

推薦論文

アスペクトモデルを用いた Web 画像検索結果からの典型的画像の取得

手塚 太郎^{†1} 前田 亮^{†1}

World Wide Web 上で画像を検索する場合、対象となるオブジェクトの視覚的特徴を知ることが重要な目的の 1 つとしてあげられる。このようなタスクにおいて適切な検索結果は、オブジェクトの典型的な特徴をとらえた画像である。しかし既存の Web 画像検索エンジンを使用した場合、その結果は必ずしも典型的な画像の集合になっていない。そこで本研究では Web 画像検索結果に対して生成モデルのパラメータ推定を行い、典型的画像を抽出する手法を提案する。具体的には画像の典型性は記号的な特徴の組合せによって表現されると見なし、離散的潜在変数を持つ生成モデルであるアスペクトモデルを用いて表現する。画像内に特定の色相の画素が存在することを記号的特徴と見なし、EM アルゴリズムを用いてアスペクトモデルのパラメータを学習させる。評価実験の結果、典型的な画像の集合が効率的に取得できることを示した。また、実際に Web 画像検索と連動し、画像を典型性の度合いでランキングさせるシステムの実装を行った。

Finding Typical Images from Web Search Results Using Aspect Model

TARO TEZUKA^{†1} and AKIRA MAEDA^{†1}

One important motivation for searching images on the World Wide Web is to know what an object looks like. For such task, the best response is to present the most typical image of the object. Existing web-based image search engines, however, contain many results that are not typical. In this paper, we propose a method that estimates parameters of a generative model, in order to extract typical ones from a given set of images. Specifically, we assume that typicality is represented by combinations of symbolic features, and express it using the aspect model, which is a generative model with discrete latent variables. Symbolic features used in our implementation are the existences of specific colors in object region of the image. Based on the proposed method, we implemented a

system that ranks the images obtained from the Web in the order of typicality. Experiments showed the effectiveness of our method.

1. はじめに

画像検索を行う場合、クエリで指定したオブジェクトの視覚的特徴を知ることが主要な目的の 1 つとしてあげられる。特に World Wide Web 上で画像検索を行う場合、このような目的が占める割合は高い。このとき、検索結果として求められているのはオブジェクトの典型的な画像である。しかし現在 Web 上で利用可能な画像検索エンジンを利用した場合、検索結果にはクエリで指定したオブジェクトに関して典型性の低い画像も多く含まれている。そこで本研究では確率モデルを使用し、検索結果画像の集合から典型的画像を抽出する手法について述べる。

典型性という概念は人間の認知に関わり、完全な定義を与えることは困難であるが、本論文では「クエリ Q に対する典型的画像 I 」を「画像 I に対してラベルを与え、 Q という単語が適切であるもの」と定義する。本研究では離散的な潜在確率変数を持つ確率モデルであるアスペクトモデルを学習させ、そのパラメータに基づく指標を用いて典型的画像のランキングを行う。ランキングの対象となるのは Web 上で公開され、画像検索エンジンによって取得された画像集合である。

前処理として画像に対して領域分割を行い、画像の中心的な位置を占めるオブジェクト領域を抽出する。オブジェクト領域内の画素集合について色特徴量のベクトルを求め、離散的確率モデルの 1 つであるアスペクトモデルを用い、画像を主要な特徴に要約した「アスペクト」を推定する。生起確率の最も高いアスペクトを画像集合の主特徴と見なし、これのもとでの条件付き確率を用いて典型度の指標を定義し、画像をランキングする。

本手法の特徴として、画像を離散的なアスペクトの集合と見なすという点があげられる。画像を確率的な生成モデルでとらえる場合、主成分分析 (KL 展開) 等、連続的な潜在変数を仮定したモデルが広く使われている。代表的なクラスタリング手法の 1 つである k-means 法も、混合ガウス分布の推定に基づくものと見なすことができる。しかし Web 画像検索結果のように、まったく異なる対象を写した写真が混在している場合、潜在変数が連続的な分

^{†1} 立命館大学情報理工学部

College of Information Science and Engineering, Ritsumeikan University

布に従うと仮定するよりも、離散的な混合モデルを使用した方が妥当であると考えられる。また、そのようなモデルのパラメータの方が解釈も容易であるという利点がある。アスペクトモデルは画像集合の構成が何らかの意味で記号的である状況に適している。

提案手法は画像検索エンジンの利便性を向上させるだけでなく、Web 画像検索をより幅広い用途で使用することを可能にさせる。例として、ナビゲーションシステムにおける画像検索の利用があげられる。携帯電話での画像閲覧機能を利用し、道案内時に Web から得られた建物の画像を表示することが可能になってきている。このような目的においては、無関係な画像は利用者の誤解を招くため、目印となる建物の特徴を最もよく表した典型的な画像を提示することが望ましい。

逆に典型的な画像の集合を検索クエリと関連づけて大量に蓄積することで、画像からオブジェクトの名称を検索するといったシステムも可能になる。近年ではモバイル端末にデジタルカメラが搭載されていることが多いため、今後の発展が期待される応用である。本研究では提案手法に基づき、実際に Web 画像検索の結果から典型的画像を抽出するシステム「Typi」の実装も行った。

論文の構成は以下のとおりである。2 章では関連研究について述べる。3 章では手法の詳細を述べる。4 章では実装について述べる。5 章では評価実験の結果を示す。6 章でまとめを行う。

