

主食材の見えの考慮による料理写真の魅力度推定手法の改良

高橋 和馬[†] 道満 恵介^{††,†} 川西 康友[†] 平山 高嗣[†] 井手 一郎[†]

出口 大輔^{†††,†} 村瀬 洋[†]

[†] 名古屋大学 大学院情報科学研究科 〒464-8601 愛知県名古屋市千種区不老町

^{††} 中京大学 工学部 〒470-0393 愛知県豊田市貝津町床立 101

^{†††} 名古屋大学 情報戦略室 〒464-8601 愛知県名古屋市千種区不老町

あらまし 従来研究では、料理を美味しそうに撮影するための支援技術として、料理が美味しそうに見える度合い「魅力度」を推定する手法を提案してきた。この手法では、魅力度付きの料理画像群から画像特徴を抽出し、回帰の枠組みにより任意の料理画像に対して魅力度を推定する。本報告では、主食材の見えを考慮した画像特徴を新たに導入し、従来から提案してきた画像全体の印象を考慮した特徴量と統合利用する方法について検討した結果を述べる。具体的には、皿に占める主食材の割合や重心の座標差、勾配方向ヒストグラム、勾配方向ヒストグラムの第1次～第4次モーメントを利用する。情景写真や動物写真を対象とした一般的な写真の審美性評価手法と比較した結果から、料理の色合いや立体感、食材の向きや配置を考慮する提案手法の有効性を確認した。また、各画像特徴量を単体で利用した手法と比較した結果から、画像特徴量を統合利用することの有効性を確認した。

キーワード 料理写真, 撮影支援, 魅力度, 撮影角度

Improvement of an attractiveness estimation method for food photos considering the appearance of main ingredients

Kazuma TAKAHASHI[†], Keisuke DOMAN^{††,†}, Yasutomo KAWANISHI[†],

Takatsugu HIRAYAMA[†], Ichiro IDE[†], Daisuke DEGUCHI^{†††,†}, and Hiroshi MURASE[†]

[†] Graduate School of Information Science, Nagoya University

Furo-cho, Chikusa-ku, Nagoya-shi, Aichi, 464-8601 Japan

^{††} School of Engineering, Chukyo University

Tokodachi 101, Kaizu-cho, Toyota-shi, Aichi, 470-0393 Japan

^{†††} Information Strategy Office, Nagoya University

Furo-cho, Chikusa-ku, Nagoya-shi, Aichi, 464-8601 Japan

Abstract In our previous research, we proposed a method for estimating the attractiveness of a food photo in order to assist a user to shoot attractive food photos. In this report, the proposed method extracts image features that reflect the appearance of the main ingredient and the impression of photos, and then integrates them by a regression scheme. By this way, the proposed method estimates the attractiveness of an arbitrary food photo.

Experimental results showed that the color distribution of food, three-dimensional appearance of food, and the orientation of its ingredients were effective for attractiveness estimation. Also, we confirmed the effectiveness of integrating image features considering both the impression of photos and the appearance of the main ingredient.

Key words Food photo, shooting support, attractiveness, shooting angle

1. はじめに

料理レシピサイトや SNS の普及により Web 上への料理写真の投稿が増加している。そのような料理写真では料理が美味し

そうに撮影されていることが望ましい。しかし、Web サイトや SNS に投稿される料理写真の多くは非専門家が撮影したものであるため、同一の料理でも美味しそうに見える度合いは様々である。例えば、図 1 は同一の料理を撮影した写真であるが、



(a) 魅力的ではない構図

(b) 魅力的な構図

図 1 個人が撮影した同一の料理を被写体とした写真の例

図 1 (a) よりも図 1 (b) の方が被写体の大きさや明るさ、撮影角度や構図の観点で料理が美味しそうに撮影されている。

一般に、美味しそうに見えるように料理を撮影するのは必ずしも容易ではない。そのため、撮影時に被写体の撮影角度を推薦するシステムや撮影された料理写真群から良いものを判断するシステムがあれば有用だと考えられる。そのようなシステムを実現するためには、まず撮影された料理が美味しそうに見える度合いを定量的に分析する必要がある。本研究では、料理が美味しそうに見える度合いを「魅力度」と定義する。

