

画像解析による畜産牛の残飼料量推定

山下 幹太^{1,a)} 福元 伸也^{1,b)} 鹿嶋 雅之^{1,c)} 渡邊 睦^{1,d)} 西 正満^{†1,e)}

概要: 本研究は、スマート農業実証プロジェクトの一環として、ローカル 5G と AI 技術を活用した牛の成長推定および飼育効率化を目指し、牛舎内の残飼料量自動推定に取り組んだ研究である。学習に必要なデータ収集では、自律移動ロボットを用いて撮影した飼槽の映像から学習用の画像を生成する。推定には Detectron2 を用いて画像データから残飼料領域の検出を行い、残飼料量推定を行った。実験では、粗飼料と濃厚飼料、それぞれのピクセル数と重量の真値を用いて、残飼料のピクセル数から重量の推定値を算出した。その結果推定重量と真値との相関が 0.84、絶対誤差 2kg 未満の割合が 75.8%となり、提案手法の有効性が示された。

Estimation of Remaining Feed Quantity for Livestock Cattle Using Image Analysis

1. 研究背景と目的

本研究は、高品質な畜産物の輸出促進や飼料費および生産費の低減といった背景の下で、ローカル 5G を活用したリアルタイム画像解析技術および移動ロボットによる畜産業の効率化を目指したものである。この研究は、農研機構によるスマート農業実証プロジェクトの一環として実施され、特に見回りロボットによる給餌ロス 20%削減を目標としている。

牛の健康維持や正常な発育・繁殖活動を実現するためには、各発育段階や肥育ステージに応じた適切な栄養を含む飼料を過不足なく給与することが必要である。濃厚飼料は栄養供給の重要な役割を果たす一方で、反芻動物である牛にとっては反芻行動が重要であり、消化管内環境の維持や心理的安定に寄与する粗飼料の給与も欠かせない。これら 2 種類の飼料を適切に給与するためには、毎朝残飼料量を

確認し、その残存状況を基に調整を行う必要がある [1]。

しかし、畜産業従事者の減少による人手不足や測定者間の計測量の誤差が課題となっており、残飼料量推定の自動化が求められている。本研究では、移動ロボットを活用し、残飼料量の自動推定システムを開発することで、これらの課題解決を目指す。

2. 外部状況

本研究を行うにあたり、残飼料重量を推定するためにいくつかの手法を試した中で、対象物の面積から重量を推定する研究を参考にした。福島ら [2] は、収穫前の作物を撮影した画像を用いて、収穫前の重さ推定を行った。ResNet-18 を用いた回帰分析による手法で、レタスの重量を推定したところ、高い精度で推定することができた。會下ら [3] は、食事画像からカロリー量を推定した。米粒の大きさが一定であることを利用し、CNN で米飯画像から直接実寸を推定し、推定値と正解値の平均相関係数 0.946 という高い精度で推定することができた。

しかしながら、本研究では残飼料画像を使用し、残飼料は濃厚飼料と粗飼料という 2 種類の飼料が混在している状態である。各飼料の混合比率によって、飼料の形状や密度が不均一であることから、これらの手法を用いて画像から正確な面積推定をすることは困難である。また、飼料の色が似ているため、画像解析のみで区別することは難しい。本研究では、各飼料ごとのピクセル数と重量の関係を導き

¹ 鹿児島大学大学院理工学研究科工学専攻情報生体工学プログラム
Presently with Department of Engineering, Graduate School of Science and Technology, Kagoshima University

^{†1} 現在、鹿児島大学大学院理工学系研究科技術部
Presently with Presently with Department of Technology, Graduate School of Science and Engineering, Kagoshima University

a) k9670499@kadai.jp

b) fukumoto@ibe.kagoshima-u.ac.jp

c) kashima@ibe.kagoshima-u.ac.jp

d) mutuyas256@gmail.com

e) nishi@eng.kagoshima-u.ac.jp

出し、各飼料の領域を検出することで残飼料の重量推定を行った。

3. 推定用画像の成型

本研究で使用した画像データの成型手順を図1に示す。



図1 画像成型のフローチャート

本研究では、自律移動ロボットを用いて撮影した映像を学習・推定に用いる。移動ロボットは、幅3mの牛房が28個連なった牛舎内を移動しながら、飼槽に残っている残飼料の動画を撮影する。使用する自律移動ロボットを図2、撮影環境を図3に示す。



