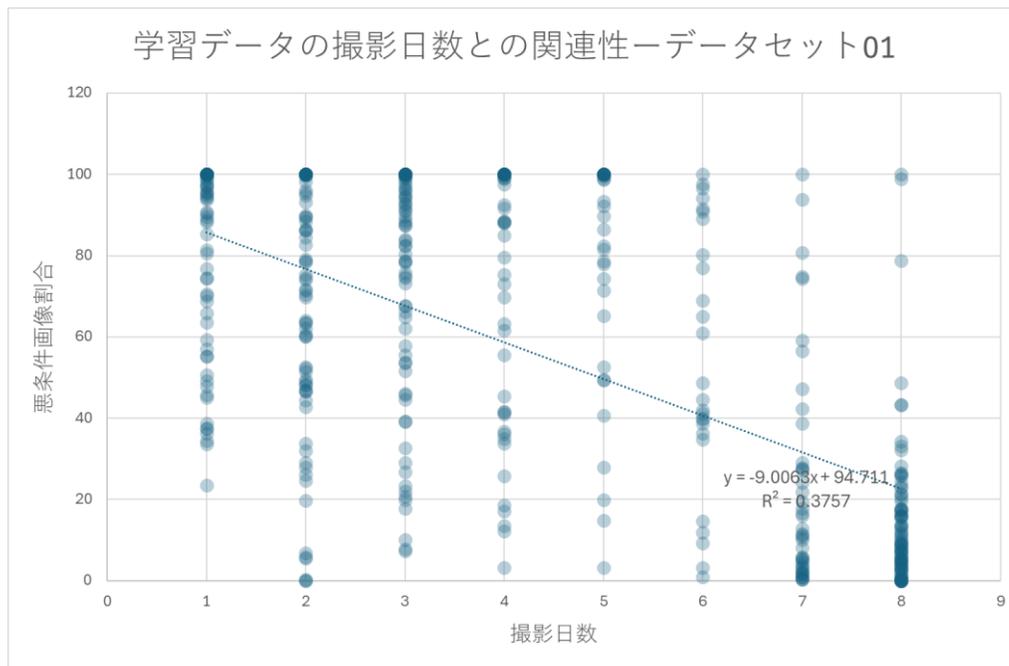


図 4.11 データセット 01 における学習データの撮影日数と悪条件画像割合の関連性

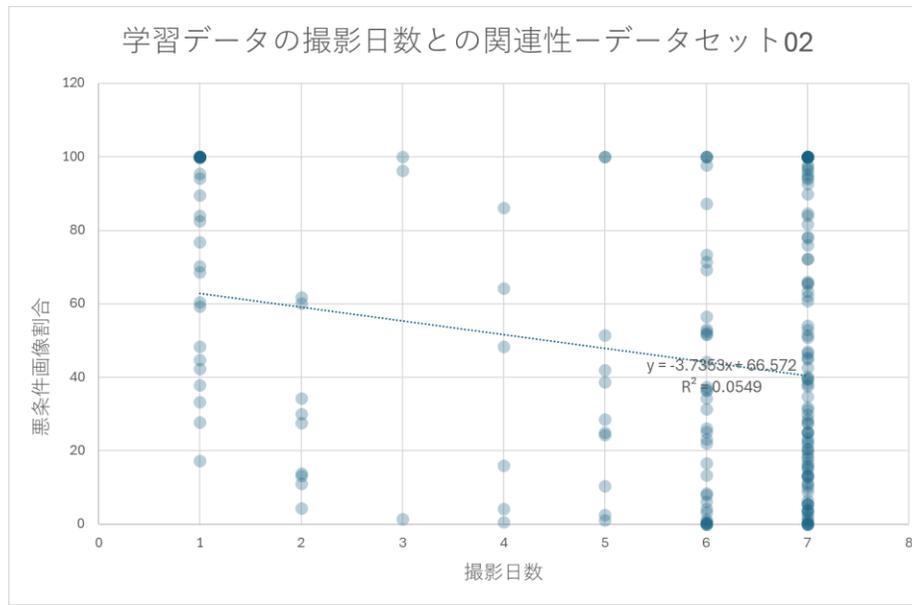


図 4.12 データセット 02 における学習データの撮影日数と悪条件画像割合の関連性

図 4.11 および図 4.12 より、学習データの撮影日数が 1 日のみである個体は、悪条件画像として判定される割合が高くなっている。対照的に、撮影日数が 7 日から 8 日に及ぶ個体では、悪条件画像の割合が低くなる傾向が確認できる。すなわち、学習データの撮影日数が最小の個体では画像品質が低く評価されやすく、最大日数に達している個体では画像品質が高いと評価されている。また、分布全体を見ても、撮影日数が少ない個体ほど悪条件画像割合が高く、撮影日数が多い個体ほどその割合が低くなるという負の相関が確認できる。特にデータセット 01 においてはこの傾向が顕著に現れている。以上の結果から、学習データの撮影日数を増やし、データに多様性を持たせることが個体の特徴をより顕著に抽出することを可能にし、特徴量ノルムの値を押し上げる要因になると考察できる。

#### 4.5 悪条件画像の分析結果に関する考察

本章で行った 3 つの観点による分析の結果、いずれの要因も画像品質との間に一定の相関を有することが示唆された。各要因の影響は、特定の条件下で顕著に現れるものの、画像品質を決定付ける要素は単一ではなく、複数の要因が相互に作用していることが明らかとなった。このことは、MagFace における特徴量ノルムが、撮影環境や学習データの状態といった多様な変動要因を統合的に反映する包括的な指標として機能していることを示唆している。

また、データセット 02 においては各要因の相関はデータセット 01 と比較して顕著には現れなかった。これは、3.4 節で示した通り、データセット 02 の特徴量ノルム分布全体が高品質側に偏っており、悪条件画像として抽出されたサンプルの性質がデータセット 01 とは異なっていたことが要因として推察される。