情景写真や動物写真などを対象とした一般的な写真の審美性評価に関する研究として、被写体を考慮した深層学習手法が提案されている。Tian ら [1] は被写体のクエリごとに深層学習モデルを構築することで、写真の審美性の良し悪しを識別する手法を提案している。しかし、この手法は料理写真を対象としておらず、本研究の目的に対してはそのまま適用できない。一般に、情景写真や動物写真などを対象とした審美性評価に関する手法は、被写体の様子（季節、表情など）を考慮せずに、画像全体の印象を評価する。そのため、料理の見えが重要となる料理写真では、画像全体の印象だけではなく料理の向きや見えの大きさなどを考慮する必要がある。

これに対して我々は、料理の向きを考慮して、画像全体の印象を考慮した特徴量を利用して料理写真の魅力度推定手法を検討してきた [2]。文献 [2] では、料理の色合いや色彩調和、立体感や向きなどの画像から与えられる印象を特徴量に導入した。具体的には、 $L^*a^*b^*$ 色空間の色差、エッジの向きと強度、Deep Convolutional Activation Feature (DeCAF) [3] を利用した。そして、見えが大きく異なる 3 種類の料理と見えの似た 2 種類の料理を対象として、DeCAF を利用した推定器の有効性を確認した。また、見えが似た料理ごとに推定器を構築することの有効性を確認した。しかし、文献 [2] の手法では、主食材の向きや大きさなど、主食材の見えについては考慮していない。料理写真において、主食材の見えが魅力的であることは重要である。本報告では、新たに 5 種類の料理をデータセットに追加し、更に料理の主食材の見えを考慮した特徴量を利用した結果について報告する。主食材の見えを考慮した特徴量として、具体的には主食材の皿に占める面積の割合や皿の重心とずれ、勾配方向ヒストグラムやその第 1 次～第 4 次モーメントを利用する。

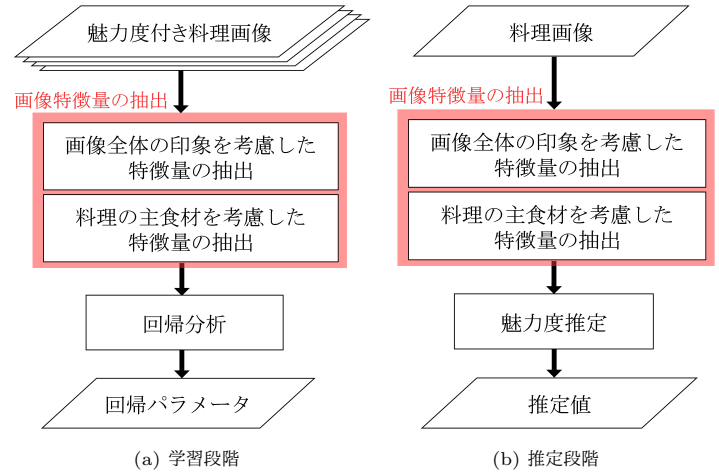


図 2 料理写真の魅力度推定手法の処理手順

以降、2. で料理写真の魅力度を推定する手法と画像特徴の抽出方法について説明する。次に 3. で被験者実験による魅力度の評価値が与えられた料理画像データセットの構築方法について述べ、4. で提案手法の有効性を検証した実験について述べる。最後に 5. で本報告をむすぶ。

2. 料理写真の魅力度推定手法と料理の主食材の見えを考慮した画像特徴の抽出方法

本節では、魅力度推定手法の概要と画像特徴の抽出方法について述べる。

2.1 手法の概要

料理写真は、画像全体の印象だけではなく、主食材の見えが魅力的であることが望ましいと考えられる。そこで提案手法では、画像全体から与えられる印象と料理の主食材の見えを考慮した画像特徴を抽出し、それらを統合して回帰することにより料理写真の魅力度を推定する。魅力度推定手法の処理手順を図 2 に示す。学習段階では、魅力度の評価値が与えられた料理画像群を入力とする。そして、入力画像から画像全体の印象を考慮した画像特徴と料理の主食材を考慮した画像特徴を抽出して回帰パラメータを求めることで、魅力度推定器を構築する。魅力度推定器の学習には Random Regression Forest [4] を用いる。推定段階では、任意の料理画像を入力とする。そして、学習段階で構築した魅力度推定器を用いて、その魅力度を推定する。