図2 自動走行ロボット




図3 撮影環境

撮影した動画を牛房単位に分割するが、幅3mの飼槽は1画面には映りきらない。これを1画面に収めきるために、図4に示すようにスティッチングを行いパノラマ画像を作成する。これにより、1枚の画像から対象の牛房の残飼料量を視覚的にも把握しやすくする。その後、ヒストグラム平坦化でコントラストを上げ、中心で縦に折りたたんで正方形の画像に成型し、256×256ピクセルにリサイズを行う。以降残飼料量推定にはすべてこの画像データを使用する。生成したパノラマ画像を図5、推定に使用する画像を図6に示す。



図4 スティッチング方法



図5 動画から生成したパノラマ画像



図6 残飼料画像

4. 考案手法

本研究では、学習用に作成した残飼料の画像を使用して、機械学習を用いた残飼料量の4クラス分類の手法2つと、残飼料領域の検出後、面積から重量を推定する手法2つ、計4つの手法を考案した。

4.1 ResNetを用いた4クラス分類

本手法では、ResNetで学習した後、「0kg」「0-2kg」「2-5kg」「5kg以上」の4クラスに分類を行う。

4.1.1 Resnetとは

ResNet (Residual Network) は、2015年に Kaiming Heら [4] によって提案された深層学習モデルであり、深いニューラルネットワークにおける学習の困難を解決するために設計されたアーキテクチャである。

ResNetは、層を深くすることで精度を向上させることを目指しているが、一般的に層が深くなると、勾配消失問題や学習の収束速度が遅くなるといった課題が生じる。これに対して、ResNetは「残差接続」というアプローチを導入し、この問題を解決した。

4.1.2 学習・4クラス分類

学習では、各クラス30枚ずつを training 用、3枚ずつを test 用に使用した。設定したハイパーパラメータを表1に

示す。

項目	値
バッチサイズ	32
エポック数	200




図 8 1 × 1 ピクセル



図 9 8 × 8 ピクセル

4.2 輝度値順に並び替えた画像を用いた 4 クラス分類

本手法では、元の残飼料画像を輝度値順に並び替えた画像を使用して、テクスチャ解析で GLCM 特徴量と LBP 特徴量を抽出した後、XGBoost[5] で学習を行い、「0kg」「0-2kg」「2-5kg」「5kg 以上」の 4 クラスに分類を行う。

4.2.1 XGBoost とは

XGBoost (eXtreme Gradient Boosting) は、2014 年に Tianqi Chen らによって提案された、勾配ブースティングアルゴリズムに基づく機械学習ライブラリであり、高速かつ高精度な予測性能を特徴とする。

本アルゴリズムは、既存の勾配ブースティング手法に改良を加え、計算効率や汎化性能を大幅に向上させた。その結果、機械学習分野における分類、回帰、ランク付けなど、様々なタスクで優れた性能を発揮している。

4.2.2 8 × 8 ピクセルごとの輝度値順に並び替え

図 7 に示すように、画像をラスタ走査（一次元配列走査）で左上から右下までピクセルごとに読み込む。その後、読み込んだ情報から輝度値順に並び替えて、上から下にかけて、黒から白になっていく画像を作成する。




図 7 ラスタ走査

図 8 のように 1 ピクセルごとに並び替えるとどのクラスでも特徴が出にくくなるため、図 9 のようにもとの画像を 8 × 8 ピクセルのブロックごとに分割し、そのブロックの輝度値の平均値で並び替えを行うことで、特徴を残しつつ、同じクラス間では似た性質を持つ画像を生成する。

4.2.3 画像の水増し

学習に使用する画像の枚数が少なく、またクラスによって枚数も異なるため、水増し処理を行う。

図 10 に示すように、8x8 ピクセルごとのブロックを、0°、90°、180°、270° の 4 つからランダムに選び、回転させることで一枚の画像から複数枚水増しを行う。水増し枚数は各クラス 200 枚になるよう調整する。




図 10 水増し方法

4.2.4 テクスチャ解析による特徴量抽出

テクスチャ解析によって、特徴量を抽出する。今回は GLCM 特徴量と LBP 特徴量を計算し、まとめて次の XGBoost による学習に利用する。以下に 2 つの特徴量について詳細を示す。

GLCM 特徴量は、画素のグレーレベル感の空間的な相関性を表す行列を計算するもので、テクスチャの一貫性や、コントラスト、画素間の相関性を見る。規則的なパターンや方向性を持つテクスチャの画像に適している。