今後は、今回確認された傾向から大きく逸脱する個体や画像について詳細に調査を行うことで、画像品質を左右する他の特徴も特定できると考えられる。

## 第 5 章 悪条件画像の自動抽出による識別性能評価実験

### 5.1 実験設定

本章では、MagFace によって算出された特徴量ノルムに基づく悪条件画像の除外が、牛の個体識別精度に与える影響を評価する。

評価の手順を以下に示す。まず、評価用データセットの各画像に対し、学習済みモデルを用いて特徴抽出を行う。ここで、バックボーンから抽出された特徴ベクトルから品質指標である特徴量ノルムを算出すると同時に、特徴ベクトルと各クラスの重みベクトルとの内積計算により、各クラスの推論スコアを算出する。識別精度には、算出されたスコアの中で最大値を持つクラスを予測結果として扱い、実際の正解ラベルと予測結果が一致した割合である正解率を用いる。

特徴量ノルムを用いて悪条件画像を除外して評価を行う際には、基準となるノルムの閾値を設定する。そして、特徴量ノルムが閾値を下回る画像を評価対象から除外し、残存した画像のみ識別精度を算出する。

本実験では、閾値を段階的に変動させ、各段階で画像抽出を行った後の識別精度を算出することで、MagFace による悪条件画像の自動抽出が個体識別に悪影響をもたらす画像を効果的に除去できているかを検証する。

### 5.2 閾値の変化に伴う識別精度の推移

本節では、特徴量ノルムの閾値を段階的に変化させた際の識別精度の推移について述べる。閾値を 2 から 1 刻みで変動させた際の識別精度を表 5.1 に示す。また、閾値の変化に伴う識別精度およびデータ残存率の推移を図 5.1（データセット 01）および図 5.2（データセット 02）にそれぞれ示す。これらの図において、左縦軸は識別精度、右縦軸は全画像数に対するデータの残存率、横軸は特徴量ノルムの閾値をそれぞれ表している。また、青線は各閾値における識別精度を示し、赤色の破線は抽出後のデータ残存率を示している。