2.2 画像特徴の抽出方法

提案手法では、画像全体の印象を考慮した特徴量と料理の主食材の見えを考慮した特徴量を抽出する。以降、各特徴量の抽出方法について詳細に述べる。

2.2.1 特徴量抽出領域

事前処理として、入力された料理画像の皿を含めた前景領域を GrabCut [5] により抽出する。ここで、抽出された皿を含む料理の領域を「料理領域」と定義する。そして、料理領域から画像全体の印象を考慮した特徴量を抽出する。一方、料理の主食材を考慮した特徴量は主食材領域から抽出する。ここで、主



図3 鰻井の写真を入力とした場合の料理領域（黄色）と主食材領域（緑色）

食材を「料理を特徴づける食材群」と定義し、その領域を「主食材領域」と呼ぶ。例として、鰻井を入力画像とした際の料理領域と主食材領域を図3に示す。料理領域を図3(b)の黄色で示し、主食材領域を図3(c)の緑色で示した。本手法では、料理を魅力的に撮影するための支援システムを想定し、主食材領域はインタフェースを通じた利用者の入力により決定されるものとする。また、サラダや炒飯などのように料理を特徴づける食材が料理全体である場合には、料理領域から皿を除いた領域を主食材領域とする。

2.2.2 画像全体の印象を考慮した特徴量の抽出

画像全体の印象を考慮した特徴量として、従来研究[2]で提案した以下のものを利用する。これらは、料理領域から抽出する。

L*a*b*色空間の色差：料理領域全体から最頻出色 $G = (L, a, b)$ を計算する。次に、図4(a)に示すような放射状の局所領域100個から各最頻出色 $R_i = (\tilde{L}_i, \tilde{a}_i, \tilde{b}_i)$ およびその出現数 F_{R_i} を計算する。ここで、 i は局所領域の番号を表し、 $i \in \{1, \dots, 100\}$ である。そして、 G と R_i の色差 D_i に F_{R_i} を乗じることで100次元ベクトルの特徴量 D とした。

$$D_i = F_{R_i} \sqrt{(L - \tilde{L}_i)^2 + (a - \tilde{a}_i)^2 + (b - \tilde{b}_i)^2} \quad (1)$$

$$D = (D_1, D_2, \dots, D_{100}) \quad (2)$$

エッジの向きと強度：図4(b)に示すような10×10の局所領域に入力画像を分割する。そして、各領域の最大エッジ強度 e_j とその勾配方向 n_j を乗じることで100次元ベクトルの特徴量 M とした。ここで、 j は局所領域の番号を表し、 $j \in \{1, \dots, 100\}$ である。

$$M_j = e_j n_j \quad (3)$$

$$M = (M_1, M_2, \dots, M_{100}) \quad (4)$$

DeCAF：DeCAFは、ImageNetの1,000カテゴリが学習されたネットワークの重みデータであり、8層のニューラルネットワークからなる。5層までが畳み込み層（convolution layer）であり、残りの3層が全結合層（fully-connected layer）である。文献[3]を参考にして、ニューラルネットワークの7層目である全結合層の出力結果を[0,1]に正規化して特徴量とする。得られる特徴量は、4,096次元のベクトルである。

2.2.3 料理の主食材の見えを考慮した特徴量の抽出方法

本報告では、2.2.2で導入した特徴量に加えて、主食材の見えの大きさや配置、向きや形状を考慮するために、料理の主食材から画像特徴量を抽出する方法を提案する。料理認識の手法において、食材の関係性や食材の画像を学習することで、料理




図4 特徴量の抽出領域

図4 特徴量の抽出領域

の認識精度が向上することが報告されている[6],[7]。そのため、食材を考慮した画像特徴を魅力度推定に利用することは有用であると考えられる。そこで、本手法にも主食材の配置や向きを捉えるための特徴量を検討した。具体的には、主食材領域から以下の特徴量を抽出する。