2. 関連研究

本章ではコンテンツ型画像検索、Web 画像検索、ならびに典型的画像の抽出システムに関する関連研究を述べる。

2.1 Web 画像検索

近年、Google Image Search、Yahoo! Image Search、goo 画像検索をはじめとして、多数の Web 画像検索エンジンが公開されている。一方、Web 画像検索とオブジェクト領域推定を結び付ける研究として、Smith らによる WebSeek があげられる¹⁾。また、Web 画像検索は商品の外観を知るといった目的において頻繁に使用されるが、Jing らは商品画像のランキングに画像類似度からなる仮想的なグラフ構造を利用する研究を行った²⁾。

竹内らは Web 上の画像に対する説明文を取得するという目的のために、類似画像の周辺テキストにおいて頻出する語を関連語と見なし、それらを多く含む文の抽出を行った³⁾。また、Rui らは画像に対するアノテーションを充実させるために、Web 上の画像の周辺テキストから特徴的な語彙を抽出し、さらに画像検索エンジンを利用して関連語を拡張したう

で、強化学習によって絞り込む手法を提案している⁴⁾。

獅子堀らはユーザのフィードバック情報を登録した画像知識データベースを利用して Web 上の画像をフィルタリングするシステムを開発した⁵⁾。フィルタリングにあたってユーザからのフィードバックの情報を利用しているため、Web 上の画像の情報のみを用いて典型的画像の取得を行う本研究とはアプローチが異なる。柳井は Web 画像検索結果をフィルタリングし、一般オブジェクト認識に使用できる画像を大量に収集する研究を行っている⁶⁾。Web を利用することで既存の画像データベースには存在しない多彩な特徴を持った画像を集めるという目的のため、典型的画像を取得するという本研究とは方向性が異なる。市川らは画像の色特徴間の非類似度を用いてクラスタリングを行い、ユーザが選択したクラスから画像周辺のキーワードを抽出し、拡張検索を行うシステムを開発した⁷⁾。一方、本研究ではオブジェクトの典型的な画像を取得することを目的としているため、領域分割を行ったうえで特徴量ベクトルを求め、確率モデルを用いて典型的特徴を取得している点に特徴がある。

2.2 Bag-of-features

言語モデルで利用されている Bag-of-words の仮定を画像認識に利用する Bag-of-features の手法が注目を集めている。Vogel らは画像に写っている対象を特徴的な要素の組合せとして表現することで、検索精度の評価に利用する手法を提案している⁸⁾。Fei-Fei らは画像を分割して得られる小領域が持つ特徴量を「符号語」とし、テキスト情報検索で利用される生成モデルを学習させ、画像分類を行った⁹⁾。Bag-of-features モデルは現在までに画像検索や画像分類に適用されているが、本研究では画像の典型的特徴の推定に利用する。

2.3 典型的画像の取得

多数の画像集合から典型的な画像を求めるタスクに関しては近年、いくつかの研究が行われ始めている。Kennedy らは建造物の写真集合から典型的な画像を取得する手法を開発した¹⁰⁾。また、Wu らは画像中に現れる視覚的に顕著なオブジェクトを識別するために最近傍法を利用する手法を開発した¹¹⁾。

君田らは画像の概略を示した図をクエリとして使用し、類似する画像をデータベースから検索したうえで対話的に絞り込みを行うことで、典型的画像を取得するシステムを開発した¹²⁾。この手法ではユーザの明示的な選択によって典型的画像を求めており、検索結果画像の特徴量のみを用いて典型的画像を推定する本研究のアプローチとは異なる。また、山本らは色特徴と周辺テキストを用いて画像の信憑性を評価する手法を提案している¹³⁾。本研究とは目的が異なり、また手法も画像間の類似度に基づくグラフマイニングに力点を置いたものとなっている。

3. 提案手法

本章では、Web 検索によって得られた画像集合から典型的な画像を抽出するシステムについて述べる。手法の概略は以下のとおりである。

1. 既存の Web 画像検索エンジンを用いて画像の収集を行う。
2. 画像データに対し、RGB ならびに明度の 4 つの値についてヒストグラムを求める。
3. 4 つの成分のうち、判別分析法に基づくクラス間分散・クラス内分散の商（分離度）が最大となる分割を用いて二値化を行う。
4. 二値化で得られた二領域の面積比が閾値を超えた場合、 p -タイル法で二値化を行う。
5. 輪郭追跡を行い、定められた条件を満たす側をオブジェクト領域と見なす。
6. オブジェクト領域内の画素と画像特徴の二者間データを用いてアスペクトモデルのパラメータを推定する。
7. 生成確率を用いてアスペクトをランキングし、上位のアスペクトを用いて典型的画像を取得する。

図 1 にシステムの構成を示す。本章の各節では以上の提案手法の詳細について述べる。

3.1 二 値 化

既存の Web 画像検索エンジンを用いて取得された画像からオブジェクト領域を推定するため、判別分析法を用いた二値化を行う。この際、一般的に使われる明度ヒストグラムだけでなく、RGB（赤・緑・青）を加えた 4 次元についてヒストグラムを構成し、クラス間分散・クラス内分散の商（分離度）が最大となる次元での分割を利用する。オブジェクトの輪郭は明度の違いだけでなく色の違いによって現れることも多いため、このような手法を採用している。なお、いずれかのヒストグラムにピークが 2 つ以上存在する場合、判別分析法を用いた二値化は通常成功するが、全体のほとんどが同系統の色から構成される画像、特に黒が多い画像の場合、定義域の端に閾値が来てしまい、二値化に失敗することがある。この場合、 p -タイル法を $p = 1/2$ で使用し、ヒストグラムの面積を半分に分ける形で二値化を行う。具体的には二値化によって得られる二領域の面積比に閾値を設け、判別分析法でその閾値を超えた場合に p -タイル法を適用する。

p -タイル法ではあらかじめ一定の割合 p を定め、閾値 t より小さい値を持つ画素の割合が p となるように t を設定する。判別分析法では閾値 t で画素集合を 2 つのクラスに分けたと




図 1 典型的画像抽出システムの構成

Fig. 1 System flow for extracting typical images.

