

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

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。魅力度推定手法では、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未知の料理画像に対して魅力度を推定する。本報告では、魅力度推定手法で抽出する画像特徴について検討した結果と、手法の汎化性能について検証した結果を述べる。画像特徴の検討では、抽出範囲を改良した色特徴と形状特徴、畳込みニューラルネットワーク (CNN) から得られる特徴量である Deep Convolutional Activation Feature (DeCAF) を利用した。また、各料理の魅力度推定器を異なる料理カテゴリで評価することで、手法の汎化性能を検証した。検証結果より、見えが似た料理で学習した推定器の精度が高いことが確認され、料理の見えに基づいて推定器を切り替え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

Accuracy improvement of food photo attractiveness estimation based on consideration of image features

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 predicting the attractiveness of a food photo in order to assist a user to shoot attractive food photos. In this report, we consider applying different image features; 1) Deep Convolutional Activation Feature (DeCAF) extracted from a convolutional Neural Network, and 2) improvement of the extraction region for color and shape features. We also investigated the capability of the proposed method in estimating attractiveness within untrained food categories. Experimental results show that the accuracy of the attractiveness estimation was improved by training with food samples that looked similar to the testing one, which suggested the importance of an adaptive estimator selection based on food appearance.

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、図 1 (a)



(a) 魅力的でない構図

(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

よりも図1 (b)の方が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である。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。

一般的な写真の審美性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ニューラルネットワークのモデルを構築し、写真の審美性が高いか低いかの2クラス分類に適した手法を提案している。しかしこの手法では、2クラス分類にしか適応できず、審美性が高い(低い)写真同士の優劣を付けることはできない。なお、この研究は料理写真を対象としておらず、全体的な雰囲気よりも被写体の見かけを重要視する。一般的な写真と料理写真では性質が異なるため、この手法を料理写真に対して単純に適用することはできない。

料理写真を対象とした研究として、料理を魅力的な構図で撮影するための支援手法が提案されている。Charlesら[2]は料理には最も美味しそうに見える向きがあると報告しており、撮影時に料理の回転方向を考慮することが重要であると考えられる。柿森ら[3]は皿の配置を指定することで、美味しそうな構図決定を支援するシステムを考案した。しかし、このシステムでは各料理の回転方向が考慮されていない。

これに対して我々は、料理の向きを考慮して、画像特徴から料理写真の魅力度を推定する手法を検討してきた[4]。文献[4]では、見えが大きく異なる3種類の料理を対象として、魅力度を推定した。そして、料理の種類によって有効な特徴量は異なることが示され、料理ごとに推定器を切り替えることを考察した。しかし、料理の種類は膨大であるため、料理ごとに推定器を構築するのは現実的ではない。そのため、似た見えの料理ごとに推定器を構築するなどして、構築する推定器の数を削減する必要がある。本報告では、似た見えの料理をデータセットに追加し、手法の汎化性能を評価する。それと同時に、抽出

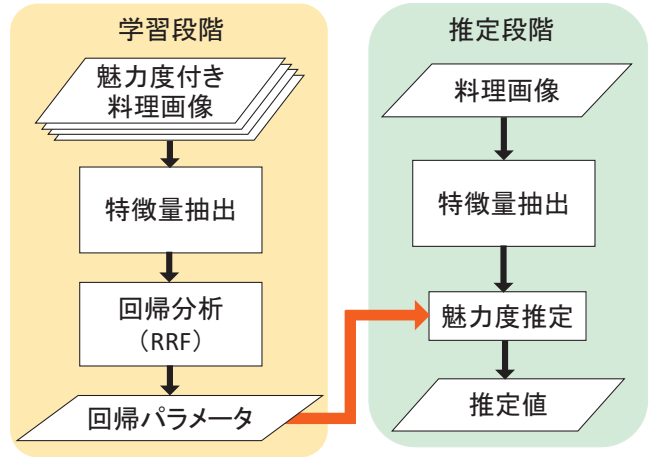


図2 料理写真の魅力度推定手法の処理手順

範囲を改良した色特徴・形状特徴と、CNNから得られる特徴量であるDeCAF[5]を利用した結果について述べる。その際に、有効な特徴量を分析するために、回帰の枠組みにRandom Regression Forest[6]を用いた。