料理領域中に占める主食材領域の割合：料理を魅力的に撮影するための構図を決定するためには、主食材の見えの大きさを考慮することが有効であると考えられる。そのため、料理領域 R に占める主食材領域 \tilde{R} の割合 $P_{\tilde{R}}$ を画像特徴として導入する。

$$P_{\tilde{R}} = \frac{\tilde{R}}{R} \quad (5)$$

料理領域の重心と主食材領域の重心のずれ：料理を魅力的に撮影するための構図を決定するためには、主食材の配置を考慮することが有効であると考えられる。そのため、料理領域の重心 $G(x, y)$ と主食材領域の重心 $\tilde{G}(\tilde{x}, \tilde{y})$ の x 座標と y 座標の差 Δx と Δy を画像特徴として導入する。

$$\Delta x = \tilde{x} - x \quad (6)$$

$$\Delta y = \tilde{y} - y \quad (7)$$

勾配方向ヒストグラム：主食材の向きを考慮するために、画像の輝度勾配をヒストグラムとした勾配方向ヒストグラムを画像特徴として導入する。まず、主食材領域の座標 (x, y) における勾配強度 $m(x, y)$ と勾配方向 $\theta(x, y)$ を次式により計算する。

$$m(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (8)$$

$$\theta(x, y) = \tan^{-1} \frac{f_x(x, y)}{f_y(x, y)} \quad (9)$$

ここで、 f_x は x 方向の微分画像、 f_y は y 方向の微分画像である。次に、主食材領域に対して勾配方向ヒストグラムを計算する。勾配方向ヒストグラムの各ビンには、勾配方向0度から360度を10度刻みに分割する。また、各ビンの値は勾配強度を加算した値の総和とする。そして、ヒストグラムの各ビンの値を基に下記の36次元ベクトル H を作成し、特徴量とする。

$$H = (H_1, H_2, \dots, H_{36}) \quad (10)$$

勾配方向ヒストグラムの第1次～第4次モーメント：主食材の向きや形状を考慮するために、前述した勾配方向ヒストグラムの第1次～第4次モーメントである平均、分散、歪度、尖度を画像特徴として導入する。勾配方向ヒストグラムの全てのビ

