

## データベース分割に基づく乳牛個体識別システムの高速化

張非凡<sup>1</sup>古田諒佑<sup>2</sup>谷口行信<sup>1</sup>東京理科大学工学部情報工学科<sup>1</sup>東京大学 生産技術研究所<sup>2</sup>

## 1 はじめに

酪農家一戸あたりの乳牛飼養頭数が増加し、酪農の大規模化が進んでいる。病気や発情兆候を早期に発見するには、一頭一頭の牛を日常的に観察する必要がある。乳牛の個体識別手法として、斑紋特徴を手がかりとした画像認識技術を用いたもの [1] が提案されている。乳牛の罹患の早期発見や行動分析などの課題を解決するために、リアルタイム性がある個体識別システムの実現が課題である。

本研究では、データベース分割手法と近似近傍探索アルゴリズムを用いて個体識別を高速化することを目的とする。

## 2 先行研究

石渡ら [1] は距離学習を用いた個体識別手法を提案した。特徴抽出器を用いて、予め ID を付与した画像 (以下, DB 画像) を特徴抽出器に入力し, 出力として得られる 2048 次元の特徴ベクトル (以下, DB 特徴ベクトル) を個体特徴データベースに登録する。ID を推定したい画像 (以下, クエリ画像) を特徴抽出器に入力し, 出力として得られた特徴ベクトル (以下, クエリ特徴ベクトル) と, 全ての DB 特徴ベクトルとの間のユークリッド距離を計算し, 距離が最も小さい DB 特徴ベクトルに対応する ID をクエリ画像に付与する。本手法の問題点として, DB 特徴ベクトルの数を  $n$  とすると  $O(n)$  回の距離計算が必要となり, 照合に時間がかかることがある。

## 3 提案手法

提案手法は, 画像に写る乳牛の向いている方向 (以下, 向き角度) を推定し, 推定結果に基づいてデータベースを分割することで個体識別を高速化する。向き角度に応じて個体特徴データベースを分割 (例えば,  $L$  分割) した上で局所性鋭敏型ハッシュ (LSH) [2] を用いると計算量を  $O(d(\frac{n}{L})^{\frac{1}{c}} \log \frac{n}{L})$  ( $c > 1$ ) に削減できる。ただし,  $c, d$  は LSH のハッシュビット数とハッシュテーブル数を表す。

提案手法の全体フローを図 1 に示す。(1) 角度推定学習フェーズ: ResNet18 [3] を用いて角度推定器を学習する。個体ごとに乳牛の向き角度を画像に付与した教師データを用意し, 交差エントロピー損失を最小化するように ResNet18 を学習する。(2) 識別準備フェーズ: DB 画像を角度分類器に入力し, 出力として得られた向き角度に対応する個体特徴データベースに DB 特徴ベクトルを登録する。個体特徴データベースには LSH ハッシュを付与する。(3) 識別フェーズ: クエリ画像を角度分類器に入力し, 出力として得られた向き角度に対応する個体特徴データベースを選択する。LSH を用いた近似近傍探索を実行し, 最近傍の DB 特徴ベクトルに対応する ID を個体識別結果として出力する。

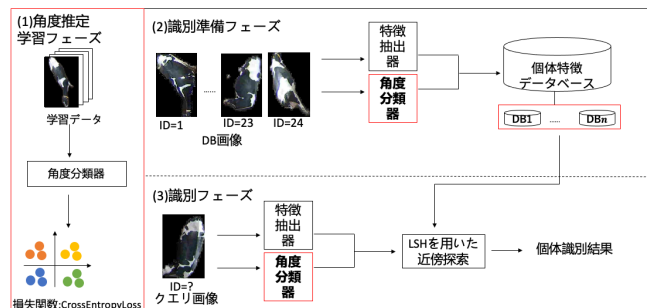


図 1 提案手法の全体フロー図

## 4 実験

乳牛画像を DB 画像として 10774 枚, クエリ画像として 1672 枚用意し, 斑紋特徴を用いた個体識別手法 [1] の特徴抽出器で特徴を抽出し, 提案手法のデータベース分割数を 4 とした。Top  $k$  正解率を, クエリ特徴ベクトルの  $k$  近傍に正解 ID の DB 特徴ベクトルを含む割合と定義した。実験で Intel Core i5-9600K, 32GB メモリ, Nvidia GTX 1070Ti を用いた。

識別精度と実行時間を表 1 に示す。提案手法の Top1 正解率は, LSH と比べて 1% 低下したものの, 実行時間は 26% に減少した。

表 1 乳牛個体識別の精度と実行時間

	実行時間 (ms)	Top1 (%)	Top5 (%)
全探索	99.7	91.9	98.0
LSH	5.5	<b>91.9</b>	<b>98.0</b>
提案手法	<b>1.4</b>	90.6	94.7

## 5 おわりに

本稿では, 乳牛の向き角度に応じて個体特徴データベースを分割し, 近傍探索に LSH を使用することで, 乳牛個体識別システムの高速化を実現した。今後の課題として, 角度分類クラス数が増加しても個体識別精度を低下させない手法の検討が挙げられる。

## 参考文献

- [1] 石渡翔太郎, 古田諒佑, 谷口行信. Attention 機構を導入した乳牛同定と実利用を想定した精度評価. 第 48 回画像電子学会年次大会, 2020.
- [2] L. Pauleve, H. Jegou, and L. Amsaleg. Locality sensitive hashing: a comparison of hash function types and querying mechanisms. *Pattern Recognition Letters*, pp. 1348–1358, 2010.
- [3] K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition. *CVPR*, pp. 770–778, 2016.