表 5.1 各閾値における識別精度

閾値	データセット 01	データセット 02
2	0.531	0.619
3	0.536	0.623
4	0.586	0.653
5	0.674	0.696
6	0.781	0.729
7	0.879	0.761
8	0.932	0.809
9	0.971	0.851
10	0.996	0.892
11	1.000	0.966
12		0.985

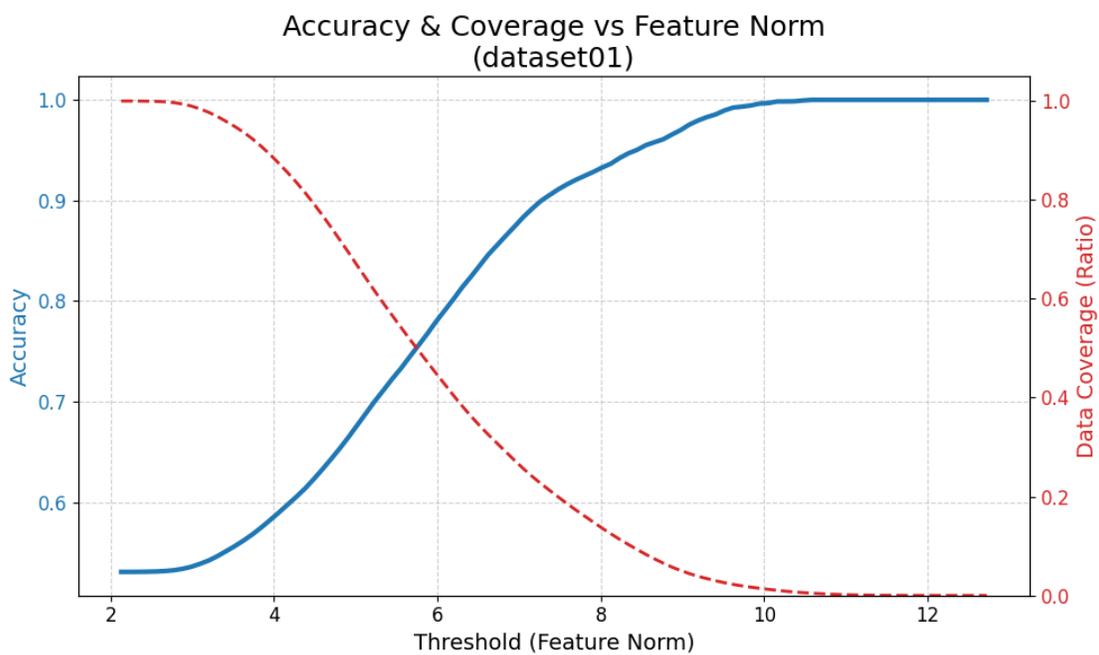


図 5.1 データセット 01 における閾値と識別精度の関係

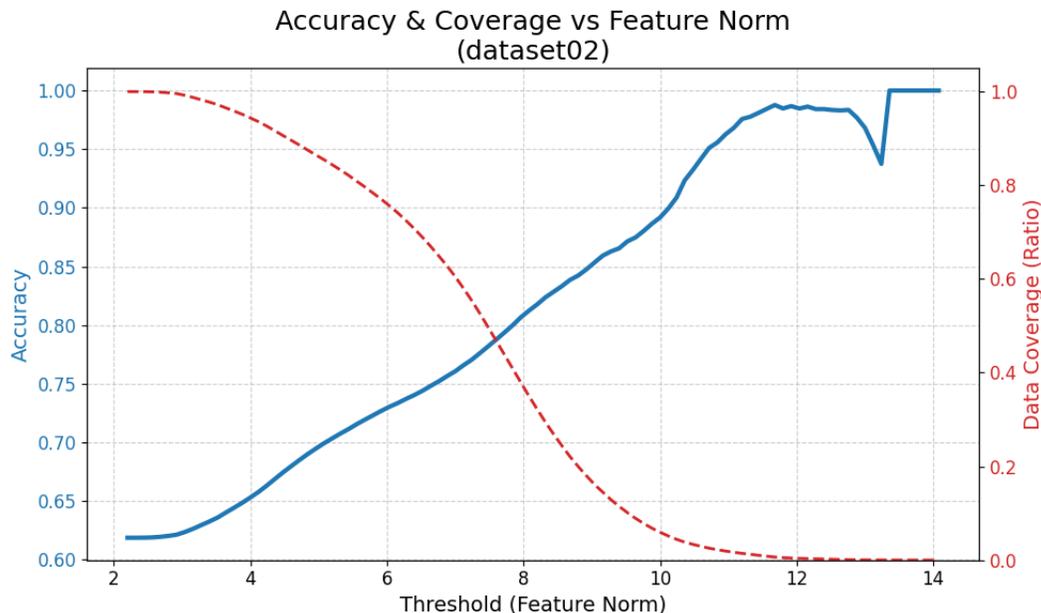


図 5.2 データセット 02 における閾値と識別精度の関係

表 5.1 より、閾値の上昇に伴って識別精度が段階的に向上していることが確認できる。この結果から、MagFace の特徴量ノルムに基づく悪条件画像抽出は、個体識別精度を低下させる要因を持つ画像を適切に除去できていると言える。

詳細な傾向を見ると、図 5.1 のデータセット 01 では、データ残存率の低下に呼応するように識別精度が大幅に上昇している。これは、データセット 01 内に存在する識別精度の低下に強く関与する画像群を、本手法が効果的に抽出し、排除できていることを示唆している。