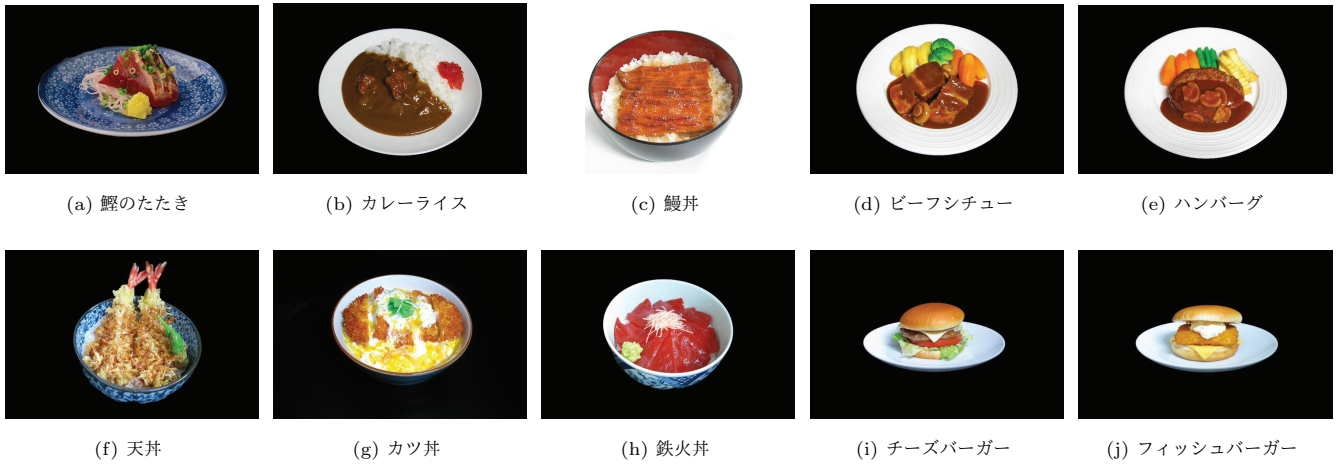


図5 データセットに含まれる各料理

ンに対して、平均、分散、歪度、尖度を計算する。

3. 魅力度付き料理画像データセットの構築方法

本節では、実験用データセットの構築方法について述べる。提案手法では、料理写真の魅力度を回帰の枠組みで分析する。そのため、回帰の目標値となる個々の料理画像に対する魅力度を求めるために Thurstone の一対比較法 [8] を用いた。以降、データセットの構築方法について述べる。

3.1 対象料理

文献 [2] で対象とした鯉のたたき、カレーライス、鰻丼、ビーフシチュー、ハンバーグに加えて、新たに5種類の料理をデータセットに追加した。データセットに含まれる計10種類の料理を図5に示す。見えや立体感が大きく異なる丼もの料理として「天丼」、「カツ丼」、「鉄火丼」の3種類と、立体感のある料理として「チーズバーガー」と「フィッシュバーガー」の2種類を選択した。本実験では、撮影の利便性と再現性の点から、時間経過に伴う状態の変化や盛り付けの変化が生じない食品サンプル^(注1)を用いた。

3.2 撮影方法

料理写真の魅力度を定量化するため、仰角と回転角を変えて36方向から被写体を撮影した。皿と撮影時の背景を各撮影角度で統一し、皿や料理の背景など撮影角度以外の要素を排除した。なお、仰角は撮影装置の回転皿と同じ平面を仰角0度とし、その面を基準に30、60、90度を撮影範囲とした。回転角は料理のある方向を基準として定め、その方向から右回りに30度刻みに330度までを撮影範囲とした。

3.3 Thurstone の一対比較法による魅力度の算出

魅力度の目標値を設定するために、データセット内の各料理に対して Thurstone の一対比較法 [8] を適用した。新たに追加した5種類の料理カテゴリに付与された魅力度とその画像の抜粋を図6に示す。各料理につき9名の被験者から2,015回の対比較結果を得た。なお、被験者は20代の男女延べ28名であっ

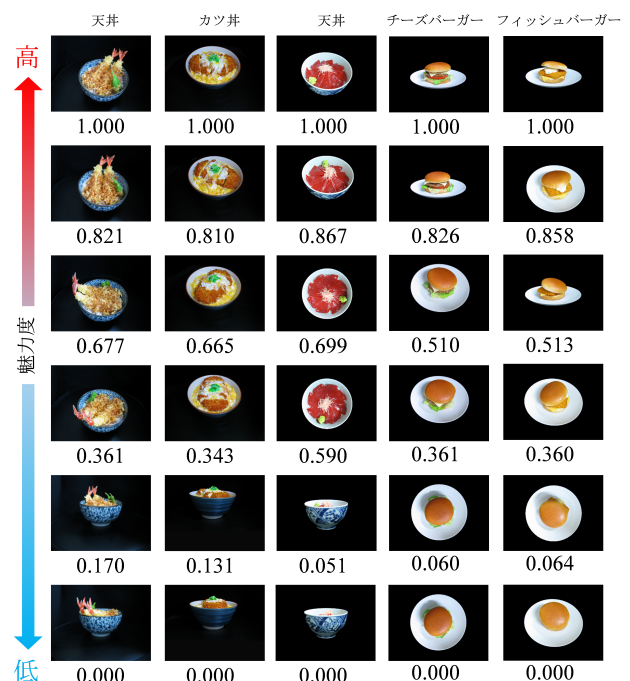


図6 付与された魅力度とその画像(抜粋)

た。そして、得られた対比較結果に対して、間隔尺度値を求めた。最後に、間隔尺度値を [0,1] に正規化し、その値を被験者実験により算出した料理画像の魅力度とした。魅力度が1に近いほど相対的に評価が高い画像である。この処理を各料理に適用した。

4. 評価実験

本節では、実験により料理の色合いや立体感、食材の向きや配置を考慮した提案手法の有効性について評価した結果について述べる。実験1では、情景写真や動物写真を対象とした一般的な写真に対する審美性評価の手法 [1] と比較した。実験2では、各画像特徴量単体を利用した手法と比較し、画像特徴を統合利用することの有効性を評価した。

(注1)：撮影に使用した食品サンプルは全て、(株) まいづる製である。食品サンプル専門店まいづる，“食品サンプル専門店 maiduru pro,” <http://www.maiduru.biz/> [2017/2/13 参照].

