

LiDARCalorieCam: LiDAR センサを用いた 食事カロリー量推定アプリケーション

藤田 晴斗^{1,a)} 柳井 啓司^{1,b)}

概要

近年、食事のカロリー管理が健康維持やダイエットにおいて重要な役割を果たしている。特に、食事内容やカロリーの記録に対する関心が高まっており、それをサポートするさまざまなアプリが提供されている。しかし、利便性を追求するあまり、精度が低下しているものや、ユーザビリティに課題があるものも少なくない。

そこで、本研究では、iPhone に搭載されている LiDAR センサを用いて、食事のカロリー量をリアルタイムで推定するシステム“LiDARCalorieCam”を提案する。本システムでは、食事の画像を撮影し、深度センサによって食品の 3次元形状を取得する。その 3次元形状をもとに、食品の体積を推定し、その体積を元にカロリーを算出する。本研究の主な貢献は、(1) LiDAR センサを活用した基準物体不要な高精度体積推定手法、(2) 信頼度指標に基づく複数体積算出手法の統合アルゴリズム、(3) モバイル端末を用いたリアルタイム 3D 食品解析システムの実現、(4) 既存手法との定量比較による提案手法の有効性検証である。

1. はじめに

本研究では、LiDAR (Light Detection and Ranging) 技術を用いて食事の 3次元形状を捉え、正確な体積に基づくカロリー推定の精度向上を目指す。これにより、日常的なカロリー管理が効率化し、より実践的な食事管理に貢献できると考えられる。

従来の食事カロリー推定手法は、基準物体の携帯が必要、撮影角度の制限、対応食品カテゴリの少なさなど、実用性の観点で課題が残されている。特に、正確な体積推定が困難であることが、カロリー推定精度の限界となっている。

本研究では、以下の技術的新規性により既存手法の限界を克服する：

(1) **基準物体不要な 3D 体積推定:** LiDAR センサの高精度深度情報を活用し、ユーザビリティを大幅に向上

- (2) **信頼度ベース統合アルゴリズム:** 複数の体積推定手法の結果を変動係数に基づいて統合し、ロバスト性を向上
- (3) **リアルタイム 3D 解析パイプライン:** モバイル端末上でセグメンテーション、分類、カロリー量推定を統合したシステムを実現

2. 関連研究

食事画像を用いたカロリー推定は、健康管理や栄養指導で重要な研究領域である。この分野では、食事のカテゴリ分類と体積推定を組み合わせた手法が一般的で、多様なアプローチが提案されている。

Akpa ら [1] や丹野ら [9] は、箸や米粒など身近な物体を基準としてカロリー推定の精度向上を試みている。一方、Fang ら [4] は食事の幾何学的形状を利用して体積を推定し、Myers ら [6] は領域分割と深度推定ネットワークを組み合わせて、より正確なカロリー量の推定を提案している。

また、Quin ら [10] の研究では、『Nutrition5k』と呼ばれるデータセットを用いて、食品の画像からカロリーを推定する手法を提案している。このデータセットには、5,000 種類以上の食品画像が含まれており、食品の種類とカロリー量、栄養素がラベル付けされている。しかし、データセットの収集対象は西洋料理を中心となっていることや、単一の食品ではなく複数の食品が混在する 경우가多く、1つの食品カテゴリに対してカロリー値を一律に適用するという問題がある。

岡元ら [8] が開発した CalorieCam は、クレジットカードなど既知サイズの基準物体を利用して食事の実面積を算出し、カロリーを推定するシステムである。Android スマートフォンで食事画像を撮影し、食品の種類とカロリー量を推定するアプローチを採用している。手軽に高精度な計測ができる点で優れているが、ユーザーが常に基準物体を用意する必要があり、使用時の負担となる。また、面積のみの計測では立体的な食事の正確な体積推定が難しい。

安蒜ら [2] が開発した DepthCalorieCam は、それまでの問題であった基準物体の用意が不要となったカロリー量推定アプリケーションである。デュアルカメラ深度値を利用