LBP 特徴量は、各画素の近傍画素との総合的な輝度差を 2 進数として符号化し、テクスチャパターンをキャプチャするもので、明るい部分と暗い部分のパターンを効率的に記述する。微細なテクスチャや荒いパターンを持つ画像に適している。

4.2.5 XGBoost による 4 クラス分類

テクスチャ解析で抽出した特徴量を使って、XGBoost で学習し、4 クラスに分類する。各クラス 200 枚ずつを学習に、3 枚ずつを test 用を使用した。設定したハイパーパラメータを表 2 示す。

項目	値
学習率	0.3
決定木の数	100
決定木の深さ	6

4.3 輝度値による残飼料と飼槽の分離

本手法では、飼料と飼槽部分の輝度値の差を利用して、大津の二値化を用いて閾値を設定することで残飼料を検出し、重量を推定する。

4.3.1 大津の二値化とは

大津の二値化 (Otsu's Binarization) は、画像処理において広く用いられる手法であり、グレースケール画像を自動的に二値画像に変換するアルゴリズムである。

大津の二値化の基本的な考え方は、画像のヒストグラムに基づく分割である。具体的には、画像全体の画素値の分布を解析し、閾値によって画像を2つのクラス(対象領域と背景領域)に分割する。最適な閾値は、クラス内分散(同一クラス内の画素値の分散)を最小化し、クラス間分散(異なるクラス間の画素値の分散)を最大化するように選定される。これにより、画像のコントラストが最も高くなるように分離を行うことができる。

4.3.2 飼料部分のピクセル数抽出

残飼料画像は、飼料部分が明るく、飼槽部分が暗いため、二値化画像を生成すると残飼料の領域のみが白く残る。この領域のピクセル数を用いて、対象の画像が属するクラスとの関係性を比較する。

4.4 Detectron2 を用いた残飼料検出

本手法では、Detectron2 を用いて残飼料を粗飼料と濃厚飼料に分けてそれぞれ検出し、重量を推定する。

4.4.1 Detectron2 とは

Detectron2 は、Facebook AI Research (FAIR) によって開発されたオープンソースの物体検出およびセグメンテーションプラットフォームである。PyTorch を基盤として構築されており、柔軟性と拡張性に優れた設計が特徴である。物体検出、インスタンスセグメンテーション、パンopticセグメンテーション、キーポイント検出など、幅広いタスクに対応している。

4.4.2 各飼料部分のアノテーション

残飼料の粗飼料と濃厚飼料部分をそれぞれアノテーションし、ラベル付けしたものを保存する。アノテーションした画像を図 11 に示す。濃厚飼料を緑色、粗飼料を赤色で囲っている。



図 11 アノテーション画像

4.4.3 Detectron2 で学習・検出

ラベル付けを行った画像 40 枚を用いて学習を行い、残飼料を粗飼料と濃厚飼料に分けて検出する。設定したハイパーパラメータを表 3 に示す。

項目	値
学習率	0.001
バッチサイズ	4
イテレーション数	10000
ウォームアップイテレーション	1000

4.4.4 各飼料の重量とピクセル数の相関グラフ

次に濃厚飼料 0 から 15kg と粗飼料 0 から 5kg の、それぞれ 1kg 刻みの画像データを準備し、重量ごとの飼料のピクセル数を記録する。各飼料を撮影する際には、残飼料の厚みを考慮して、厚みが均等になるように平らにならしてから行う。このデータをもとに、2 種類それぞれの飼料の重量とピクセル数の相関グラフを生成する。作成した 2 種類のグラフを図 12, 13 に示す。




図 12 濃厚飼料グラフ




図 13 粗飼料グラフ

4.4.5 残飼料のピクセル数と相関グラフから重量推定

Detectron2で、濃厚飼料を青色、粗飼料を赤色でセグメンテーションを行い、それぞれの領域のピクセル数を取得する。その後、取得したピクセル数を図 12,13 の各飼料の重量とピクセル数の相関グラフと対応付け、各飼料の重量を算出し、足し合わせることで残飼料量を推定する。

5. 評価実験

5.1 ResNet を用いた 4 クラス分類

ResNet の学習データで推論を行った結果を表 4 に示す。

表 4 ResNet を用いた 4 クラス分類

重量クラス (kg)	推論結果	True or False
0	0-2	False
0	0	True
0	0-2	False
0-2	0	False
0-2	0-2	True
0-2	0	False
2-5	0-2	False
2-5	0	False
2-5	0-2	False
5-	0	False
5-	0	False
5-	0	False