き、分離度が最大となるように t を設定する¹⁴⁾。

3.2 領域分割

二値化された画像に対し、輪郭抽出によってオブジェクト領域と背景への分割を行う。8-連結の輪郭追跡を行い、オブジェクトの輪郭を抽出する。このとき、輪郭のいずれの側がオブジェクト領域であるかを区別する必要があるが、色の濃淡や面積比だけを用いて判断することは困難であるため、画像の四隅のうち、より少ない数の隅を含む側の領域をオブジェクトとする。また、ともに 2 つずつの隅を含む場合は、下側の隅を多く含む側をオブジェクトとする。これは建物等、画像の下側にオブジェクトが位置することが多いためである。もし下側の隅を含む数まで同じである場合は、オブジェクトが対角線上に位置しており、画像の大半がオブジェクトである可能性が高いため、画素数の多い側をオブジェクト領域とする。図 2 は提案手法を用いた領域分割の例を表している。

3.3 アスペクトモデル

Web 画像検索エンジンの検索結果には多様な対象が含まれている。たとえば「iris」というクエリに対しては、野草のアヤメ類（アヤメ/カキツバタ/ハナショウブ等）と眼球の虹彩が入り交じった結果が得られる。また、アヤメ類には紫や赤、黄色等、多様な色を持つもの




図 2 領域分割によるオブジェクトの抽出例

Fig.2 Examples of object extraction by region segmentation.




図 3 アスペクトモデルのグラフィカルモデル

Fig.3 Graphical model for aspect model.

が存在し、さらにはアヤメの咲いた草地を写したものや、花卉の一部を写したものもある。また、背景色が異なることや、オブジェクトの一部の領域の色だけが異なることも多い。このような状況は確率モデルの 1 つである混合モデルによって表現することができる。

本研究では離散分布が混合されるモデルであるアスペクトモデルを導入する。このモデルを導入する理由は、典型的画像はいくつかの記号的な特徴の組合せによって表現できると考えるためである。たとえばアヤメの画像であれば、オブジェクト領域が紫、黄、あるいは赤と白、といった色彩的組合せを表現することができる。

アスペクトモデルは二者間データ (dyadic data) が離散的潜在変数のもとで条件付き独立であることを仮定する確率モデルである¹⁵⁾。グラフィカルモデルでは図 3 のように表される。

ただし x と y は観測変数、 z が潜在変数であり、いずれも離散変数である。 x と y の二者間データ (x, y) が観測値として得られるとする。 N はデータ数を表す。このグラフィカルモデルに基づき、以下の条件付き独立性が得られる。これはそのままデータ (x, y) の生成モデルと見なすことができる。

$$p(x, y, z) = p(x|z)p(y|z)p(z) \quad (1)$$

z は生成モデルにおいて最初に生成される確率変数であり、アスペクトと呼ばれる。 x と y はそれぞれ z のもとでの条件付き確率 $p(x|z)$, $p(y|z)$ に従って生成されることになる。二者間データ (x, y) の頻度を $n(x, y)$ で表した場合、対数尤度 $L(x, y)$ は $\ln \prod_{x, y} p(x, y)^{n(x, y)}$ になる。前述の条件付き独立性を用い、以下のように変形できる。

$$L(x, y) = \sum_{x, y} n(x, y) \ln p(x, y) = \sum_{x, y} n(x, y) \ln \sum_z p(x|z)p(y|z)p(z) \quad (2)$$

このモデルのパラメータを最尤推定する場合、対数尤度の最大化よりも Q 関数の最大化の方が容易であるので、EM アルゴリズムを用いて推定を行う。 Q 関数は完全データの対数尤度の期待値であり、以下のように定義される。ただし $q(z)$ は現在のパラメータの推定値に基づく z の分布であり、 $E_{q(z)}$ はその分布を使って期待値を求めることを意味する。生成モデルを代入することで以下を得る。

$$Q(p, q) = E_{q(z)} \left[\sum_{x, y} n(x, y) \ln p(x, y, z) \right] \quad (3)$$

$$= \sum_z \sum_{x, y} q(z) n(x, y) (\ln p(x|z) + \ln p(y|z) + \ln p(z)) \quad (4)$$

Q 関数の最大化を行うことで、以下の E-step と M-step を得る。

E-step:

$$p(z|x, y) = p(x|z)p(y|z)p(z) / \sum_{z'} p(x|z')p(y|z')p(z')$$

M-step:

$$p(x|z) = \sum_y n(x, y) p(z|x, y) / \sum_{x', y} n(x', y) p(z|x', y)$$

$$p(y|z) = \sum_x n(x, y) p(z|x, y) / \sum_{x, y'} n(x, y') p(z|x, y')$$

$$p(z) = \frac{1}{N} \sum_{x, y} n(x, y) p(z|x, y)$$

反復はパラメータの更新によって生じる対数尤度の差が閾値以下となるまで、あるいは定められた更新回数を超えるまで行う。提案手法ではアスペクトモデルを画像において混合された特徴の抽出に使用するため、 x に画像、 y に次節で述べる画像特徴をあてはめる。