一方で、図 5.2 のデータセット 02 においては、データ残存率の低下に対し、識別精度の上昇量は相対的に緩やかな推移となった。これは、データセット 02 においては識別精度の低下に関わる画像だけでなく、精度の維持に寄与する高品質な画像も同時に一定数抽出し、除外されてしまっている可能性が考えられる。

さらに、図 5.1 および図 5.2 を俯瞰すると、高い識別精度を達成できる閾値領域においては、データ残存率が極めて低い水準となっていることが分かる。これは、識別精度を追求するほど利用可能なデータの大半が損なわれることを意味しており、現時点では高いデータ残存率の維持と十分な識別精度の確保を両立させる上で、依然として改善すべき課題が残されていることを示唆している。

### 5.3 特徴量ノルムと推論スコアに基づく抽出手法の比較

特徴量ノルムを用いた自動抽出手法の有効性を評価するため、推論スコアに基づく抽出を行った場合の識別結果との比較検討を行う。まず、推論スコアを用いた抽出の妥当性を確認するため、スコアの閾値変化に伴う識別精度およびデータ残存率の推移を調査した。データセット 01 の結果を図 5.3、データセット 02 の結果を図 5.4 にそれぞれ示す。これら図において、左縦軸は識別精度、右縦軸はデータの残存率、横軸は推論スコアの閾値を表している。また、これまでの実験と同様に、青線は識別精度を、赤色の破線は抽出後のデータ残存率を示している。