¹ 電気通信大学

^{a)} fujita-h@mm.inf.uec.ac.jp

^{b)} yanai@cs.uec.ac.jp

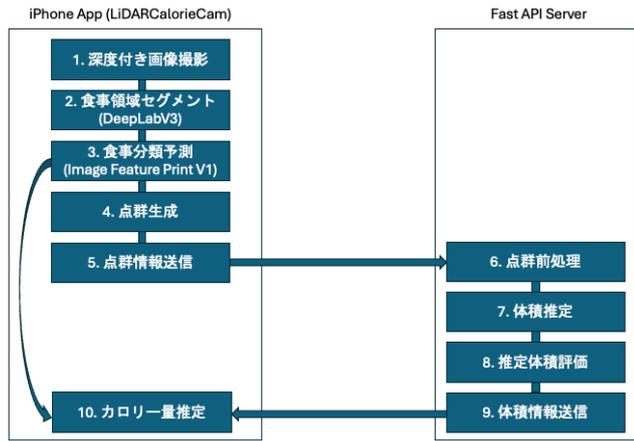


図 1 システムの処理フロー

しており、食品の体積を立体的に計測可能となった。しかし、前上から撮影する必要があることや食事カテゴリが3種類に制限されていることなどが課題として残されている。

本研究では、これらの課題を踏まえ、LiDAR センサを活用した基準物体を必要としない測定方法、立体的な食事の正確な体積推定などの新たなアプローチを提案する。

3. 手法

本研究で提案する「LiDARCalorieCam」は、iPhone の LiDAR センサで得られる深度情報を活用し、食品の3次元形状を推定したうえで体積を計算し、さらに食品の種類に基づくカロリー係数と組み合わせることでカロリー量を算出するシステムである。図1に、システムの全体的なフローを示す。

本システムは、iOS 端末上のクライアントアプリケーションと、サーバーサイドの体積計算処理で構成される。クライアントアプリケーションでは、ARKit により深度推定を行い、Core ML を用いて食品領域のセグメンテーションと食品カテゴリの分類を実行する。これらの情報を基に三次元点群を生成し、サーバーサイドに送信する。サーバー側では受信した点群に対して複数の手法で体積を算出し、推定結果をクライアントに返却する。

3.1 食品領域の抽出

食品領域を切り出すため、本研究では DeepLabV3 を Core ML 形式で運用する方針を取った。UECFoodPix[7] の食事画像データセットで fine-tuning したモデルを iOS 端末に組み込み、リアルタイム推論を行う。背景をマスクし、食品に特化した三次元点群を得るための基礎情報を生成する。

3.2 食品分類

セグメンテーションで抽出された画像を、Apple が提供する iOS の機械学習ライブラリである Create ML の Image

Classification モデルに入力し、食品カテゴリを判定する。Image Classification のモデルは、Image Feature Print V1 (IFP) と呼ばれる特徴量を抽出するための畳み込みニューラルネットワークを使用している。UEC Food-100[5] のデータセットを用いて学習したモデルを適用し、後に各カテゴリに対応するカロリー密度や体積-重量変換用の回帰式を後段で参照できるようにする。

3.3 深度推定 (ARKit の sceneDepth)

本研究では、iOS 端末上の拡張現実 (AR) 開発フレームワークである ARKit を用いて食品の三次元情報を取得する。LiDAR センサからの深度情報をリアルタイムで取得できるライブラリを用い、各フレームに対して、カメラの RGB 画像と対応する深度マップを同時に受け取り、奥行き方向の情報を利用することが可能となる。