3.4 画像特徴

提案手法では典型的画像は典型的な特徴の組合せ (混合) によって生じているととらえて

いる．ここで使用する特徴は色彩的特徴である．これをベクトルで表すために，色空間を色領域に分割する．これによって類似する色をまとめて扱う．分割には主に色相を使用する．これは同一のオブジェクトでも光のあたり方によって明度や彩度は大きく変わるが，色相の変化は少ないと考えられるためである．また，彩度や明度が 0 や 1 に近い色は非常にくすんだ色，あるいは黒に近い色，白に近い色であるため，色相の差は重要でなくなる．このため，これらの色はまとめて 1 つの色領域として扱う．それぞれの色領域に関し，オブジェクト領域内でどれだけの画素が存在するかを数え，この値を成分とするベクトルを HSV ベクトルと名付ける．

前述の手法で画像をオブジェクト領域と領域外に分割したうえで，オブジェクト領域内において，特定の色特徴を持った画素が現れているという事象を y として用いる．提案手法におけるアスペクトモデルの利用においては，画像 x に画像特徴 y が出現したということが二者間データ (x, y) と見なされる．

3.5 最上位アスペクトの取得と画像のランキング

確率 $p(z)$ の大きいアスペクトほど生じやすく，画像集合において重要であると考えられる．また，条件付き分布 $p(y|z)$ は画像特徴 y が生成される確率の分布である．あるアスペクトが画像の典型的特徴をとらえているためには，それが単一の色を生成するのではなく，複数の色の組合せを生成させることが必要と考えられる．実際，予備実験の結果，自然画像を対象とする典型的画像の抽出において，特定の色のみに偏った条件付き分布を持つアスペクトからは典型的画像を取得できないことが示された．逆にすべての色をまんべんなく生成させるアスペクトは特徴を持たないため，たとえ $p(z)$ が高くても典型的画像を取得できるアスペクトになっていない．そこで $p(y|z)$ のばらつきの指標としてエントロピー $H[p(y|z)]$ を導入する．アスペクトをエントロピーの大小でソートし，2 つの閾値を用いて中間的な大きさのエントロピーを持つアスペクトのみを残す．フィルタリングの条件は式 (5) のように表記できる．

$$\alpha|Z| < \text{rank}(H[p(y|z)]) < \beta|Z| \quad (5)$$

ただし $|Z|$ は使用するアスペクトの数であり， $\text{rank}(H[p(y|z)])$ はエントロピー $H[p(y|z)]$ で z をソートした際の順位を表す． $0 \leq \alpha, \beta \leq 1$ はアスペクトを採用する範囲を定めるための係数である．典型性の表現として妥当なアスペクトは一般に多数存在するため，このようなフィルタリングによって適切なアスペクトが得られなくなってしまうことは少ない．

条件を満たしたアスペクトを $p(z)$ で降順にソートし， $p(z)$ が最も高いアスペクトを最上

位アスペクト，2 番目に高いアスペクトを第 2 位のアスペクト，というように表記する．このようにして得られた第 m 位のアスペクトを画像 x のランキングに使用する．画像の典型度の指標 $typicality$ は式 (6) のように定義される．

$$typicality(x, m) = \sum_{z_m} p(x|z_m)p(z_m) \quad (6)$$

ただし $p(x|z)$ はアスペクト z から画像 x が生成される確率を表している． z_m はアスペクトを $p(z)$ の降順でソートしたとき，上位から m 番目にランクされたアスペクトを表す．

4. 実装

本章では提案手法に基づき実装されたシステム「Typi (ティピ)」について述べる．システム名は *typical* (典型的) という語にちなんでつけられている．

4.1 システムの構成

Typi の実装は C#で行った．システムは画像収集機能・特徴抽出機能・評価機能から構成される．画像収集機能の実装には API for Google Image Search¹⁷⁾ を使用している．検索結果は順位付けられて得られるため，これを評価実験におけるオリジナルのランキングとして使用する．

4.2 使用したパラメータ

実装時に使用した各種パラメータの値は以下のとおりである．

判別分析法による分割が失敗したと見なす閾値としては，1:16 を使用した．すなわち，小さい側の領域の面積が大きい側の面積の 1/16 以下である場合は， p -タイル法による分割を使用する．多数の画像データに対して判別分析法による領域分割を適用した結果，全体の 1/16 程度の大きさまでは正しいオブジェクトであるという事例が見られたことに基づき，この値に設定した．

色領域の設定に関しては，明度と彩度のみを用いて黒・濃灰・薄灰・白という色を定義する．明度が 0.2 未満の領域を黒と見なし，色相と彩度にかかわらず 1 つの色と見なした．また，彩度が 0.2 未満の領域のうち，明度が 0.2 以上 0.6 未満の領域は濃灰，0.6 以上 0.8 未満の領域は薄灰，0.8 以上の領域は白という色と見なした．

明度と彩度がそれ以外の値をとる色領域を明度について 3 分割，彩度について 3 分割，色相について 18 分割する．色相はオブジェクトの不変的な色彩的特徴を表すと考えられるため，細かく分割している．一方，彩度や明度は照明等の影響によっても変わり，細かく分割することは認識精度の低下につながるため，3 分割にとどめている．色相の分割に 18 とい




図 4 「Typi」システムのスナップショット
Fig. 4 Snapshot of “Typi” interface.




図 5 評価実験用インタフェース
Fig. 5 Interface for evaluation.