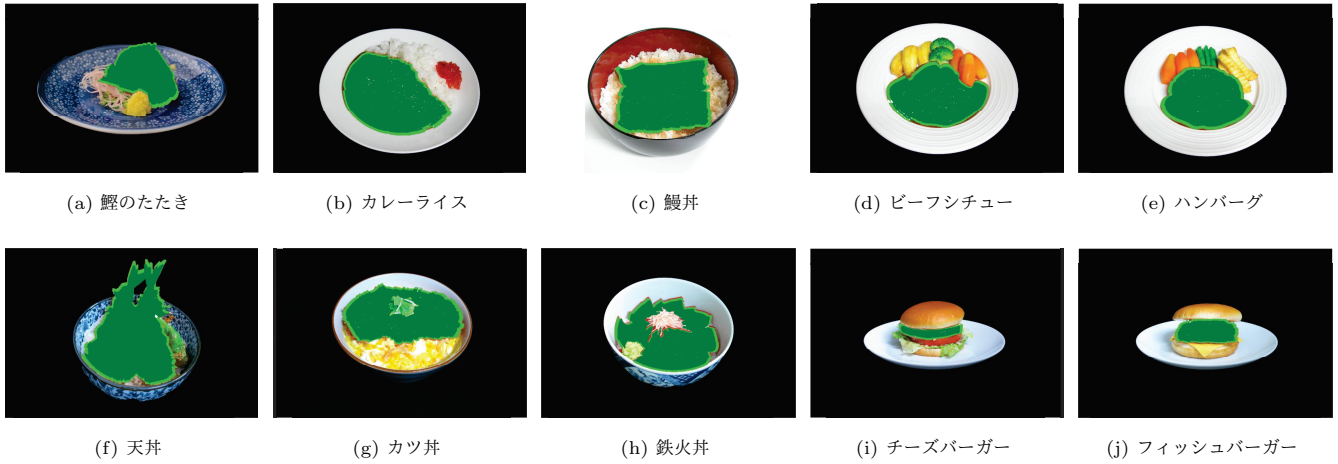


図 7 各料理の主食材領域

4.1 実験 1: 一般的な写真に対する審美性評価手法との比較
 3. で紹介したデータセットを用いて, 各料理について学習した推定器により提案手法を評価した. 以降, 実験の詳細および結果について述べる.

4.1.1 実験条件

$L^*a^*b^*$ 色空間の色差の明度 L^* , 色度 a^* , 色度 b^* は各々 8 段階に量子化し, 最大エッジ強度の勾配方向は 36 段階に離散化した. また, DeCAF の抽出には Caffe ライブラリ [9] を利用した. 料理の主食材およびその領域は, 図 7 に示すように決定した. 各料理画像中に示した緑色の領域が主食材領域である.

比較手法には, Tian らが提案したクエリごとに深層学習モデルを構築する一般的な写真に対する審美性評価手法 [1] を用いた. 文献 [1] は, 情景写真や動物写真などを対象とした一般的な写真に対して審美性の高低を判定する手法である.

推定器の構築および評価は, 各料理について学習した推定器を用いた leave-one-out 法によった. Random Regression Forest の学習には, scikit-learn [10] の RandomForestRegressor を利用し, パラメータは `random_state = 2`, `n_estimators = 150` とした. 事前処理として特徴量の各次元を $[0, 1]$ に正規化した. 評価指標は, Thurstone の一対比較法により算出したデータセット中の画像の魅力度と, 各手法により推定された魅力度の平均絶対誤差 (MAE: Mean Absolute Error) とした.

