

複数食材の大きさを統合利用した弁当画像の縮尺推定に関する検討

渡辺茉里香[†] 久徳 逢矢^{††,†} 道満 恵介^{†††,†}

駒水 孝裕[†] 井手 一郎[†]

[†] 名古屋大学 〒464-8601 愛知県名古屋市千種区不老町

^{††} 愛知工科大学 〒443-0047 愛知県蒲郡市西迫町馬乗 50-2

^{†††} 中京大学 〒470-0393 愛知県豊田市貝津町床立 101

E-mail: [†] watanabem@cs.is.i.nagoya-u.ac.jp, taka-coma@acm.org, ide@i.nagoya-u.ac.jp,

^{††} kyutoku-haruya@aut.ac.jp, ^{†††} kdoman@sist.chukyo-u.ac.jp

あらまし 近年、健康意識の高まりに伴い食事管理の需要が高まっている。日々の簡易な食事管理を支援する上で、料理画像から食事量を自動で推定する技術が必要不可欠である。本報告では弁当画像を対象として、画像中で複数の基準となる食材（以下、基準食材）の大きさから画像の縮尺値として1画素あたりの実寸値を推定する。具体的には、正規分布による手法と回帰モデルによる手法の2種類を提案する。前者の手法では、各基準食材の実寸値が正規分布に従うと仮定し、予め実測して得た正規分布を使用する。この分布に基づいて、画像平面上の基準食材の大きさにおける確率の積が最大となる縮尺値を非線形最適化により求める。また、後者の手法では、画像平面上の基準食材の大きさを説明変数、画像の縮尺である1画素あたりの実寸値を目的変数とし、ランダムフォレストを用いた回帰による画像の縮尺推定を行なう。実験では、基準食材を含む弁当を撮影することで構築した弁当画像データセットを用いて評価した。実験結果から、正規分布による手法より回帰モデルによる手法の方が高い推定精度を示した。また、両手法において画像に含まれる基準食材の増加が推定精度向上に寄与することが示唆された。

キーワード 料理画像, 食材, 縮尺推定, 画像認識, 食事記録

A Study on *Bento* Image Scale Estimation by using Sizes of Multiple Ingredients

Marika WATANABE[†], Haruya KYUTOKU^{††,†}, Keisuke DOMAN^{†††,†},

Takahiro KOMAMIZU[†], and Ichiro IDE[†]

[†] Nagoya University Furo-cho, Chikusa-ku, Nagoya, Aichi, 464-8601 Japan

^{††} Aichi University of Technology 50-2 Manori, Nishihama-cho, Gamagori, Aichi, 443-0047 Japan

^{†††} Chukyo University 101 Tokodachi, Kaizu-cho, Toyota, Aichi, 470-0393 Japan

E-mail: [†] watanabem@cs.is.i.nagoya-u.ac.jp, taka-coma@acm.org, ide@i.nagoya-u.ac.jp,

^{††} kyutoku-haruya@aut.ac.jp, ^{†††} kdoman@sist.chukyo-u.ac.jp

Abstract Recently, due to growing health awareness, there has been an increasing demand for meal management. Automated estimation of meal quantities from food images is crucial for supporting easy meal management. This report focuses on *bento* images and proposes two methods for estimating image scale based on ingredient sizes; a normal distribution-based method and a regression-based method. The former estimates the image scale by integrating multiple normal distributions that the actual sizes of each reference ingredient follows a normal distribution, while the latter utilizes a random-forest regressor to estimate the image scale based on the sizes of reference ingredients. Experimental results on a newly created *bento* image dataset showed that the regression-based method outperformed the normal distribution-based method, and that the estimation accuracy increased as reference ingredients increased.