う値を採用した理由は、一般に共通して使われる色名の数 が 18 種以内に収まると考えられるためである．結果として $(18 \times 3 \times 3) + 4 = 166$ 次元のベクトルが得られ，これを HSV ベクトルとして使用した．

アスペクトモデルの潜在変数 z は 10 種類の値をとれるものとした．これは 1 つのクエリに対して Web 画像検索で得られた 100 枚の画像をオブジェクトに応じて分類した場合，要素数 2 以上のグループは 10 程度に収まるという経験に基づいて設定されている．エントロピーを用いたアスペクトのフィルタリングの閾値としては， $\alpha = \frac{1}{2}$ および $\beta = \frac{4}{5}$ を使用した．

学習において収束を判定する条件は対数尤度の増加が 10^{-5} 以下，あるいは反復回数が 300 回を超えた時点で終了させるようにした．また，EM アルゴリズムは局所解に陥る可能性があるため，初期値を変更して 5 回の試行を行い，最も対数尤度が高い結果を選んだ．

4.3 インタフェース

図 4 はシステムのスナップショットである．検索エンジンによるランキングと提案手法によるランキングを切り替えて表示させることができる．また，図 5 は評価実験用インタフェースを示している．システムによって得られた画像に対し，簡単なクリック操作によって正解が不正解かの情報を入力し，容易に評価実験を行えるようにしている．

5. 評 価

5.1 評価手法と評価対象

提案手法に対し，カテゴリ別およびクエリ別の top-k 精度（適合率）を用いて評価を行った．実験は 3 つのカテゴリから 20 件ずつのクエリを選び，それぞれから 100 枚の画像を取得し，計 6,000 枚の画像を対象として行った．使用したカテゴリとそれに含まれるクエリを表 1 に示す．クエリには英単語を使用した．複数の単語から構成されるクエリに関してはダブルクォーツで囲い，フレーズ検索を行った．

これらのカテゴリに属するオブジェクトはいずれも典型的な色と形状を持つため，正解・不正解の判定が容易であり，また確実性の高い評価を行うことができる．処理の高速化のため，Web 上に存在する画像そのものではなく，検索エンジンが提示する縮小画像を利用している．そのため画像のサイズは最大で 150×150 ピクセルである．

5.2 評価基準

提案手法に基づいて得られた画像の集合に対し，典型的画像として適切であるかどうかを目視で判定しながら評価を行うため，統一した基準で判断を行う必要がある．

1 章で述べたように，本論文では「クエリ X に対する典型的画像」を「その画像に対してラベルを与えとき， X という単語が最も適切であるもの」と定義している．そのため精度評価の基準として，検索クエリによって表されるオブジェクトが画像中に現れることは必要条件とした．一方，画像中に複数のオブジェクトが含まれ，「クエリで指定されたオブジェ

表 1 実験対象カテゴリとクエリ

Table 1 Categories and queries used for experiments.

カテゴリ：画像検索クエリ例
野草 (wildflower): dandelion, daisy, buttercup, iris, water arum, hawkweed, calliopsis, columbine, searocket, pale flax, harebell, wild radish, scarlet pimpernel, lady's slipper, baby blue eyes, chinese houses, ice plant, franciscan wallflower, clematis, forget me nots
トロピカルフルーツ (tropical fruit): dragonfruit, jackfruit, durian, papaya, carambola, mangosteen, longan, rambutan, mango, pineapple, black sapote, guava, lychee, granadilla, soursop, banana, naranjilla, mamoncillo, pupunha, mamey sapote
スパイス/ハーブ (spice / herb): star anise, cloves, fennel, coriander, nutmeg, caraway, cumin, turmeric, cardamom, saffron, tarragon, parsley, basil leaf, cinnamon, ginger, bay leaf, oregano, lemongrass, lemon balm, marjoram

クトの外観を知る」というタスクにおいて不十分と考えられる場合は、たとえ該当するオブジェクトが含まれていたとしても不正解とした。実際、複数のオブジェクトが現れる画像はオブジェクトの外観に関する知識獲得という目的において不適切であると考えられる。たとえば「タンポポ」が検索クエリの場合、それがタンポポであることが十分に識別できるだけの情報が画像中に提示されていなくてはならない。画像がディテールに乏しく、花の一種類としてしか認識できないような場合は典型的画像として適切でないと見なす。また、タンポポ畑の写真やタンポポと別の花がともに写っている写真は不正解としたが、タンポポが主要な対象となっている画像であれば背景に関してはこだわらずに正解画像とした。なお、オブジェクトにラベルを与える評価者はその特徴に関して十分な知識を持っているものとする。

なお、ランキング精度の絶対値は評価セットに依存するため、本評価実験において目標とするのは提案手法が検索エンジンと比較して相対的に精度を向上させることを示すことである。

5.3 評価結果

本節ではシステムの実行結果例、および精度に関する結果を示す。

5.3.1 領域分割の基準の比較

表 2 は 1,000 枚の画像を対象に、各次元について、判別分析法による分離度、ならびにオブジェクト領域と背景領域の面積比、面積比が閾値を超えた回数をまとめたものである。色相と彩度は提案手法では領域分割の次元として使用していないが、実際に面積比が閾値を超えることが多く、領域分割の基準として有効でないことが予想される。

表 2 領域分割に関する統計

Table 2 Statistics on region segmentation.

次元	分離度の平均	面積比の平均	分離度が最大であった回数	面積比閾値の超過回数	領域分割での使用回数
R (赤)	4.436	0.535	282	12	288
G (緑)	4.745	0.537	209	17	207
B (青)	4.884	0.510	434	11	433
V (明度)	4.686	0.544	75	11	72
H (色相)	11.040	0.375	*	153	*
S (彩度)	3.389	0.410	*	75	*

表 3 オブジェクト領域抽出の評価

Table 3 Evaluation of object region extraction.