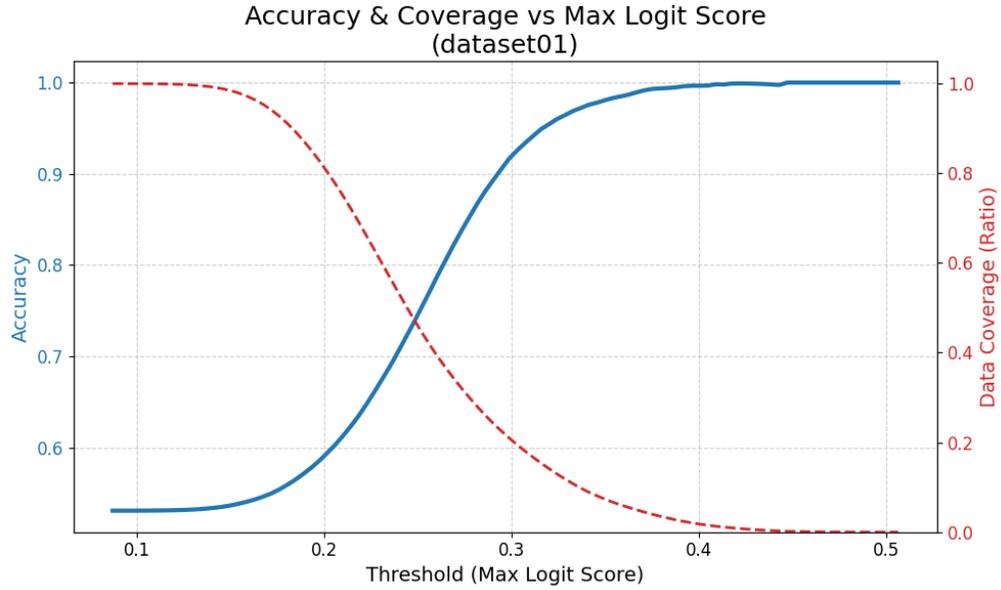


図 5.3 データセット 01 における推論スコアと識別精度の関係

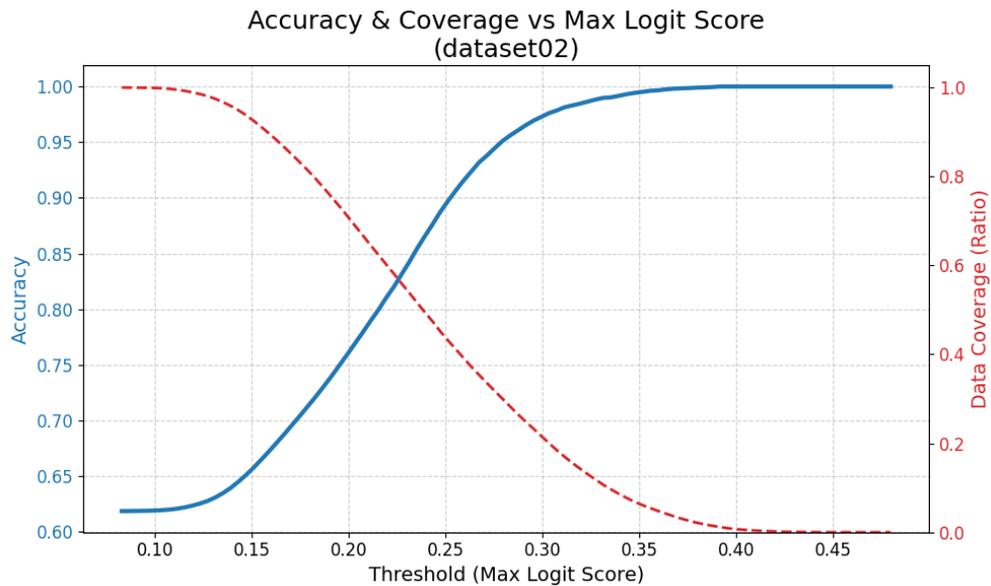


図 5.4 データセット 02 における推論スコアと識別精度の関係

図 5.3 および図 5.4 より、いずれのデータセットにおいても推論スコアが低い画像を除去することによって全体の精度が向上する傾向が確認できた。これにより、推論スコアも特徴量ノルムと同様に、識別精度の改善に有効な指標となり得ることが示された。

そこで、これら 2 つの指標の性能を詳細に比較するため、データの残存率が同一となる条件下で、それぞれの指標を用いた際の識別精度を算出した。比較にあたっては、縦軸に正解率、横軸に残存