Key words Food image, ingredient, estimation of image scale, image recognition, food recording

1. はじめに

人々にとって食事は健康的な生活を送る上で重要な要素である。近年では、新型コロナウイルスの流行などから健康に対する意識が高まり、健康的な食生活を目指す人が増加している [1]。健康的な食生活を実現する上で、日々の食事で摂取したカロリー量や栄養素量を記録し、改善へ繋げることが重要である。簡易な食事管理を支援するため、撮影した料理画像からカロリー量や栄養素量を自動的に推定するソフトウェアが開発されており、健康的な食生活を目指す利用者の注目を集めている。これらのサービスは、料理画像からの料理カテゴリ判別に基いて標準的なカロリー量を反映している。これは実際の量が考慮されないため、より正確なカロリー量を反映したい場合は利用者が各料理の重量を計測するなどして食事量を人手で入力する必要がある。この作業は利用者の負担が大きく、日々継続して食事管理を行なう妨げになっている。そのため、実用性を向上させるためには、食事量の自動推定が必要不可欠である。

本研究では、自作弁当を職場に持参する人が増えている現状 [2] を受けて、食事の中でも特に自作弁当に着目する。一般に自作弁当を用意する人は、食費を抑えられるという費用面に加えて、栄養バランスを重視している [3]。しかし、自作弁当はカロリー量や栄養素量を容易に把握できないという課題がある。栄養バランスを重視して自作弁当を用意する人にとって、この課題は食事の管理における制約となっている。

これらの課題に対し、画像の縮尺を示す特定の物体を料理と同時に撮影することで、料理画像から食事量を推定する技術が提案されている [4]。この手法は、撮影時に利用者の手間を要し、さらに Social Networking Service (SNS) 上に投稿されている料理画像など、既存の画像から食事量を推定することはできない。そこで、本研究では料理画像に含まれる食材の大きさをセグメンテーション技術で取得し、これらを指標として縮尺を推定する手法を提案する。以降、2. で関連研究について述べ、3. で提案手法、4. で評価実験について述べる。さらに、5. で評価実験の考察をし、6. で本報告をまとめる。

2. 関連研究

2.1 食材のセグメンテーションに関する研究

食材ごとのセグメンテーションに関する研究として、多様な粒度で食品をセグメンテーションする FoodSAM が提案されている [5]。これは、Segment Anything Model (SAM) [6] を利用した、料理画像における食材に特化したセグメンテーションモデルである。ここで SAM とは、学習していない物体 (未知物体) に対しても高精度なセグメンテーションを可能にしたモデルである。しかし、汎用モデルである SAM は料理画像に対して食材カテゴリを正確に識別することが困難であった。これに対し FoodSAM は、高精度な食材カテゴリのクラス分類を行なう従来手法と高品質なセグメンテーションを出力する SAM を統合したモデルである。また、FoodSAM は切断された食材をそれぞれ 1 つの個体とみなすことができ、同一カテゴリの食材の領域を個体ごとに検出するインスタンスセグメンテーション

を実現している。本研究では弁当画像からの食材領域の抽出に FoodSAM を使用する。

2.2 料理画像からの食事量推定に関する研究

料理画像からのカロリー量推定に関する研究として、撮影した料理画像から食事量を推定し、食品のカロリーを自動推定するシステムである CalorieCam が提案されている [4]。このシステムは、画像の縮尺を示す基準物体を料理画像に含めることで、基準物体の画素数との比較により各食品の食事量推定を実現している。この手法では料理画像の撮影時に料理とは無関係である基準物体を含めて撮影する必要があるため、撮影時に手間を要し、さらに SNS 上などに投稿されているカロリー量推定を目的とせず撮影された料理画像には対応できない。

さらに、基準物体を必要としない料理画像からのカロリー量推定に関する研究として、深度の測定が可能なカメラが搭載された携帯端末を使用し、料理の体積を考慮したカロリー量推定が提案されている [7]。実験では、カロリー量が既知である料理に対して体積を推定したデータを収集することで、推定体積とカロリー量に関する回帰式を得ている。そして、回帰式を算出した 3 つの料理カテゴリにおけるカロリー量を推定し、高い精度を示している。しかし、この手法ではカテゴリごとに推定体積とカロリー量のデータを収集して回帰式を得る必要があり、未学習のカテゴリに対するカロリー推定はできない。

また、畳み込みニューラルネットワーク (Convolutional Neural Network; CNN) を用いて米飯画像から料理領域の表面積を推定する手法が提案されている [8]。この手法では米飯粒の大きさがある程度一定であることに着目し、複数の米飯粒が密集した米飯画像から実寸を推定する CNN を構築している。実験では、様々な盛り付け方の米飯をテーブル面に対して垂直に真上から撮影した実寸情報付き米飯画像データセットを独自に作成し、CNN の学習および評価で使用している。本研究では、実寸を推定する基準として複数の食材を利用することで、料理画像からの縮尺推定の精度向上を目指す。