4.1.2 実験結果

提案手法の有効性を評価した結果を表 1 に示す. 全ての料理において, 一般的な写真に対する審美性評価手法の推定誤差よりも提案手法の推定誤差が小さかった. このことから, 全ての料理に対して, 料理の色合いや立体感, 食材の向きや配置を考慮した提案手法の有効性を確認した.

4.2 実験 2: 各画像特徴単体を利用した手法との比較

3. で紹介したデータセットを用いて, 各料理について推定器を構築する. 画像特徴を統合利用することの有効性を確認するために, 各画像特徴単体を利用して魅力度推定器を学習する手法と比較した.

4.2.1 実験条件

4.1.1 同様に, 推定器の構築は各料理について学習した推定

表 1 一般的な写真の審美性評価手法と提案手法による魅力度の推定誤差 (表中の数値は MAE $[0, 1]$ を示し, 太文字は各料理において推定誤差が小さい値を示す)

料理名	手法	
	比較 (Tian ら [1])	提案
鰹のたたき	0.330	0.133
カレーライス	0.214	0.108
鰻丼	0.383	0.077
ビーフシチュー	0.349	0.085
ハンバーグ	0.258	0.096
天丼	0.405	0.124
カツ丼	0.326	0.100
鉄火丼	0.297	0.053
チーズバーガー	0.438	0.065
フィッシュバーガー	0.441	0.071
平均	0.344	0.091

器を用いる leave-one-out 法を用いた. 評価指標は, 各料理の推定誤差を MAE で評価した.

4.2.2 実験結果

画像特徴を統合利用する提案手法と各画像特徴単体を利用する比較手法を評価した結果を表 2 に示す. 表中の太字の数字は, 各料理における魅力度の推定誤差 (MAE) の最小値である. 提案手法の推定誤差の平均が 0.091 となり最小であった. このことから, 画像特徴を統合利用して推定器を学習する提案手法の有効性が確認できた. 各画像特徴単体を利用して推定器を学習する手法の中では, DeCAF のみを利用した手法の推定誤差が 0.093 となり最小であった. DeCAF の次に小さな推定誤差 0.109 となったのは, 主食材領域の勾配方向ヒストグラムのみを利用した手法で推定した結果であった.

4.3 考察

各料理における推定誤差の結果から, 料理によって魅力度推定に有効な特徴量は異なることがわかる. そのような場合, 料理によって推定器を切り替える必要がある. 推定器を切り替える方法については, 料理認識を用いて料理ごとに切り替える方法や, 見えが似た料理ごとに切り替える方法が考えられる. 料

表2 各手法を利用した推定器による推定誤差（表中の数値は MAE [0, 1] を示し、太文字は各料理において推定誤差が最小となった値を示す）

料理名	手法（特徴量）							統合利用 （提案）
	画像全体の印象を考慮した特徴量			料理の主食材を考慮した特徴量				
	色	形状	DeCAF	領域の割合	重心	方向 ヒストグラム	モーメント	
鰹のたたき	0.279	0.208	0.123	0.192	0.256	0.139	0.144	0.133
カレーライス	0.209	0.117	0.122	0.165	0.127	0.126	0.095	0.113
鰻丼	0.180	0.069	0.061	0.088	0.136	0.112	0.087	0.067
ビーフシチュー	0.193	0.154	0.084	0.195	0.138	0.139	0.166	0.085
ハンバーグ	0.246	0.158	0.097	0.186	0.137	0.162	0.130	0.096
天丼	0.242	0.235	0.127	0.183	0.138	0.103	0.101	0.124
カツ丼	0.260	0.114	0.094	0.160	0.112	0.095	0.128	0.100
鉄火丼	0.233	0.059	0.055	0.038	0.065	0.038	0.038	0.053
チーズバーガー	0.203	0.068	0.065	0.095	0.116	0.117	0.115	0.065
フィッシュバーガー	0.292	0.200	0.104	0.099	0.189	0.063	0.106	0.071
平均	0.233	0.138	0.093	0.140	0.141	0.109	0.111	0.091