ARFrame には、カメラ姿勢と内部パラメータ (K 行列) が含まれる。内部パラメータは、焦点距離 f_x, f_y と画像中心 (c_x, c_y) で表され、

$$K = \begin{pmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{pmatrix}$$

ピクセル座標 (u, v) と深度 d が与えられた場合、実世界座標は

$$X = \frac{(u - c_x)d}{f_x}, \quad Y = \frac{(v - c_y)d}{f_y}, \quad Z = d$$

と求められる。ここで d はメートル単位の深度値で、得られる (X, Y, Z) はカメラ座標系における位置を示す。

3.4 点群生成

セグメンテーションマスクを用いて食品画素のみを抽出し、RGB 値と座標情報を組み合わせる。深度マップ (256 × 192) と RGB 画像 (1920 × 1440) と解像度が異なるためスケーリングを考慮した点群を作成する。各点には (X, Y, Z) と (R, G, B) の情報が付与され、サーバーへ送信される。実際にサーバー側で受信された点群データの例を図2に示す。

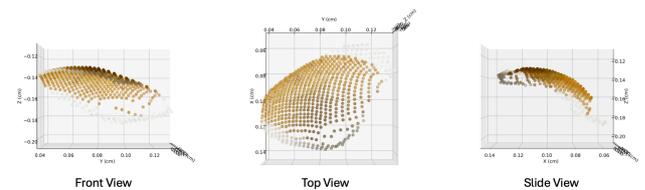


図 2 点群データの例

3.5 体積計算

サーバー側に受信した点群に対して点群中の密度の低い

領域や孤立した点を外れ値として検出・除去できるよう、DBSCAN[3]を用いた外れ値の除去を行う。なお外れ値除去により半数以上の点が失われた場合は元の点群にロールバックするように設計している。

3.6 信頼度ベース統合アルゴリズム

本システムでは、3つの手法を組み合わせて体積を推定する。点群から体積を計算する代表的な手法として、Convex Hull 法, Delaunay 三角分割法, メッシュベース法を採用している。

各手法から得られた体積値の平均 μ と標準偏差 σ を計算し、変動係数 (CV: Coefficient of Variation) $CV = \frac{\sigma}{\mu}$ を求める。信頼度を $confidence = e^{-CV}$ で定義し、confidence が高いほど精度が高いとみなす。

推奨体積の選択は信頼度が 0.8 以上の場合はメッシュベース法の結果を採用し、それ以外については Convex Hull 法の結果を採用している。この統合アルゴリズムにより、単一手法では対応困難な複雑形状に対してもロバストな体積推定を実現する。

3.7 カロリー推定

3.7.1 体積から重量への変換

食品カテゴリごとに事前に測定した体積-重量データを用いて回帰式を作成する。回帰式を $W = aV + b$ とし、 V を体積、 W を重量とする。パラメータ a と b はカテゴリごとに異なる値を設定し、推定された体積を入力とすることで重量を推定する。

3.7.2 重量からカロリー量への変換

カテゴリごとのカロリー密度 [kcal/g] を食品成分表や既存データベースから取得し、 $\hat{C} = D \times \hat{W}$ よりカロリー量 \hat{C} を求める。ここで D はカテゴリごとに定義されるカロリー密度、 \hat{W} は推定重量である。

4. 実験

本システムの性能を総合的に評価し、考察を行う。また、実際のアプリケーションの動作例を図 3 と図 4 に示す。

4.1 体積推定の精度評価

実験方法

複数の食品を 30cm 程度の距離から斜め撮影し、取得した三次元点群に対して体積を推定する。推定体積と実体積の差を評価するため、実体積の測定には計量カップや水置換法などを活用し、吸水性がある食品にはラップを巻くなどの対応を行った。

実験結果

表 1 に、食品ごとの推定体積と実体積の誤差について MAE と MAPE で評価する。なお、今回はすべての測定データが信頼度を 0.8 を超えていたためメッシュベースの