12 枚で推定を行った結果、クラスが一致したデータが 2 枚、不一致であったデータが 10 枚であり、正答率は 16% であった。

5.2 輝度値順に並べ替えた画像を用いた 4 クラス分類

テクスチャ解析で抽出した GLCM 特徴量と LBP 特徴量の 2 つを用いて、XGBoost の学習データで推論を行った結果を表 5 に示す。

表 5 輝度値順に並べ替えた画像を用いた 4 クラス分類

重量クラス (kg)	推論結果	True or False
0	0	True
0	0	True
0	0	True
0-2	0-2	True
0-2	2-5	False
0-2	5-	False
2-5	2-5	True
2-5	0-2	False
2-5	2-5	True
5-	2-5	False
5-	5-	True
5-	5-	True

12 枚で推定した結果、クラスが一致したデータが 8 枚、不一致であったデータが 4 枚であり、正答率は 66% であった。

5.3 輝度値による残飼料と飼槽の分離

大津の二値化で閾値を自動設定し、飼料と飼槽を分離した結果を図 14,15 に、重量クラスごとの飼料領域のピクセル数の分布を図 16 に示す。どの重量クラスにおいても、残飼料領域のピクセル数は広く分布しており、重量との相関がみられなかった。また、0kg の画像においても、本来は 0 であるべきところが、他のクラスと同じように広い分布を示していた。



図 14 元画像

図 15 大津の二値化




図 16 各クラスのピクセル数分布グラフ

5.4 Detectron2 を用いた残飼料検出

畜産牛に与える飼料は、粗飼料という草、あるいは草を元に作られた餌と、濃厚飼料というトウモロコシや大豆、小麦などを粉末状にした餌を混ぜ合わせた物を使用しており、粗飼料と濃厚飼料ではそれぞれ重量が異なっている。

図 17,18 に示すように、重量の異なる粗飼料と濃厚飼料の画像を用意し、それぞれセグメンテーションする。



図 17 粗飼料



図 18 濃厚飼料

Detectron2 で濃厚飼料を青色，粗飼料を赤色でセグメンテーションした画像を図 19,20 に，重量の真値と推定値の比較グラフを図 21 に示す．相関係数は 0.83，絶対誤差が 2kg 未満の割合は 75.8% という値が得られた．



図 19 元画像




図 20 Detectron2




図 21 重量と真値の相関グラフ

6. 考察

6.1 ResNet を用いた結果に関する考察

ResNet を用いた 4 クラス分類の結果，正答率は 16% と非常に低い値にとどまった．この要因として，残飼料画像の多様性が挙げられる．特に，同じクラス内でも画像の特徴に大きなばらつきがあり，モデルがその差を十分に学習できなかったと考えられる．また，画像内の空間情報をそのまま使用したため，残飼料の配置や形状に起因する特徴がノイズとなった可能性がある．

6.2 輝度値順に並べ替えた画像を用いた結果に関する考察

本手法では，輝度値順に並べ替えた画像を用いることで，残飼料の配置に関する情報を排除し，面積情報に焦点を当てた．この結果，正答率は 67% と一定の精度向上が見られた．しかし，粗飼料と濃厚飼料の比率や質量の違いといった要因を考慮していないため，分類精度に限界が生じたと考えられる．

6.3 大津の二値化を用いた結果に関する考察

大津の二値化を用いた重量推定では，ピクセル数と重量の相関が十分に得られなかった．特に，粗飼料と濃厚飼料の異なる密度が影響を与えていると考えられる．

また，大津の二値化の性質上，画像から必ず閾値を設定して画像を二値化するため，残飼料のない 0kg の画像に対しては，飼槽の明るい部分と暗い部分で二値化をしてしまう．これにより図 22,23 のように誤検出が発生するなど，手法の限界も確認された．



図 22 0kg の画像



図 23 誤検出した画像

6.4 Detectron2 を用いた結果に関する考察

図 21 の真値と推定重量の相関係数 0.83，絶対誤差 2kg 未満の割合 75.8% という結果から，本手法が十分な実用性を有していることが示唆される．この精度向上は，2 種類の飼料を分けて検出し，それぞれのピクセル数から重量を算出したことに起因すると考えられる．