理認識を用いて料理ごとに推定器を切り替える方法では、認識対象とする料理ごとに推定器を用意すればよい。しかし、料理認識で学習されていないデータに対しては対応できない。また、同一の料理であっても使用する食材やトッピング、盛り付け方法により見えが大きく異なり、認識精度が低くなることもある。Yanai らの報告 [11] によると、256 種類の料理カテゴリ (UEC-FOOD256 [12]) において、平均認識率 67.6% を達成している。しかし、料理の種類は膨大であるため、256 種類の推定器を用意するだけでは不十分である。そのため、色合いや立体感など料理の見えを基準に推定器を切り替える方法が現実的であると考えられる。

5. まとめ

料理を美味しく撮影するための支援を目的とし、料理写真の魅力度を推定する手法を提案した。36 方向から撮影した 10 種類の料理画像群を基に魅力度付き料理画像データセットを構築し、提案手法を評価した。評価実験により、料理の色合いや立体感、食材の向きや配置を考慮した提案手法の有効性を確認した。また、画像特徴量を統合利用することの有効性も確認した。しかし、料理によって有効な特徴量は異なるため、料理によって推定器を切り替える必要性が示唆された。

今後は、推定器の切り替え方法およびその評価について検討していく。さらに、照明による色合いや明るさの違い、被写体の見え大きさや背景のぼけ具合など魅力度に影響する撮影角度以外の要因の考慮、撮影支援システムへの応用についても検討していく。

謝辞 本研究の一部は、科研費および MSR-CORE12 による。被験者実験に協力して頂いた方々に感謝する。

文 献

- [1] X. Tian, Z. Dong, K. Yang, and T. Mei, "Query-dependent aesthetic model with deep learning for photo quality assessment," *IEEE Trans. on Multimedia*, vol. 17, no. 11, pp. 2035–2048, Oct. 2015.
- [2] 高橋 和馬, 道満 恵介, 川西 康友, 平山 高嗣, 井手 一郎, 出口

- 大輔, 村瀬 洋, "料理写真の魅力度推定に用いる特徴量の検討による精度向上," *信学技報*, MVE2016-12, Oct. 2016.
- [3] J. Donahue, Y. Jia, O. Vinyals, J. Hoffman, N. Zhang, E. Tzeng, and T. Darrell, "DeCAF: A deep convolutional activation feature for generic visual recognition," *Proc. 31st Int. Conf. on Machine Learning*, pp.647–655, June 2014.
- [4] A. Liaw and M. Wiener, "Classification and regression by Random Forest," *R News*, vol. 2, no. 3, pp. 18–20, Dec. 2002.
- [5] C. Rother, V. Kolmogorov, and A. Blake, "GrabCut: Interactive foreground extraction using iterated graph cuts," *ACM Trans. on Graphics*, vol.23, no.3, pp.309–314, Aug. 2004.
- [6] J. Chen and C.W. Ngo, "Deep-based ingredient recognition for cooking recipe retrieval," *Proc. 24th ACM Multimedia Conf.*, pp. 32–41, Oct. 2016.
- [7] H. Wu, M. Merler, R. Uceda-Sosa, and J. R. Smith, "Learning to make better mistakes: Semantics-aware visual food recognition," *Proc. 24th ACM Multimedia Conf.*, pp. 172–176, Oct. 2016.
- [8] L.L. Thurstone, "Psychophysical analysis," *American J. of Psychology*, vol.38, no.3, pp.368–389, July 1927.
- [9] Y. Jia and L. Developer, "Caffe," <http://caffe.berkeleyvision.org/> [2017/2/7 参照].
- [10] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, "Scikit-learn Machine learning in Python," *J. of Machine Learning Research*, vol. 12, pp. 2825–2830, Oct. 2011.
- [11] K. Yanai and Y. Kawano, "Food image recognition using deep convolutional network with pre-training and fine-tuning," *Proc. 2015 IEEE Int. Conf. on Multimedia and Expo*, 6p., June 2015.
- [12] Y. Kawano and K. Yanai, "Automatic expansion of a food image dataset leveraging existing categories with domain adaptation," *Proc. 2014 European Conf. on Computer Vision*, pp. 3–17, Sept. 2014.