図 3 撮影画面



図 4 カロリー推定結果

体積値を使用している。

表 1 食品ごとの体積推定誤差

食品	MAE (cm ³)	MAPE (%)
唐揚げ	32.5	64.5
コロッケ	58.0	31.0
焼き鳥	37.4	39.5
ホットドッグ	28.5	8.8
トースト	61.3	13.9
焼きそば	14.4	7.8
ポテトサラダ	14.7	12.4
おにぎり	27.7	31.1
卵焼き	3.4	14.0
野菜炒め	17.0	13.1

撮影角度や食品形状に起因するバラツキはあるが、大きな外れ値は少なく、概ね許容範囲内に収まる結果が得られた。一部の食品では誤差が大きくなる傾向が見られたが、これは撮影角度や形状の特性によるものと考えられる。

4.2 重量推定の回帰分析

実験方法

推定体積 (V) と実重量 (W) の関係を単回帰分析によってモデル化する。食品カテゴリごとに複数サイズの食品を撮影し、回帰式 $W = aV + b$ を求める。

実験結果

表 2 に 10 カテゴリの回帰式と決定係数 R^2 を示す。

表 2 食品ごとの推定体積 (V) から重量 (W) を求める回帰式

食品	回帰式 ($W = aV + b$)	R^2
唐揚げ	$W = 0.45V + 11.4$	0.95
コロッケ	$W = 0.33V + 38.0$	0.87
焼き鳥	$W = 0.36V + 26.0$	0.92
ホットドッグ	$W = 0.17V + 23.81$	0.65
トースト	$W = 0.15V + 22.6$	0.97
焼きそば	$W = 0.44V + 21.35$	0.85
ポテトサラダ	$W = 0.77V + 5.2$	0.71
おにぎり	$W = 0.49V + 20.7$	0.81
卵焼き	$W = 0.65V + 4.0$	0.62
野菜炒め	$W = 0.29V + 28.0$	0.85

4.3 カロリー推定の精度評価

体積から重量を推定し、さらに食品成分表や既存のカロリー情報に基づいてカロリー量を計算する。表 3 と表 4 に、食品ごとの推定カロリーについて MAE と MAPE を示す。カロリー量は文部科学省が公開している日本食品標準成分表 [11] と、食品栄養情報が掲載された Web サイトであるカロリー Slism^{*1}を参考にしている。既存研究 DepthCalorieCam と比較するために、唐揚げとコロッケの結果を合わせて示す。

表 3 カロリー量の推定結果の誤差 MAE (kcal)

食品カテゴリ	DepthCalorieCam	LiDARCalorieCam
唐揚げ	101.29	15.88
コロッケ	43.09	12.83
焼き鳥	—	25.68
ホットドッグ	—	12.03
トースト	—	23.95
焼きそば	—	30.42
ポテトサラダ	—	16.76
おにぎり	—	24.19
焼き鳥	—	6.01
野菜炒め	—	11.52

表 4 カロリー量の推定結果の誤差 MAPE (%)

食品カテゴリ	DepthCalorieCam	LiDARCalorieCam
唐揚げ	52.84	7.87
コロッケ	20.11	6.10
焼き鳥	—	11.50
ホットドッグ	—	5.59
トースト	—	8.64
焼きそば	—	16.25
ポテトサラダ	—	16.81
おにぎり	—	12.15
卵焼き	—	10.53
野菜炒め	—	9.99

*1 <https://calorie.slism.jp/>

5. 考察

5.1 体積推定誤差とカロリー推定誤差の関係

唐揚げにおいて、体積推定の MAPE 値が 64.5%と大きいにも関わらず、カロリー推定では 7.87%まで誤差が改善される現象が観察された。これは、回帰式 $W = 0.45V + 11.4$ ($R^2 = 0.95$) の定数項 11.4g が体積推定における系統誤差を効果的に補正するためである。具体的には、体積の過大評価による重量増加分が定数項により相殺され、最終的なカロリー推定精度が向上する。

5.2 実用性の観点からの評価

本研究で達成されたカロリー推定精度 (MAPE 5.59-11.50%) は、栄養指導における一般的な許容誤差 (± 20%程度) を大幅に下回っており、実用レベルに達していると考えられる。また、従来の手動入力方式と比較して、ユーザーの操作負荷を大幅に軽減しながら高精度を実現している。

