

# Tripletのマイニング方法による乳牛の個体識別精度の比較

松永葵<sup>1</sup> 古田諒佑<sup>2</sup> 谷口行信<sup>1</sup>

東京理科大学<sup>1</sup> 東京大学<sup>2</sup>

## 1 まえがき

近年、少子高齢化や地方部の過疎化に伴う酪農業の後継者不足により、酪農家1戸あたりの飼養頭数が増加している。これに伴い、飼養形態も変化しており、乳牛が自由に歩き回ることができるフリーストールが増加している。しかしながら、24時間の監視が困難であるという理由から、個体管理の自動化が課題となっている。解決策として、乳牛にセンサを取り付ける手法が挙げられるが、コストが高いことや、衝突によりセンサが破損するという問題がある。本研究では、センサと比較してコストが低く、破損の危険性が少ないという理由から、牛舎の天井に設置したカメラで撮影した画像(以後、牛舎画像)を用いた個体管理に着目する。

石渡ら [1] は距離学習 (Triplet loss [2]) を利用した乳牛の個体識別手法を提案している。しかしながら、この手法では、図1のような斑紋特徴が類似した乳牛の個体識別は難しいという問題点がある。そこで本研究では、Tripletのマイニング方法を工夫することで、斑紋特徴が類似した乳牛の個体識別精度向上を目指す。

## 2 Tripletのマイニング方法による比較

TripletにおけるNegativeのサンプリング方法に着目する。石渡らの手法では、Anchorと異なるラベルの中からランダムに選択する方法(以後、Random Negative)を採用している。本研究では、Schroffらの手法 [3] を参考に、以下の2種類のマイニング方法を採用し、従来手法との精度を比較する。(i)  $d_p \leq d_n < d_p + \alpha$  を満たすものの中からランダムに選択する方法(以後、Semi-hard Negative), (ii)  $d_n < d_p + \alpha$  を満たすものの中からランダムに選択する方法(以後、Hard Negative)。ただし、 $d_p$  はAnchor-Positive間の距離、 $d_n$  はAnchor-Negative間の距離、 $\alpha$  はマージンとする。

## 3 実験条件・結果

本実験で使用する個体識別フローを図2に示す。実験データには、昼間に撮影された牛舎画像を個体ごとに抽出し、背景をマスクした画像を用いた。実験データのうち、62個体、計14,228枚を学習データ、35個体、1,980枚をテストデータとした。ただし、学習データとテストデータに同じ個体は含まれない。また、テストデータの



図1: 斑紋特徴が類似した個体の例

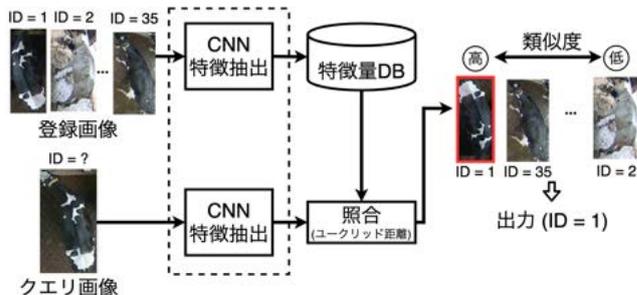


図2: 個体識別フロー

表1: 個体識別精度の比較結果 (%)

	Top 1	Top 3	Top 5
(1) Random Negative	71.6	91.7	96.3
(2) Semi-hard Negative	33.8	37.2	39.2
(3) Hard Negative	<b>79.0</b>	<b>95.6</b>	<b>98.4</b>

うち、各個体5枚を登録画像、残りをクエリ画像とした。CNN特徴抽出には、ResNet50をTriplet lossを用いてfine-tuningしたモデルを利用した。その際、(1)Random Negative, (2)Semi-hard Negative, (3)Hard Negativeの3種類のTripletのマイニング方法でfine-tuningを行い、精度を比較した。ただし、 $\alpha = 3.0$ とした。評価方法は以下のように定義した。類似度の上位k番目までに、クエリ画像と同じ個体が含まれる場合に正解として、Top k (k = 1, 3, 5) 正解率を算出した。結果を表1に示す。(3)では、類似個体の識別精度が向上したことにより、従来手法である(1)と比較してTop 1正解率が7.4%向上した。一方、(2)は学習がうまく進まず、他の2つと比較して大幅に精度が低い結果となった。その原因として、乳牛は人物と比較して特徴量が類似しており、 $d_p \leq d_n$ を満たすNegativeが十分に存在しなかったことが考えられる。

## 4 今後の課題

斑紋特徴が類似した乳牛の識別精度をさらに向上させるための手法の考案し、Top 1正解率90%以上を目指す。また、時系列情報を考慮した手法の提案を行い、更なる識別精度向上を図る。

### 参考文献

[1] 石渡翔太郎, 古田諒佑, 谷口行信. 斑紋特徴を用いた乳牛のRe-identification. 電子情報通信学会総合大会 ISS 学生ポスターセッション, 2020.  
 [2] D. Yi, Z. Lei, S. Liao, and S. Z. Li. Deep Metric Learning for Person Re-identification. In *ICPR*, pp. 34–39, 2014.  
 [3] F. Schroff, D. Kalenichenko, and J. Philbin. Facenet: A unified embedding for face recognition and clustering. In *CVPR*, pp. 815–823, 2015.