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画像特徴の抽出方法

提案手法は、料理写真から抽出した画像特徴の回帰分析を用いて、そ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から画像特徴を抽出し、魅力度推定器を構築する。推定段階では、構築した魅力度推定器を用いて、魅力度が未知の入力された料理画像に対して魅力度を推定する。以降、各段階の処理について詳述する。

2.1 学習段階：魅力度推定器の構築

図2の左側に示すような処理手順により、魅力度推定器を構築する。まず、予め魅力度の評価値が与えられた料理画像を入力画像とする。次に、入力された料理画像の皿を含めた前景領域をGrabCut[7]により抽出する。GrabCutは、前景として抽出したい領域を矩形で囲むことにより背景と前景を分離することができる。そして、抽出された領域から画像特徴を抽出する。最後に、Random Regression Forest[6]を料理写真の魅力度推定器とする。

2.1.1 色特徴量の抽出

一般的な写真の審美性を判定する際に、色彩調和が有効であるという知見[8]から、皿や副菜との色の調和や食材の色合いを考慮することが重要であると考えられる。そのため、色特徴として、 $L^*a^*b^*$ 色空間における色差の分布の利用を検討した。

具体的には、まず料理領域から $L^*a^*b^*$ の3次元ヒストグラムを作成し、最頻出の色 $G = (L, a, b)$ を計算する。ここで、次元




図3 特徴量の抽出範囲

削減のために $L \times a \times b$ の各成分を 0 から 7 の 8 段階に量子化する。次に、入力画像を図 3(a) に示すような放射状の 100 個の局所領域に分割する。従来研究 [4] では、局所領域をグリッド上に分割していた。本報告では、皿の形状を考慮した食材の色配置を特徴量に導入するために放射状に分割する。そして、各局所領域から最頻出の色 $R_i = (\tilde{L}_i, \tilde{a}_i, \tilde{b}_i)$ 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、 $i \in \{1, \dots, 100\}$ 、 $\tilde{L}_i \in \{0, \dots, 7\}$ 、 $\tilde{a}_i \in \{0, \dots, 7\}$ 、 $\tilde{b}_i \in \{0, \dots, 7\}$ である。そして、 G と L_i の色差 D_i を次式で計算する。

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

本手法では、計算した色差に F_{R_i} を乗じることで重み付けする。各色差 D_i を基に下記の 100 次元のベクトル D を作成し、色特徴量とする。

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

2.1.2 形状特徴量の抽出

魅力的な料理写真の撮影には、盛り付けや料理の向きが重要であるという知見 [2] から、料理の立体感や向き、見えの複雑さを考慮することが重要であると考えられる。そのため、形状特徴として、エッジの向きや強度の利用を検討した。

具体的には、まず入力画像を図 3(b) に示すような 10×10 の局所領域に分割し、各領域の最大エッジ強度 e_i とその勾配方向 n_i を乗じることで重み付けする。ここで、 i は局所領域の番号を表し、 $i \in \{1, \dots, 100\}$ である。従来研究 [4] では、画像全体から抽出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、尖度を形状特徴として利用していた。本報告では、勾配方向の画像上の位置を特徴量として導入するために、格子状に局所領域を分割した。また、勾配方向を計算する際に、皿を含めた料理領域から 5 画素内側の領域に対して処理する。これは、皿の縁に現れるエッジの影響を軽減するためである。そして、下記の 100 次元のベクトル M を作成し、形状特徴とする。

$$M_i = e_i n_i \quad (3)$$

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

2.1.3 Deep Convolutional Activation Feature (DeCAF) の抽出

物体認識のための大規模なデータセットで学習した Deep Convolutional Neural Network (DCNN) の活性化信号を画

像特徴として利用することが広く行われており、提案手法でも画像特徴として導入した。DeCAF [5] は、ImageNet [9] 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。本報告では、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正規化して特徴量として利用する。得られる特徴量は、4,096 次元のベクトルである。

2.1.4 魅力度推定器の学習

提案手法では、2.1.1～2.1.3 で述べた特徴量および予め付与された魅力度の評価値を用いた回帰により、魅力度推定器を構築する。すなわち、目的変数を 3. で述べる被験者実験により得る魅力度とし、説明変数を 2.1.1～2.1.3 で述べた特徴量として回帰モデルを学習する。魅力度推定器の学習には Random Regression Forest [6] を用いる。