5.3 既存手法との定量比較

DepthCalorieCam との比較において、唐揚げで MAE 85.41kcal (83.9%)、コロッケで MAE 30.26kcal (70.2%) の誤差削減を達成した。これは、LiDAR センサによる高精度な深度情報取得と、信頼度ベース統合アルゴリズムの効果によるものである。

5.4 今後の改善方向

実用化に向けては、食品データベースの大幅拡充、マルチビュー撮影による 3D 再構成精度向上、深層学習による直接的なカロリー回帰モデルの導入が有効と考えられる。

6. おわりに

本稿では、iPhone の LiDAR センサと深層学習モデルを活用し、食事の 3 次元形状を正確に測定することで、基準物体を用いずにリアルタイムなカロリー推定を実現するシステム「LiDARCalorieCam」を提案した。

実験の結果、従来手法と比較して体積推定およびカロリー推定の精度向上が確認され、栄養指導の許容誤差を大幅に下回る精度を実現した。

今後は、より多様な食品カテゴリに対応するための大規模な学習データの拡充、容器や皿など外部オブジェクトの影響除去、および液体や複雑形状の食品に対する推定精度の向上に取り組むことで、実用性の高い食事管理システムの実現を目指す。

参考文献

- [1] Akpa, E., Suwa, H. and Yasumoto, K.: Smartphone-Based Food Weight and Calorie Estimation Method for Effective Food Journaling, *SICE Journal of Control, Measurement, and System Integration* (2017).
- [2] Ando, Y., Ege, T., Cho, J. and Yanai, K.: DepthCalorieCam: A Mobile Application for Volume-Based Food Calorie Estimation using Depth Cameras, *Proc. of ACM MM Workshop on Multimedia Assisted Dietary Management (MADIMA)* (2019).
- [3] Ester, M., Kriegel, H.-P., Sander, J. and Xu, X.: A density-based algorithm for discovering clusters in large spatial databases with noise, *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, p. 226–231 (1996).
- [4] Fang, S., Liu, C. et al.: Single-view food portion estimation based on geometric models, *IEEE International Symposium on Multimedia (ISM)*, pp. 385–390 (2015).
- [5] Matsuda, Y., Hoashi, H. and Yanai, K.: Recognition of Multiple-Food Images by Detecting Candidate Regions, *Proc. of IEEE International Conference on Multimedia and Expo (ICME)* (2012).
- [6] Meyers, A., Johnston, N. et al.: Im2Calories: towards an automated mobile vision food diary, *Proc. of IEEE International Conference on Computer Vision*, pp. 1233–1241 (2015).
- [7] Okamoto, K. and Yanai, K.: UEC-FoodPIX Complete: A Large-scale Food Image Segmentation Dataset, *Proc. of ICPR Workshop on Multimedia Assisted Dietary Management (MADiMa)*, p. 647–659 (2021).
- [8] Okamoto, K. and Yanai, K.: An Automatic Calorie Estimation System of Food Images on a Smartphone., *In Proc. of ACM MM Workshop on Multimedia Assisted Dietary Management (MADiMa)* (2016).
- [9] Tanno, R., Ege, T. and Yanai, K.: AR DeepCalorieCam V2: Food calorie estimation with cnn and ar-based actual size estimation, *In Proc. of the 24th ACM Symposium on Virtual Reality Software and Technology* (2018).
- [10] Thames, Q., Karpur, A., Norris, W., Xia, F., Panait, L., Weyand, T. and Sim, J.: Nutrition5k: Towards Automatic Nutritional Understanding of Generic Food, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 8903–8911 (2021).
- [11] 文部科学省：日本食品標準成分表（八訂）増補 2023 年，https://www.mext.go.jp/a_menu/syokuhinseibun/mext_00001.html.