データ数を取り、両手法の推移をプロットした。データセット 01 および 02 における比較結果を、図 5.5 および図 5.6 にそれぞれ示す。

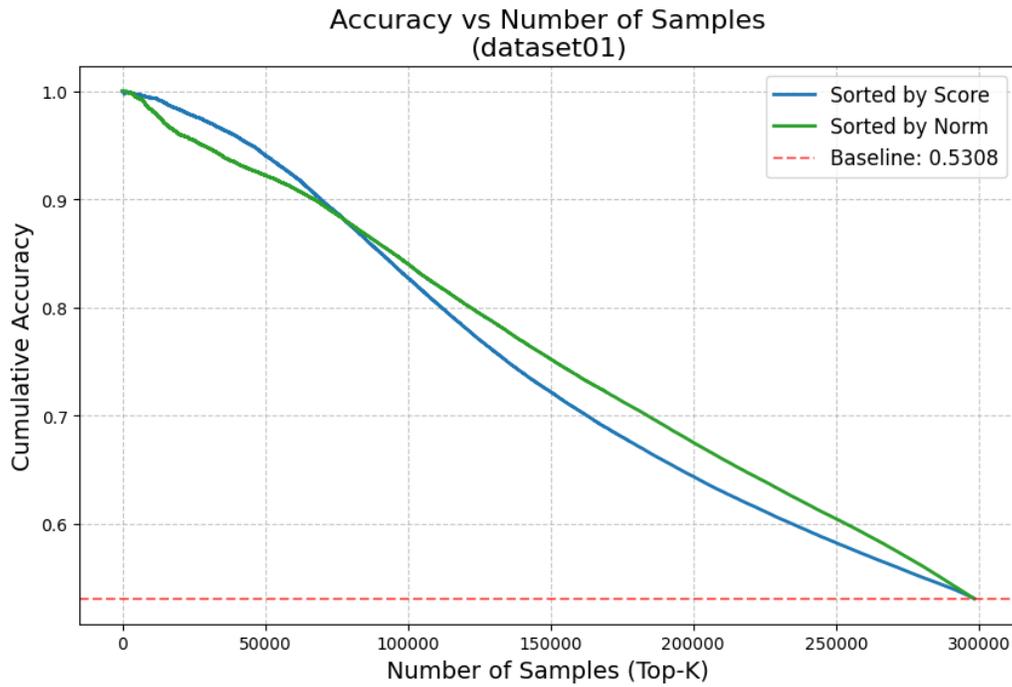


図 5.5 データセット 01 における 2 つの抽出法の識別精度比較

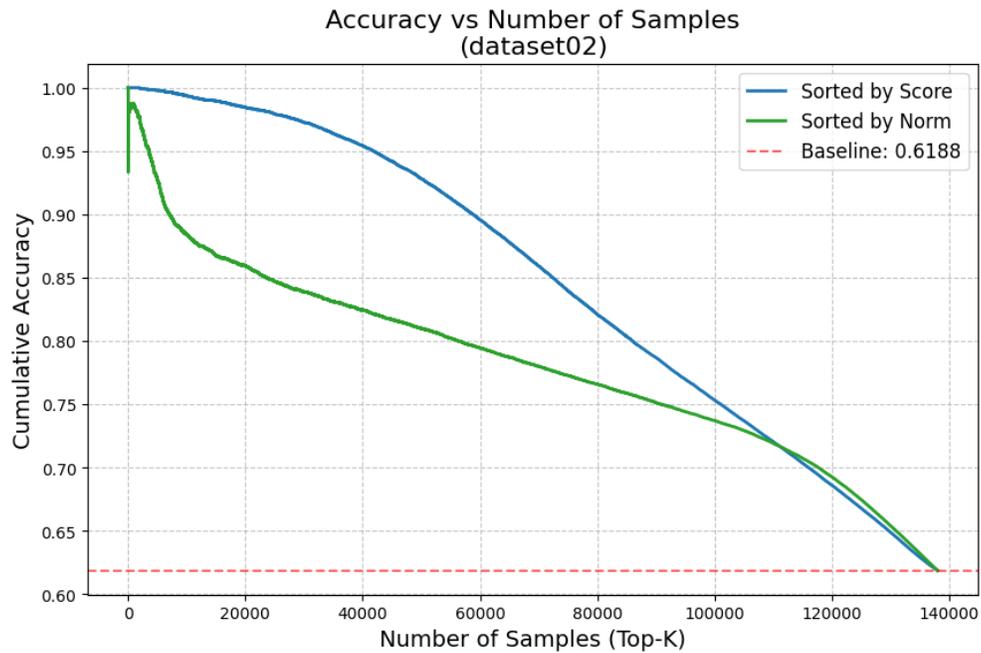


図 5.6 データセット 02 における 2 つの抽出法の識別精度比較

図 5.5 のデータセット 01 においては、閾値が低く残存画像数が多い段階では、特徴量ノルムによる抽出法の方が高い精度を示した。この結果から、データセット全体に含まれる低ノルムの画像群については、画像品質に基づく除去が精度向上に極めて効果的であることが分かる。一方で、閾値が高く残存画像数が少なくなる段階では、推論スコアに基づく抽出法が精度面で優位となる逆転現象が確認された。

同様の傾向は、図 5.6 のデータセット 02 においても確認できる。これらの結果から、特徴量ノルムは、撮影環境や被写体の状態に起因する「そもそも識別が困難な悪条件画像」を排除するフィルタとして機能しており、画像品質の底上げに寄与している。一方で、画像品質が一定以上に担保された領域においては、画像そのものの良し悪しよりも、対象となる画像の個体から抽出された特徴量が各クラスの重みベクトルにどれほど近いかを表す「推論スコア」の方が、最終的な識別精度の選別において重要な役割を果たすようになると推察される。

以上のことから、本研究で提案した **MagFace** による自動抽出手法は、撮影環境の変動が大きく、低品質な画像が多く含まれるような実運用に近い困難なデータセットにおいて、識別精度を安定させるために極めて有効な手法であるといえる。

## 第6章 おわりに

本研究では、牛の顔画像を用いた個体識別において、誤識別を招く「悪条件画像」を自動的に抽出し、排除する手法として MagFace を用いた品質評価手法を提案した。