3. 提案手法

提案手法では、弁当画像から抽出した複数の食材の大きさを統合利用することで画像の縮尺を推定する。従来手法の多くは料理とは無関係の実寸が既知である基準物体を含めた料理画像を撮影する必要があったが、本手法では料理に含まれる食材自身を基準物体として扱う。これにより、撮影時に基準物体を含める手間が不要であり、さらに食事量推定を目的とせず撮影された料理画像に対しても縮尺推定を可能とすることを目指す。また、2. で紹介した米飯を基準とした料理画像からの縮尺推定は米飯のみを基準としていたが、本手法では複数の食材を基準として扱う。これにより料理画像からの縮尺推定の精度向上を期待する。図 1 は提案手法全体の処理手順である。まず弁当画像を入力し、セマンティックセグメンテーション技術を用いて弁当画像に含まれる食材ごとの領域を抽出する。次に、提案する 2 つの手法において、セグメンテーション結果から得られる画像上の基準食材の大きさを利用して画像の縮尺推定を行なう。具体的には、正規分布による縮尺推定と回帰モデルによ




図 1: 提案手法の処理手順 .




図 2: 対象物体に対する Feret 径の最大値と最小値 .


る縮尺推定を提案する .

3.1 基準食材とその大きさ

本研究では, 基準食材としてミニトマト, ゆで卵, ミートボール, ウィンナーソーセージを使用する. これらの基準食材は, 自作弁当において一般的に含まれることが多く, 標準的な大きさのばらつきが小さいものとして選択した. また, 本手法では, 基準食材の大きさを表す値として Feret 径 [9] を使用する. 図 2 に示すように Feret 径とは, ある図形に外接する長方形の辺の長さを指す. 各基準食材において, 個体差による実寸の変動が小さい箇所を食材の大きさを表す値に採用するため, ミニトマトやミートボールは Feret 径の最大値, ゆで卵は半分に切断した黄身部分における Feret 径の最大値, またウィンナーソーセージは Feret 径の最小値を採用する. 本研究では, 弁当画像から食材ごとの領域を抽出するために 2.1 で述べた FoodSAM [5] を用いる. これにより得られた食材領域のマスク画像から画像平面上における各食材の Feret 径を計測する. 弁当画像からウィンナーソーセージとゆで卵の黄身部分の Feret 径を計測した例を図 3 に示す.


3.2 手法 1: 正規分布による縮尺推定

本研究における基準食材は, 弁当に含まれることが多く, 標準的な大きさのばらつきが小さい食材を選択した. ミートボールとウィンナーソーセージは加工食品であり, 製造過程において均一な大きさや重さで生産されていると考えられる. 一方,



(a) 弁当画像の例 .

(b) ウィンナーソーセージに対する Feret 径 .



(c) ゆで卵の黄身部分に対する Feret 径 .

図 3: 弁当画像からの食材ごとの Feret 径 .

ミニトマトや鶏卵に関しても, 大きさや重さの規格に沿って販売されている. そのため, どの基準食材も大きさが概ね均一であると考えられるため, 本手法では各基準食材の実寸値は正規分布に従うと仮定する. まず, 各基準食材の実寸の統計を得るために実際に食材の大きさを計測し, 収集したデータから算出した平均値と標準偏差に基づく正規分布を得る. これらの正規分布と画像上の基準食材の大きさを利用して, 画像の縮尺値として 1 画素あたりの実寸 [mm/pixel] を求める. 式 1 は, 確率変数 x , 平均 μ , 標準偏差 σ とした正規分布の確率密度関数である.

$$f(x; \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \quad (1)$$

ここで, C は基準食材集合を表し, 本研究では $C = \{\text{ミニトマト, ミートボール, ウィンナーソーセージ, ゆで卵}\}$ である. 画像上における各基準食材の Feret 径 (画素数) を x_c ($c \in C$), 予め得た基準食材の平均値と標準偏差をそれぞれ μ_c , σ_c , 求めたい 1 画素あたりの実寸値を y [mm] とし, 式 2 に従い, 正規分布の確率密度関数の積が最大となる \hat{y} を求める.

$$\hat{y} = \arg \max_y \prod_{c \in C} f(x_c y; \mu_c, \sigma_c) \quad (2)$$

なお, 同種類の基準食材が複数含まれる場合は, 画像平面上における当該食材の Feret 径の平均値を x_c とする. 最大値の算出には, 非線形最適化アルゴリズムを用いる.