2.2 推定段階：魅力度の推定

図 2 の右側に示すような処理手順で、料理写真の魅力度を推定する。まず、入力された料理画像に GrabCut [7] を適用し、皿を含む料理のみの領域を抽出する。そして、抽出された領域から 2.1.1～2.1.3 で述べた画像特徴を抽出し、魅力度推定器を用いて魅力度を算出する。

3. 魅力度付き料理画像データセットの構築

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の魅力度を求めるために Thurstone の一対比較法 [10] を用いる。以降、データセット構築方法の詳細について述べる。

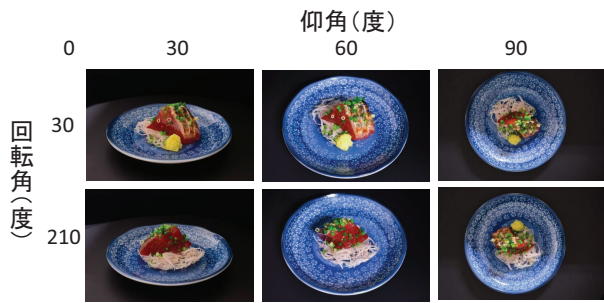
3.1 対象料理

魅力度の推定対象として見た目が大きく異なる「鰹のたたき」、「カレー」、「鰻丼」の 3 種類と、見た目が似ている「ビーフシチュー」、「ハンバーグ」の 2 種類を選んだ。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。

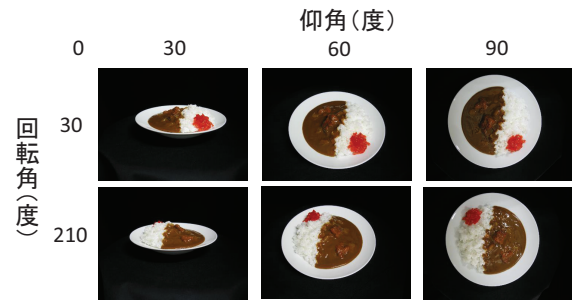
3.2 撮影方法

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。データセットの一部を図 4 に示す。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、仰角と回転角の始点と間隔は次のように設定した。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、料理のある面を基準として、その面から右回りに 30 度刻みに 330 度までを撮影範囲とした。


(注1)：撮影に使用した食品サンプルは、(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/> [2016/8/29/参照]。




(a) 鯉のたたき



(b) カレー



(c) 鰻丼




(d) ビーフシチュー



(e) ハンバーグ

図 4 データセット中の画像例




(a) 鯉のたたき




(b) カレー



(c) 鰻丼



(d) ビーフシチュー



(e) ハンバーグ

図 5 各データセットにおける魅力度が最も高い画像（左）と最も魅力度が低い画像（右）：魅力度（仰角，回転角）

3.3 Thurstone の一対比較法による魅力度の算出

料理写真の目標値を設定するため，データセット内の各料理に対して Thurstone の一対比較法 [10] を適用した．Thurstone の一対比較法は官能検査の 1 つであり，対比較結果に基づいて複数の試料の感覚値を間隔尺度化するものである．具体的にはまず，各料理画像ごと 36 枚から異なる 2 枚の組み合わせ ${}_{36}C_2 = 630$ 通りを求める．次に，全ての組み合わせに対して各々 3 人以上の被験者から回答が得られるように実験を行った．その

表 1 各料理カテゴリ内で学習した推定器による推定誤差

手法 (特徴量)	平均絶対誤差 (MAE)					
	鰹のたたき	カレー	鰻丼	ビーフシチュー	ハンバーグ	平均
比較 1 (色のみ)	0.28	0.21	0.18	0.19	0.25	0.22
比較 2 (形状のみ)	0.21	0.12	0.069	0.15	0.16	0.14
提案 (色+形状)	0.22	0.12	0.076	0.15	0.15	0.14

表 2 DeCAF を利用した推定器および DeCAF と色特徴・形状特徴を統合利用した推定器による推定誤差

手法 (特徴量)	平均絶対誤差 (MAE)					
	鰹のたたき	カレー	鰻丼	ビーフシチュー	ハンバーグ	平均
DeCAF のみ	0.12	0.12	0.061	0.084	0.097	0.097
DeCAF+色+形状	0.12	0.12	0.069	0.085	0.096	0.098