まず、識別に悪影響を及ぼす特徴を特定するため、特徴量ノルムが極めて小さい画像や、Grad-CAM を用いて得られた可視化画像を詳細に調査した。その結果、主要な要因として「顔と背景のコントラスト差」「学習時と識別時の鼻紐の有無」「学習データの偏り」の3点に着目し、それぞれの特徴と特徴量ノルムの関係性について検証を行った。分析の結果、学習データ量の不足や顔領域のコントラスト低下が悪条件画像の判定に強く関与していることを明らかにした。一方で、鼻紐の有無についても、学習時との不一致が画像品質を変動させる一要因となることを突き止めた。これらの分析を通じて、個体識別の精度を低下させる「悪条件画像」の性質を明らかにし、本手法による自動抽出の妥当性を示した。

次に、特徴量ノルムに基づいた画像の自動抽出が識別精度に与える影響を評価した。実験の結果、ノルムを基準とした閾値を設定して低品質な画像を除去することで、識別精度が段階的に向上することを確認した。さらに、推論スコアを用いた抽出手法との比較により、本手法は特に低品質な画像が多く含まれるデータセットにおいて、識別に適さない画像を効果的に特定・除去できる強みを持つことが明らかとなった。

以上の成果により、従来は識別に与える影響が不明確であった「悪条件」の定義を、特徴量ノルムという指標を通じて定量的に評価し、自動的に選別できる可能性を示した。これは、情報技術を活用した牛の個体管理システムの信頼性を高める上で極めて有用な知見であると考えられる。

こうした一定の成果が得られた一方で、実用化に向けたさらなる課題も明らかとなった。

第一に、今回確認された傾向から大きく逸脱する個体や画像について、詳細な調査を行うことが挙げられる。本研究の分析では、撮影環境や学習データ量などの要因が複合的に画像品質に影響を及ぼしていることが示唆されたが、依然としてこれらの傾向に当てはまらない特異な事例も確認されている。こうした例外的なデータを精査し、画像品質を左右するより他の特徴を特定することで、モデルの判断根拠に基づいた高度な品質評価が可能になると考えられる。