3.3 手法 2: 回帰モデルによる縮尺推定

回帰を用いて, 弁当画像に含まれる基準食材の大きさから画像の縮尺を推定する手法について述べる. 本研究では, 決定木



図 4: 作成した弁当画像データセットの画像例 .



(a) 入力画像 . (b) ノイズ除去前 . (c) ノイズ除去後 .

図 5: ウィンナーソーセージ領域のノイズ除去例 .

とアンサンブル学習を組み合わせる分類や回帰を行なう機械学習アルゴリズムであるランダムフォレスト [10] を用いる . 説明変数として各基準食材 $c \in C$ の画像平面上の Feret 径 x_c を並べたベクトルを, 目的変数として 1 画素あたりの実寸値 y を用いてモデルを構築する . つまり, $|C|$ 次元の説明変数 x_c から 1 次元の目的変数 y を推定する . なお, 正規分布による縮尺推定手法と同様に同種類の基準食材が複数含まれる場合は, 画像平面上の Feret 径の平均値を使用する . また, 基準食材集合 C のうち弁当画像に含まれない食材がある場合は, 説明変数の一部が欠損値となる . このとき, 弁当に含まれない食材は弁当画像上の大きさが 0 画素であると考え, 欠損値を 0 で補完して学習や推定に使用する .

4. 評価実験

提案手法による縮尺推定精度の評価実験について述べる . まず, 実験に使用する弁当画像のデータセットを構築した . このデータセットを用いて, 正規分布による手法と回帰モデルによる手法を用いた縮尺推定を行なった . さらに, 画像中の弁当箱領域の Feret 径を用いて弁当箱の直径の実寸を推定することで精度評価を行なった .

4.1 データセットの構築

提案手法の有効性を評価するため, 独自に弁当画像データセットを構築した . 構築したデータセットの画像例を図 4 に示す .

4.1.1 弁当画像の撮影

まず各基準食材について, 大きさが異なる 2 種類の食材を用意した . また, 容器の縁が円形であり, その直径が 135 mm である弁当箱を用意した . これらを使用して, 弁当に基準食材が 2 種類以上かつ 3 個以上含まれるように詰め替えながら 68 通りの弁当を用意し, それぞれ長さ約 50 秒の動画を撮影した . このとき, 実利用時を想定した多様な画像を含めるため, 各弁当に対して被写体とカメラの距離や角度を変更しながら撮影した . 撮影には Apple 社の iPhone 12 を使用し, 解像度 3,840×2,160 pixel, フレームレート 60 fps の動画を撮影した .

表 1: 基準食材の大きさを 20 個ずつ計測した結果 .

| 食材 | 平均 [mm] | 標準偏差 [mm] |
|------------|-----------|-------------|
| ミニトマト | 28.81 | 1.577 |
| ゆで卵 | 31.00 | 1.640 |
| ミートボール | 25.64 | 1.262 |
| ウィンナーソーセージ | 19.37 | 0.662 |

表 2: 各手法におけるデータセット全体の MAE .

| 手法 | MAE [mm] |
|-------|------------|
| 正規分布 | 12.22 |
| 回帰モデル | 7.42 |

1 つの動画を 49 等分した区切りのフレームにおける画像を 50 枚抽出し, 全体で 3,400 枚の弁当画像を収集した .

4.1.2 画像上の食材領域の抽出

料理画像に特化したインスタンスセグメンテーション手法である FoodSAM [5] を使用して, 弁当画像中の個々の食材領域を抽出し, そのカテゴリ名を取得した . セグメンテーション結果にはノイズが含まれる場合があるため, 各カテゴリの領域群に対して小領域除去を施した . ウィンナーソーセージに対するノイズ除去の例を図 5 に示す .

4.2 実験手順

構築したデータセットを用いた提案手法の評価実験について述べる . 正規分布による手法では, まず各基準食材の実寸の統計量を得るために, 各食材につき 20 個ずつデジタルノギスを用いた実寸を計測した . 使用したノギスの最小計測値は 0.1 mm である . 各基準食材について, Feret 径の最大値または最小値を計測した . 結果の集計を表 1 に示す .