クエリ	正解画像数	抽出成功数	成功率
dandelion	38	34	89%
daisy	59	51	86%
iris	86	75	87%
naranjilla	27	25	93%
rambutan	51	41	80%
mamey sapote	40	34	85%
star anise	54	48	89%
cloves	36	36	100%
fennel	10	9	90%

領域分割には RGB と明度の各成分がいずれも使用されており、4 つの次元を合わせて使用することの有効性が示されている。また、色相と彩度を領域分割に使用する研究も多いが、これらは本実験の結果を見る限り、面積比が閾値を超えることが多く、あまり効果的な指標ではないことがいえる。

5.3.2 オブジェクト領域抽出

領域分割によって適切にオブジェクト領域が抽出できているかを評価するため、各カテゴリから 3 つずつのクエリを選び、実験を行った結果を表 3 に示した。

多くのクエリにおいて 100%の精度は達成できておらず、オブジェクト領域を正しく抽出できなかった画像も存在する。しかし正解画像は多数存在するため、正しくオブジェクト領域を抽出できたものをランキング上位に入れることができれば、十分実用的なシステムになると考えられる。iris (アヤメ類) ならびに daisy (デージー) に関して領域抽出を行った例を図 6、図 7 に示した。抽出されたオブジェクト領域の境界線は太線で示されている。理想



図 6 「iris (アヤメ類)」におけるオブジェクト領域抽出
Fig.6 Object region extraction for “iris”.



図 7 「daisy (デージー)」におけるオブジェクト領域抽出
Fig.7 Object region extraction for “daisy”.

的なオブジェクト領域に一部足りないものも存在するが、全体での色の分布を特徴量として使用するため、本手法での利用においては問題ないと考えられる。

5.3.3 ランキング例

本項では検索エンジンおよび最上位アスペクトによるランキングの上位の画像を例示する。画像は左上から右方向へ向けてランキングの降順で並んでいる。評価実験の基準において不正解画像と見なされたものには×印を付けている。

図 8, 図 9 は野草カテゴリに含まれる「iris (アヤメ類)」に対するランキング結果の比




図 8 「iris (アヤメ類)」における検索エンジンランキング
Fig.8 Search engine ranking for “iris”.




図 9 「iris (アヤメ類)」における最上位アスペクトによるランキング
Fig.9 Top aspect ranking for “iris”.

較である。iris には眼球の虹彩という意味もあるため、検索エンジンの結果ではこれらの画像も上位 (10 番目, 15 番目) に入ってきてしまっている。これはテキストベースのランキングの弱みであるともいえる。最上位アスペクトによるランキングの上位には多数の正解画像が含まれ、精度は検索エンジンのランキングよりも高い。

ここで 5.2 節で述べた評価基準を具体例に即して説明する。図 8 における 4 番目は様々な種類の花を並べた画像であるが、これは花を比較している表であり、「iris (アヤメ類)」というラベルを付与することが適切とはいいきれないため、不正解画像と見なしている。図 9



図 10 「chinese houses (チャイニーズ・ハウゼズ)」における検索エンジンのランキング
Fig.10 Search engine ranking for “chinese houses”.




図 11 「chinese houses (チャイニーズ・ハウゼズ)」における最上位アスペクトによるランキング
Fig.11 Top aspect ranking for “chinese houses”.

の 10 番目は花壇の画像であるが、この画像に関しても同様に「iris (アヤメ類)」というラベルが適切とはいえないため、不正解画像と判定している。

図 10, 図 11 は野草カテゴリに含まれる「chinese houses (チャイニーズ・ハウゼズ)」に対するランキング結果の比較である。chinese houses は文字どおり「中国の家」という意味もあるため、検索エンジンの結果ではこれが上位に入ってきてしまっている。一方、最上位アスペクトによるランキングでは高い割合で正解画像である花の画像が得られている。

図 12, 図 13, 図 14 はトロピカルフルーツの「naranjilla (ナランジャ)」に対する検索



図 12 「naranjilla (ナランジャ)」における検索エンジンのランキング
Fig.12 Search engine ranking for “naranjilla”.



図 13 「naranjilla (ナランジャ)」における最上位アスペクトによるランキング
Fig.13 Top aspect ranking for “naranjilla”.

結果である。検索エンジンの結果は多数の不正解画像を含んでおり、典型的画像の集合になっていない。一方、最上位アスペクトでは正解画像である果実の画像が高い割合で得られている。第 2 位のアスペクトでランキングした結果を見ると、逆に葉を中心とした画像集合が得られており、果実と葉がそれぞれ異なるアスペクトとして推定できていることが分かる。

5.3.4 カテゴリごとの top-k 精度

提案手法の有効性を調べるため、各クエリについて 100 件の画像をランキングする実験を行った。野草・トロピカルフルーツ・スパイス/ハーブの 3 種のカテゴリに対し、表 1 で



図 14 「naranjilla (ナランジャ)」における第 2 位アスペクトによるランキング
Fig. 14 Second aspect ranking for “naranjilla”.




図 15 野草カテゴリにおける top-k 精度の比較
Fig. 15 Top-k precisions of “wildflower” category.

あげた各 20 件のクエリを使用した。

検索エンジン (Google Image Search¹⁶⁾) によって提供されたランキング, ならびに最上位アスペクトによるランキングを用いて画像をソートし, top-k 精度を求めた結果が図 15, 図 16, 図 17 である。

ランキングの対象となる画像は 100 枚なので, top-100 精度が全画像の集合における正解画像の割合を示している。この値は野草, トロピカルフルーツ, ハーブ/スパイスの各カテゴリについてそれぞれ 0.58, 0.42, 0.38 である。すなわち提案手法はランダムサンプリングで得られる精度よりも高くなっている。




図 16 トロピカルフルーツカテゴリにおける top-k 精度の比較
Fig. 16 Top-k precisions of “tropical fruit” category.




図 17 スパイス/ハーブカテゴリにおける top-k 精度の比較
Fig. 17 Top-k precisions of “spice / herb” category.