第二に、本研究の核心となる「悪条件画像抽出手法」の高度化である。現状の手法では、高い識別精度を追求するほどデータ残存率が低下するという課題が残る。今後は、MagFace のノルム値による評価に加え、識別の確信度を示す推論スコアや他の画像特徴量を積極的に組み合わせることで、「正解となる画像の除外を最小限に抑えつつ、悪条件画像のみを的確に特定・排除する」仕組みを構築することが求められる。

このように、分析によって得られた知見を抽出手法の改善に反映させることで、「高いデータ残存率を維持した上での、高精度な個体識別」を保証するシステムの実現を目指したい。

## 謝辞

本論文を完遂するにあたり、多大なるご指導とご鞭撻を賜りました椋木雅之教授に深く感謝の意を表します。研究の過程において試行錯誤していた際も、先生の的確なご指摘をいただいたおかげで、研究の方向性を定めることができ、本手法の提案に至ることができました。多忙な中、丁寧かつ迅速なご指導をいただき大変感謝しております。

本研究を進める上で欠かせない貴重な牛顔画像データの撮影をさせていただいた農家の方々や撮影者の方々、ならびにデータ取得のため撮影作業にご協力いただいた（株）デンサンの皆様に、心より感謝申し上げます。

また、先行研究において参考にさせていただいた諸先輩方、ならびに日々の研究生活において多角的な知見や有益な助言をくださり、些細な相談にも親身に乘っていただいた椋木研究室の皆様に深く感謝いたします。

椋木研究室の皆様の今後のさらなる活躍を、心よりお祈りしております。

## 参考文献

- [1] 谷山 こはる, “深層学習を用いた牛個体識別における悪条件画像の除去による精度向上の調査”, 宮崎大学工学部情報通信工学プログラム 卒業論文, 2024
- [2] 農林水産省, “牛・牛肉のトレーサビリティ”, <https://www.maff.go.jp/j/syouan/tikusui/trace/>
- [3] Zhi Weng, Longzhen Fan, Yong Zhang, Zhiqiang Zheng, Caili Cong, and Zhongyue Wei, “Facial Recognition of Dairy Cattle Based on Improved Convolutional Neural Network”, *IEICE TRANS. INF. & SYST.*, VOL.E105-D, No.6, pp.1234-1238, 2022
- [4] Ling Sun, Guiqiong Liu, Xunping Jiang, Junrui Liu, Xu Wang, Han Yang, and Shiping Yang, “LAD-RCNN: A Powerful Tool for Livestock Face Detection and Normalization”, *Animals*, Vol.13, Issue 9, 1446, 2023
- [5] Mingjie He, Jie Zhang, Shiguang Shan, Meina Kan, and Xilin Chen, “Deformable face net for pose invariant face recognition”, *Pattern Recognition*, Vol.100, 107113, 2020
- [6] 立山 魁人, “CycleGAN を用いたボケ除去による顔画像からの牛顔個体識別精度への影響調査”, 宮崎大学工学部情報システム工学科 卒業論文, 2023
- [7] Jiankang Deng, Jia Guo, Jing Yang, Niannan Xue, Irene Kotsia, and Stefanos Zafeiriou, “ArcFace: Additive Angular Margin Loss for Deep Face Recognition”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 44, No. 10, pp. 5962-5979, 2022
- [8] Qiang Meng, Shichao Zhao, Zhida Huang, Feng Zhou, and Shichao Zhao, “MagFace: A Universal Representation for Face Recognition and Quality Assessment”, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 14225-14234, 2021
- [9] Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, and Dhruv Batra, “Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization”, *International Journal of Computer Vision (IJCV)*, Vol. 128, No. 2, pp. 336-359, 2019