一方, 回帰モデルによる手法では, 弁当画像のデータセットに対して Leave-one-out 交差検証による画像の縮尺推定を行なった . 具体的には, データセットに含まれる同一の弁当を撮影して得られた 50 枚の弁当画像を 1 セット (以下, 画像セット) とし, 同一の弁当を 1 つとみなした際の Leave-one-out 交差検証を行なった . データセットには 68 個の画像セットが含まれるため, 回帰モデルによる推定手法では, 68 回の学習とテストを行なった .

以上の手順により, 両手法において弁当画像のデータセットに対する画像の縮尺値を推定した . さらに, 推定した縮尺値と画像中の弁当箱領域の Feret 径との積を弁当箱の直径の実寸 (本データセットでは 135 mm) と比較することで推定精度を評価した . 評価には, 弁当箱の直径に対する平均絶対誤差 (Mean Absolute Error; MAE) を用いた .

4.3 実験結果

両手法における全画像セットに対する MAE の平均値を表 2 に示す . この表から, 正規分布より回帰モデルによる手法の方が, 全体として約 5 mm 高精度な結果が得られたことがわかる .

5. 考 察

5.1 各手法における縮尺推定結果の評価とその比較

カロリー量推定を目的とした弁当画像の縮尺推定という観点から、各手法による推定精度を評価する。ここで食品表示法(平 25 法 70)の規定に基づいて定められている食品表示基準について述べる。一般用加工食品の販売には栄養成分表示が義務付けられているが、その表示する値は食品表示基準に定められている許容差の範囲内にある必要がある。このうち、熱量(カロリー量)の許容差の範囲は $\pm 20\%$ である。この熱量の許容差から、本実験で推定した弁当箱の直径における誤差の許容範囲を定める。カロリー量は体積に比例すると仮定すると、相似比は体積比の3乗根であるため、推定体積が実際の体積の $\pm 20\%$ となる直径の誤差の範囲は次式で求めることができる。

$$\text{推定した直径値の許容範囲} = \sqrt[3]{135^3 \pm 135^3 \times 0.2} \quad (3)$$

つまり、容器の直径が135 mmの弁当箱における許容範囲は約125.32 ~ 143.46 mmであると考え、実寸値からの誤差は $-9.68 \sim +8.46$ mmがカロリー量推定における許容範囲であるとみなす。

以上をふまえて4.で述べた結果を評価する。表2に示したように、回帰モデルによる手法におけるデータセット全体のMAEは7.42 mmであった。これは、カロリー量推定を目的とした弁当画像の縮尺推定という観点において許容範囲内の推定結果であり、本手法の有効性が確認された。一方、正規分布による手法におけるデータセット全体のMAEは許容範囲外である12.22 mmとなったため、本手法は改善が必要である。

このように本実験では、2つの推定手法による推定結果において精度差が生じた。誤差の大きい結果となった正規分布による手法では、実際に食材の大きさを計測して求めた平均値と標準偏差に基づく正規分布を使用して、画像上の食材の大きさにおける確率を算出した。本手法では、各基準食材の実寸値はあらかじめ計測により得た正規分布に従うと仮定したが、画像の縮尺推定に利用するためにはより多くの食材から統計を得た平均値や標準偏差に基づく正規分布を要する可能性があると考えられる。

一方、回帰モデルによる手法では、低次元の単純な特徴ベクトルを用いているが、弱識別器である決定木を組み合わせることで全体を構築するランダムフォレストの性質が合致した結果、正規分布による手法より高精度な縮尺推定が可能となったと考える。また、使用した弁当画像データセットに含まれる各食材につき2つの大きさのみを学習に使用したため、多くの画像セットで正規分布による手法よりも高い精度を示したと考える。

5.2 基準食材の種類数や個数の違いによる精度への影響

画像に含まれる基準食材の種類数や個数の違いによる縮尺推定精度への影響を確認するため、画像セットごとの精度に基づいて、様々な評価基準によるMAEを新たに集計した。まず、画像に含まれる基準食材の種類数ごとにMAEを集計した結果を図6に示す。次に、画像に含まれる基準食材の個数ごとにMAEを集計した結果を図7に示す。さらに、種類数と個数の