野草カテゴリの top-10 精度に関しては検索エンジンによるランキングが 71%であるのに対し, 最上位アスペクトによるランキングでは 78%を得ており, 約 7 ポイントの精度向上が得られた。また, top-30 精度では検索エンジンによるランキングが 66%, 最上位アスペクトでは 76%となっており, 10 ポイントの精度向上が得られている。トロピカルフルーツカテゴリでも top-30 精度において 56%および 61%となり, 5 ポイントの精度向上が得られている。スパイス/ハーブにおける最上位アスペクトのランキングは検索エンジンによるランキングより全般的に劣っているが, この理由に関しては 5.3.5 項で考察を行う。

5.3.5 対象ごとの top-k 精度

表 4, 表 5 は野草カテゴリとスパイス/ハーブカテゴリの各クエリに関して top-k 精度を

表 4 野草カテゴリにおけるクエリごとの top-k 精度
Table 4 Top-k precision for each query in “wildflower” category.

クエリ	手法	10	20	30	40	50	100
dandelion	search en.	0.40	0.40	0.37	0.43	0.46	0.38
	aspect md.	1.00	1.00	0.93	0.78	0.68	0.38
daisy	search en.	1.00	0.75	0.80	0.73	0.70	0.59
	aspect md.	0.80	0.85	0.87	0.85	0.76	0.59
buttercup	search en.	0.70	0.65	0.70	0.68	0.62	0.44
	aspect md.	0.90	0.80	0.77	0.73	0.68	0.44
iris	search en.	0.80	0.85	0.87	0.88	0.86	0.86
	aspect md.	0.90	0.95	0.97	0.95	0.96	0.86
water arum	search en.	0.80	0.75	0.70	0.63	0.66	0.45
	aspect md.	0.90	0.75	0.73	0.63	0.64	0.45
hawkweed	search en.	1.00	0.95	0.87	0.88	0.86	0.80
	aspect md.	0.80	0.85	0.90	0.88	0.90	0.80
calliopsis	search en.	0.80	0.70	0.67	0.70	0.72	0.78
	aspect md.	1.00	1.00	0.97	0.95	0.96	0.78
columbine	search en.	0.20	0.15	0.20	0.28	0.30	0.36
	aspect md.	0.90	0.95	0.90	0.80	0.64	0.36
searocket	search en.	0.60	0.50	0.50	0.43	0.42	0.35
	aspect md.	0.10	0.15	0.17	0.15	0.18	0.35
pale flax	search en.	0.90	0.80	0.67	0.68	0.64	0.60
	aspect md.	0.90	0.75	0.83	0.80	0.82	0.60
harebell	search en.	1.00	0.90	0.90	0.88	0.90	0.78
	aspect md.	1.00	0.95	0.90	0.88	0.88	0.78
wild radish	search en.	0.80	0.80	0.73	0.70	0.70	0.75
	aspect md.	0.90	0.90	0.93	0.95	0.92	0.75
scarlet pimpernel	search en.	0.40	0.40	0.47	0.45	0.42	0.37
	aspect md.	0.50	0.45	0.40	0.38	0.32	0.37
lady's slipper	search en.	1.00	0.95	0.90	0.93	0.94	0.80
	aspect md.	1.00	1.00	1.00	1.00	0.98	0.80
baby blue eyes	search en.	0.40	0.40	0.40	0.38	0.42	0.34
	aspect md.	0.00	0.00	0.03	0.03	0.08	0.34
chinese houses	search en.	0.20	0.25	0.27	0.28	0.28	0.32
	aspect md.	0.90	0.80	0.77	0.60	0.54	0.32
ice plant	search en.	0.70	0.75	0.73	0.68	0.64	0.52
	aspect md.	0.60	0.70	0.70	0.75	0.78	0.52
franciscan wallflower	search en.	0.70	0.65	0.73	0.65	0.56	0.47
	aspect md.	0.60	0.60	0.50	0.50	0.52	0.47
clematis	search en.	0.90	0.90	0.93	0.93	0.94	0.92
	aspect md.	1.00	0.95	0.97	0.98	0.96	0.92
forget me nots	search en.	0.90	0.90	0.83	0.83	0.82	0.72
	aspect md.	0.90	0.80	0.87	0.88	0.88	0.72

表 5 スパイス/ハーブカテゴリにおけるクエリごとの top-k 精度
Table 5 Top-k precision for each query in “spice / herb” category.