際、被験者は「美味しそうに見える方はどちらか」という設問に対して、「左」または「右」を回答し、判断が付かない場合には「分からない」を回答する。その結果、20代の男女20名から料理ごとに2,015回の対比較結果を得た。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、最小値が0、最大値が1となるように値を[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。

実験により得た各料理における魅力度の最も高い画像と魅力度の最も低い画像を図5に示す。鰹のたたきは、焼き目や生姜が手前に見える構図の魅力度が高かった。カレーは、福神漬が奥に見える構図の魅力度が高かった。鰻丼は、仰角60度から撮影され、鰻の向きが垂直でない構図の魅力度が高かった。ビーフシチューとハンバーグは、肉が手前に見える構図の魅力度が高く、全体的に撮影構図とその魅力度が似ていた。このことから、料理の見えの類似度と撮影構図の魅力度には正の相関があると考えられる。魅力度が低い画像では、5種類の料理に共通して、料理全体やメインの食材が見えている部分が少ない構図や立体感がない構図が多く見られた。

4. 評価実験

本節では、評価実験により色特徴および形状特徴を統合利用した結果とDeCAFを利用した結果について述べ、魅力度推定に有効な画像特徴を比較する。また実験1で得られた結果より、有効な画像特徴を利用した魅力度推定器の汎化性能を評価した結果を述べる。

4.1 実験1：画像特徴の比較

3.で紹介したデータセットを用いて、各料理カテゴリ内で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

$L^*a^*b^*$ 色空間の明度 L^* 、色度 a^* 、色度 b^* は8分割に量子化し、勾配方向は36分割に量子化した。色特徴のみを使用する手法と形状特徴のみを使用する手法を比較することで、色特徴と形状特徴を組み合わせることの有効性を評価した。また、DeCAFを利用した結果とも比較した。本報告では、ライブラリにCaffe[11]を利用してDeCAFを抽出した。推定器の構築および評価は、データセット内の各料理カテゴリ内で学習した推定器を

用いたleave-one-out法によった。Random Regression Forestの学習には、scikit-learn[12]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平均0,分散1に正規化した。評価指標は、Thurstoneの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

色特徴と形状特徴を統合利用することの有効性を評価した結果を表1に示す。表1より、ハンバーグにおいては提案手法の有効性が確認できた。しかし、鰹のたたきと鰻丼では形状特徴のみを利用した推定器が有効であり、料理によって推定器を切り替える必要があると考えられる。

次に、DeCAFを利用した推定器の結果とDeCAFと色特徴、形状特徴を統合利用した推定器の結果を表2に示す。表2のDeCAFのみの推定誤差と表1の推定誤差を比較した場合、カレー以外の料理においてDeCAFのみの推定誤差が最小であった。また、DeCAFと色特徴、形状特徴を統合利用した推定器の推定誤差と表1の推定誤差を比較した場合、カレー以外の料理において推定精度が向上した。しかし、DeCAFのみを利用した推定器と比較した場合、ハンバーグ以外の料理において精度向上は確認できなかった。このことから、画像特徴としてDeCAFを利用することが有効であると考えられる。

4.1.3 考察

DeCAFと色特徴、形状特徴を統合利用した推定器とDeCAFのみを利用した推定器の推定誤差を比較した場合、カレーとハンバーグについては推定精度が向上したが、その他の料理については推定誤差が大きくなった。このことから、DeCAFが色と形状の特徴を包含していると考えられる。現状では、DeCAFのみを利用して推定器を構築することが有効であるが、他の特徴量との組み合わせも検討の余地がある。検討する特徴量の方針については、4.2.3の考察で述べる。

4.2 実験2：DeCAFを利用した魅力度推定器の汎化性能評価

3.で紹介したデータセットを用いて、各料理カテゴリ内で推定器を構築する。そして、異なる料理カテゴリの魅力度を推定することにより提案手法の汎用性を評価した。

表3 混合行列 (列: 推定器を構築するために学習した料理, 行: 評価した料理)

推定器 (料理名)	平均絶対誤差 (MAE)				
	鰹のたたき	カレー	鰻井	ビーフシチュー	ハンバーグ
鰹のたたき	0.12	0.23	0.28	0.26	0.30
カレー	0.32	0.12	0.31	0.20	0.21
鰻井	0.34	0.20	0.061	0.27	0.28
ビーフシチュー	0.26	0.20	0.30	0.084	0.17
ハンバーグ	0.26	0.18	0.33	0.16	0.097

4.2.1 実験条件

4.1.1 同様に, 推定器の構築は, データセット内の各料理カテゴリ内で学習した. 評価には, 学習した推定器の料理と異なるカテゴリの料理画像を入力とした. そして, 各料理の推定誤差を MAE で評価した.