表 3: 画像に含まれる基準食材の種類数と個数の組み合わせにおける MAE [mm] (正規分布による手法)。

| | | 個数 | | | |
|-----|---|-------|-------|-------|-------|
| | | 3 | 4 | 5 | 6 |
| 種類数 | 2 | 10.98 | 6.34 | — | — |
| | 3 | 13.61 | 12.00 | 11.06 | — |
| | 4 | — | 12.37 | 12.19 | 10.40 |

表 4: 画像に含まれる基準食材の種類数と個数の組み合わせにおける MAE [mm] (回帰モデルによる手法)。

| | | 個数 | | | |
|-----|---|-------|------|------|------|
| | | 3 | 4 | 5 | 6 |
| 種類数 | 2 | 10.50 | 6.25 | — | — |
| | 3 | 7.67 | 7.13 | 5.33 | — |
| | 4 | — | 6.32 | 6.28 | 4.08 |

図 6: 画像に含まれる基準食材の種類数ごとの MAE。




図 7: 画像に含まれる基準食材の個数ごとの MAE。

組み合わせごとの精度について、正規分布による手法におけるMAEを表3、回帰モデルによる手法におけるMAEを表4に示す。表中の横線「—」は、種類数と個数に該当する画像セットがない箇所である。これらの結果に基づいて、以下で評価基準ごとに考察を行なう。

まず、図6に示す結果から、正規分布による手法では画像中に基準食材が2種類だけ含まれるときにMAEが最小であった。このことから正規分布による手法では、画像に含まれる基準食材の種類数による推定精度への影響は小さく、基準食材の種類数より個数の増加の方が推定精度の向上に寄与すると考えられる。本手法では、画像に含まれない食材の正規分布は使用しなかったため、種類数を増加させて多くの正規分布における確率を使用するよりも、種類数が少なくても食材の個数を増やして個体差による誤差を減少させる方が縮尺推定の精度向上に繋

がったと考えられる。一方、回帰モデルによる手法では、画像に含まれる基準食材の種類数が多いほど MAE が小さいことがわかった。本手法におけるランダムフォレストの学習では、説明変数の次元を基準食材の種類数 $|C|$ で固定したため、画像に含まれない基準食材に関しては説明変数の値を 0 で補完した。これにより、基準食材の種類数が多いほど機械学習における説明変数の情報量も多いため、高い推定精度に繋がったと考えられる。弁当画像に含まれる基準食材の種類が少ない場合に対応するためには、画像中の使用可能な食材の情報のみをより適切に取り扱う方法の検討が必要である。

次に、図 7 に示す結果から、画像に含まれる基準食材の個数に関わらず、回帰モデルによる手法の方が正規分布による手法よりも 5 mm ほど MAE が小さい結果となった。また、両手法において、画像に含まれる基準食材の個数が多いほど MAE が小さかった。これは、基準食材の大きさの個体差による推定誤差への影響が、基準食材の個数が増えることにより軽減されるためであると考えられる。さらに表 3、表 4 に示すように、種類数が同一であるという条件の下でも基準食材の個数が多いほど MAE が小さいことがわかる。これは弁当画像に同種類の基準食材が複数存在する場合、画像上の基準食材の大きさとしてその平均を扱うため、食材の大きさの個体差による推定誤差が軽減したと考える。

6. まとめ

本報告では容易な食事管理の支援を目指し、料理画像からの食分量自動推定を目的とした。料理画像の中でも特に弁当画像に焦点を当て、画像中の複数の食材の大きさから画像の縮尺を推定するため、正規分布による手法と回帰モデルによる手法を提案した。正規分布による手法では、各基準食材の実寸値が正規分布に従うと仮定し、実測にて得た正規分布を使用した。この分布に基づいて、画像平面上の基準食材の大きさにおける確率の積が最大となる縮尺値を非線形最適化により求めた。また、回帰モデルによる手法では、画像平面上の基準食材の大きさを説明変数、画像の縮尺である 1 画素あたりの実寸値を目的変数とし、ランダムフォレスト [10] による画像の縮尺推定を行なった。評価のため、まず基準食材を含む弁当の画像データセットを独自に構築した。これを用いた実験から、正規分布による手法より回帰モデルによる手法の方が高い推定精度を示す結果を得た。また、両手法において画像に含まれる基準食材の個数の増加が推定精度向上に寄与することが示唆された。今後の課題として、以下の項目が考えられる。