また，推定重量と重量の真値の差が 2kg 以上あったデータが全体の 2 割強あった原因について，2 点考察した．

1 点目は，Detectron2 による残飼料領域の検出精度が完全ではなく，残飼料の誤検出や未検出が発生している点である．これは，今回学習に用いたカラー画像のデータが少なく，学習に使用できた枚数が 40 枚程度であったことが要因として挙げられる．また，画像によっては光の当たり方の影響により，濃厚飼料と粗飼料の見分けが付きにくいケースがあったことも，誤検出の一因であると考えられる．誤差 2kg 以上のデータのうち，真値よりも少なく推定してしまったデータに関しては，この残飼料の未検出が大きく関係しているため，トレーニングデータの増強や，特徴量の調整，さらに詳細なアノテーションを行うことで改善できると考えられる．未検出例を図 24,25 に示す．



図 24 元画像




図 25 未検出画像

2点目は、飼料の厚みを考慮できていない点である。残飼料画像のうち、飼料が厚すぎて過少に推定してしまっているデータはほとんど見られなかった。これは畜産牛が飼料を食べる際に、飼料は表面からどんどん減っていくため、初めに想定している厚みよりも厚くなることのないのであると考えられる。飼槽に薄く残っている飼料を検出したデータに関しては、特に重量のある濃厚飼料について、その領域のピクセル数をそのまま重量計算する処理を行っているため、実際の重量よりも大幅に過大推定してしまっていると考えられる。誤差 2kg 以上のデータのうち、真値よりも多く推定してしまったデータに関しては、これらが起因していると考えられるため、飼槽に薄くのこった濃厚飼料は、残飼料として検出をしないように Detectron2 で学習、推定することで改善できると考えられる。飼槽に濃厚飼料が薄く残っている画像の例を図 26,27 に示す。



図 26 元画像



図 27 飼料が薄い画像

6.5 考案手法の比較

4.1.4.2 で考案した、機械学習を用いて 4 クラス分類を行う手法では、輝度値順に並べ替えた画像を用いた分類が、他の手法に比べて高い精度を示した。一方、4.3.4.4 で考案した、残飼料領域を検出し、ピクセル数から重量を推定する手法では、Detectron2 を用いた残飼料のセグメンテーションによる重量推定が、精度および汎化性能の両面で優れていることが確認された。最も高い精度を達成した手法は、4.4 で考案した Detectron2 を用いた重量推定手法である。

7. 結論

本研究では、機械学習を用いた残飼料量の 4 クラス分類

の手法と、残飼料領域の検出後、面積から重量を推定する手法の、2 種類のアプローチを採用した。それぞれに 2 種類の手法を導入し、最適な方法を模索した。

この結果から、残飼料量推定の精度を向上させるためには、粗飼料と濃厚飼料の 2 種類のピクセル数を分離して使用することが重要であることが示唆された。

8. 今後の課題

提案システムをさらに改善するためには、以下の 2 つの課題に取り組む必要がある。

1 つ目は、使用する画像データの作成工程の自動化である。本研究で使用した画像データは、1 本の動画から複数の手動工程を経て生成したものである。このプロセスを自動化することで、撮影した動画を入力するだけで残飼料量の推定までを自動的に行えるシステムの実現が期待される。

2 つ目は、残飼料検出の精度向上である。本研究における Detectron2 を用いた手法では、比較的高い精度を示したものの、一部の画像では誤検出が発生している。特に、光の反射や飼槽の汚れといった要因が誤検出の原因となる場合があり、これらの影響を軽減するアルゴリズムの改良が必要である。

これらの課題を解決することで、畜産業の効率化および労働負担の軽減に貢献するものと期待される。

9. 謝辞

本研究は、農林水産省「スマート農業技術の開発・実証プロジェクト（課題名：ローカル 5G を活用した画像解析・見回りロボットによる大規模高品質と牛肥育体系の省力化）」（(有)うしの中山、(株)うしの中山志布志牧場）の支援により実施した。

参考文献

- [1] 農林水産省畜産局. 5 畜産第. 肉用牛の飼養管理に関する技術的な指針. 2023, 1064 号, p.12
- [2] 福島誠人, 竹長慎太郎, 波部齊, 井口信和, 画像解析による植物の重さ推定の提案. 情報処理学会関西支部. 2020
- [3] 會下拓実, 柳井啓司. 米飯画像の実寸推定に基づく面積を考慮したカロリー量推定. 第 22 回画像の認識・理解シンポジウム (MIRU). 2019
- [4] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. "Deep Residual Learning for Image Recognition". IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016
- [5] Tianqi Chen, Carlos Guestrin, "XGBoost: A Scalable Tree Boosting System". KDD. 2016