4.2.2 実験結果

各料理の推定器に対して, 異なる料理カテゴリの魅力度を推定した結果を表3に示す. 表3の混合行列より, 最小の推定誤差0.16は, ビーフシチューで学習してハンバーグで評価した結果だった. また2番目に小さな推定誤差0.17は, ハンバーグで学習してビーフシチューで評価した結果だった. このことから, 見えが似ている料理ごとに推定器を構築することの有効性を確認できた. しかし, ほとんどの料理カテゴリ間で推定誤差が0.20を超えることから, 依然として推定誤差は大きいといえる.

4.2.3 考察

DeCAFを利用した魅力度推定器の料理カテゴリ間における汎化性能を示すことができなかった. この結果からも, 料理の見えや料理名などによって推定器を切り替える必要性を確認した. 今後は, 単に料理の見えが似ているということだけでなく, その料理に含まれる食材を考慮した画像特徴の抽出や推定器の切り替えについて検討する. DeCAFや本報告で提案した色特徴と形状特徴は, 一般的な色や形状の配置やパターンについては考慮されているが, 主要な食材や添え物の向きや色合いは考慮していない. 炒飯などの食材が混ざり合っている料理については, 食材の考慮は重要でないと考えられる. しかし, データセットのような一品料理において, 主要な食材と添え物の配置や向き・色合いを考慮することは重要であると考えられる. また, 主要な食材を判断することにより, 推定器切り替えの判断基準となると考えられる. そのため, 食材を考慮した魅力度推定を導入していく枠組みを模索する.

5. まとめ

料理を美味しそうに撮影する際の支援技術を目的とし, 料理写真の魅力度を推定する手法に有効な画像特徴について検討した. 様々な角度から撮影した5種類の料理画像群を基にデータセットを構築し, 各料理カテゴリ内で学習した推定器により提案手法を評価した. 評価実験により, 画像特徴にDeCAFを利用した推定器の方が, 色と形状特徴を統合利用した推定器よりも高精度な推定が可能であることを確認した. 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, 全料理に共通して汎用性のある推定器を構築することはできず, 今後も料理の見えや主要な食材を考慮して推定器を切り替える必要がある.

今後は, 主要な食材や食材間の配置を考慮して魅力度を推定する方法を検討する. さらに, 料理と皿の色彩調和の考慮や被写体の大きさなど撮影角度以外の魅力度に影響する要因の考慮, 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, MSR-CORE12による.

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] C. Michel, A.T. Woods, M. Neuhauser, A. Landgraf, and C. Spence, "Rotating plates: Online study demonstrates the importance of orientation in the plating of food," Food Quality and Preference, vol.44, pp.194–202, Sept. 2015.
- [3] T. Kakimori, M. Okabe, K. Yanai, and R. Onai, "A system to support the amateurs to take a delicious-looking picture of foods," Proc. SIGGRAPH ASIA Symposium on Mobile Graphics and Interactive Applications, no. 28, Nov. 2015.
- [4] 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, "料理写真における構図の魅力度推定へ向けた検討," 信学技報, MVE2015-23, Oct. 2015.
- [5] 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. Con. on Machine Learning, pp.647–655, June 2014.
- [6] L. Andy and M. Wiener, "Classification and regression by Random Forest," R news, vol. 2, no. 3, pp. 18–20, Dec. 2002.
- [7] 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.
- [8] M. Nishiyama, T. Okabe, I. Sato, and Y. Sato, "Aesthetic quality classification of photographs based on color harmony," Proc. 2011 IEEE Computer Society Conf. on Computer Vision and Pattern Recognition, pp. 33–40, June 2011.
- [9] "ImageNet," <http://image-net.org/> [2016/9/9/参照].
- [10] L.L. Thurstone, "Psychophysical analysis," American J. of Psychology, vol.38, no.3, pp.368–389, July 1927.
- [11] "Caffe," <http://caffe.berkeleyvision.org/> [2016/9/9/参照].
- [12] "scikit-learn Machine learning in Python," <http://scikit-learn.org/stable/> [2016/9/9/参照].