a) 食材の実寸におけるより適切な平均値と標準偏差の取得

正規分布による手法では、各基準食材の統計を得るために、実際に食材の大きさを測定し、平均値と標準偏差を求めた。しかし、これは実際の食材の大きさを正しく反映した値であるとは限らない。本手法の精度を向上させるためには、より多くの食材の実寸から統計を得て適切な平均値や標準偏差を設定する必要があると考える。

b) 弁当画像データセットの拡大

本報告では、弁当画像のデータセットとして各食材について

大きさが異なる 2 つの食材を使用した。撮影角度を変えながら撮影したため、弁当画像内の食材の大きさ（画素数）は様々であったが、食材の実寸はそれぞれ 2 種類の大きさしか使用していない。そのため、今後は様々な実寸の食材を含む弁当画像における推定実験および評価を行なう必要がある。

c) 推定モデルや使用特徴量の改善

提案手法では、回帰モデルによる手法においてランダムフォレストを使用した。本手法は正規分布による手法よりも高い推定精度を示したが、これをより向上させるためには、より良い推定モデルを模索する必要がある。また、本研究では食材の大きさを表す値として Feret 径 [9] を採用したが、画像上の食材が他の食材や容器との重なりによって遮蔽されている場合がある。今後は画像における食材の重なりを考慮した食材の大きさの取得方法や、より適確に食材の大きさを表す値を検討する必要がある。

謝辞 本報告の執筆における助言を頂いた名古屋大学高木七海さんに深謝する。本研究の一部は JSPS 科研費 JP20K12038、JP22H00548 の支援による。

文 献

- [1] 株式会社日経ビービーコンサルティング, “健康意識はどう変化し、何が求められているのか,” https://consult.nikkeibp.co.jp/cc1/atc1/20201222_2/, Dec. 2020. [2024/2/13 閲覧]
- [2] 株式会社マイナビマイナビ子育て編集部, “勤務日のランチどうしてる？ お弁当持参派と外食派が拮抗する結果に！お弁当を持っていく頻度が増えた人も多数,” <https://woman.mynavi.jp/kosodate/articles/30724/image/783941>, Oct. 2023. [2024/2/13 閲覧]
- [3] 全国農業協同組合連合会, “現代人のお弁当事情に関するアンケート,” <https://www.zennoh.or.jp/press/release/2022/10/12/アンケート.pdf>, Oct. 2022. [2024/2/13 閲覧]
- [4] Koichi Okamoto and Keiji Yanai, “An Automatic Calorie Estimation System of Food Images on a Smartphone,” Proceedings of the 2nd International Workshop on Multimedia Assisted Dietary Management, pp.63–70, Oct. 2016.
- [5] Xing Lan, Jiayi Lyu, Hanyu Jiang, Kun Dong, Zehai Niu, Yi Zhang, and Jian Xue, “FoodSAM: Any Food Segmentation,” Computing Research Repository arXiv Preprints, arXiv:2308.05938, Aug. 2023.
- [6] Alexander Kirillov, Eric Mintun, Nikhila Ravi, Hanzi Mao, Chloe Rolland, Laura Gustafson, Tete Xiao, Spencer Whitehead, Alexander C. Berg, Wan-Yen Lo, Piotr Dollár, and Ross Girshick, “Segment Anything,” Computing Research Repository arXiv Preprints, arXiv:2304.02643, April 2023.
- [7] 安藤祥和, 會下拓実, 柳井啓司, “深度付き画像と深層学習による食事カロリー量推定システムの開発,” 第 11 回データ工学と情報マネジメントに関するフォーラム, no.F4-5, March 2019.
- [8] 會下拓実, Jaehyeong Cho, 松平礼史, 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 11 回データ工学と情報マネジメントに関するフォーラム, no.F4-4, March 2019.
- [9] Léon-René Feret, “La Grosseur des Grains des Matières Pulvêrulentés,” Premières Communications de la Nouvelle Association Internationale pour l’Essai des Matériaux, Groupe D, pp.428–436, NAIEM, Zurich, Suisse, 1930.
- [10] Leo Breiman, “Random Forests,” Machine Learning, vol.45, no.1, pp.5–32, Jan. 2001.