クエリ	手法	10	20	30	40	50	100
star anise	search en.	0.90	0.85	0.80	0.73	0.68	0.54
	aspect md.	0.90	0.70	0.70	0.68	0.70	0.54
cloves	search en.	0.70	0.50	0.53	0.45	0.42	0.36
	aspect md.	0.40	0.25	0.33	0.38	0.36	0.36
fennel	search en.	0.20	0.10	0.07	0.05	0.10	0.10
	aspect md.	0.00	0.05	0.13	0.13	0.10	0.10
coriander	search en.	0.10	0.15	0.17	0.15	0.18	0.11
	aspect md.	0.60	0.45	0.33	0.28	0.22	0.11
nutmeg	search en.	0.30	0.35	0.27	0.28	0.30	0.16
	aspect md.	0.30	0.35	0.37	0.33	0.28	0.16
caraway	search en.	0.50	0.25	0.23	0.20	0.16	0.09
	aspect md.	0.00	0.05	0.10	0.08	0.06	0.09
cumin	search en.	0.60	0.50	0.40	0.40	0.38	0.36
	aspect md.	0.20	0.30	0.33	0.35	0.36	0.36
turmeric	search en.	0.60	0.40	0.37	0.38	0.34	0.32
	aspect md.	0.20	0.35	0.43	0.38	0.34	0.32
cardamom	search en.	0.40	0.50	0.43	0.38	0.34	0.28
	aspect md.	0.10	0.20	0.20	0.18	0.22	0.28
saffron	search en.	0.50	0.50	0.47	0.40	0.34	0.29
	aspect md.	0.30	0.45	0.47	0.45	0.38	0.29
tarragon	search en.	0.80	0.70	0.70	0.63	0.56	0.39
	aspect md.	1.00	0.90	0.83	0.73	0.66	0.39
parsley	search en.	1.00	1.00	0.93	0.93	0.90	0.58
	aspect md.	0.90	0.90	0.90	0.88	0.82	0.58
basil leaf	search en.	0.80	0.80	0.57	0.53	0.52	0.39
	aspect md.	0.10	0.15	0.17	0.18	0.16	0.39
cinnamon	search en.	0.80	0.60	0.60	0.50	0.50	0.29
	aspect md.	0.40	0.35	0.40	0.38	0.42	0.29
ginger	search en.	0.50	0.45	0.53	0.48	0.44	0.25
	aspect md.	0.30	0.25	0.27	0.23	0.24	0.25
bay leaf	search en.	0.80	0.80	0.77	0.73	0.62	0.54
	aspect md.	0.30	0.45	0.47	0.48	0.58	0.54
oregano	search en.	0.80	0.65	0.63	0.65	0.64	0.58
	aspect md.	1.00	0.90	0.87	0.80	0.78	0.58
lemongrass	search en.	0.80	0.85	0.83	0.78	0.70	0.55
	aspect md.	0.60	0.60	0.60	0.53	0.60	0.55
lemon balm	search en.	0.80	0.85	0.87	0.85	0.86	0.79
	aspect md.	0.90	0.95	0.97	0.98	0.98	0.79
marjoram	search en.	0.70	0.70	0.73	0.65	0.62	0.57
	aspect md.	0.90	0.85	0.80	0.73	0.68	0.57

示したものである．トロピカルフルーツカテゴリに関する表はスペースの関係上割愛した．

野草カテゴリの場合、「baby blue eyes (ベビー・ブルー・アイズ)」において top-10 精度が 0 になっているが、最上位アスペクトで得られたのは青い目の赤ん坊の写真の集合であった．これは baby blue eyes が野草の名前であると同時に文字どおり赤ん坊の青い目を表すという語の曖昧性が原因となっている．

スパイス/ハーブカテゴリの場合、クエリ「fennel (フェネル)」や「caraway (キャラウェイ)」で top-10 精度が 0 となっており、全体の精度を下げる原因となっている．これらは生の状態のものと乾燥させたものがともにスパイス/ハーブとして使われており、検索画像においてそれぞれがほぼ同程度に存在している．今回の判定基準では乾燥させたものだけを正解としたが、最上位のアスペクトが生の特徴をとらえてしまったため、アスペクトによるランキングでは上位に正解画像がまったく入らない結果となった．このように曖昧性を持つ単語の存在が精度を下げる一因となっているが、これは 1 種類だけの典型的画像を正解とする今回の評価手法の限界であるともいえる．また、表 5 の top-100 精度の列に示されているように、スパイス/ハーブカテゴリでは正解画像が全体の 3 割以下であるものが 8 件 (全体の半分近く) あり、これらについては提案手法の精度が特に低く、そもそも正解画像が少ない集合の中から推定を行うことの難しさが現れている．一方、「coriander (コリアンダー)」のように、正解画像が全体の 1 割程度であるにもかかわらず、アスペクトモデルによるランキングで top-10 精度で検索エンジンの結果を大きく上回る 0.6 が得られているものもある．これは正解画像が茶色系統の特徴的な色彩を持ち、互いによく似ているため、分布を適切に推定できたことが原因であると考えられる．

図 18, 図 19, 図 20, 図 21, 図 22, 図 23 は検索エンジンとアスペクトモデルによるランキングで得られた上位 10 件について、精度とクエリ数の分布を示したグラフである．ただし P は精度を表す．また、円グラフの領域の大きさはその精度が得られたクエリの数 (全体に対する割合) を表している．

野草カテゴリにおいては 0.9 以上の精度を持つクエリが検索エンジンでは 35% であるのに対し、アスペクトモデルでは 65% を占めている．トロピカルフルーツカテゴリにおいても検索エンジンが 15% に対し、アスペクトモデルでは 20% になっている．しかしアスペクトモデルでは精度 0.5 未満のクエリも 20% になってしまっている．一方、スパイス/ハーブカテゴリでは 0.9 以上の精度が検索エンジンで 10% に対し、アスペクトモデルでは 30% であり、改善されている．しかし 0.5 未満の精度がアスペクトモデルでは 60% もあり、結果としてアスペクトモデルが特に弱いという結果になっている．




図 18 野草カテゴリにおける検索エンジンによるランキングの精度分布
Fig. 18 Precision distribution for “wildflower” category by search engine.




図 19 野草カテゴリにおける最上位アスペクトを用いたランキングの精度分布
Fig. 19 Precision distribution for “wildflower” category by top aspect.

5.4 考 察

実験の結果、アスペクトモデルは野草カテゴリにおいて検索エンジンの top-10 精度を 7 ポイント上回る精度で典型的画像が得られることが分かった．しかしスパイス/ハーブカテゴリでは検索エンジンによるランキングを下回る結果も得られている．その主な原因は典型性とは関係のないアスペクトが最上位にきてしまうことである．しかしそのような場合も、第 2 位以下に適切なアスペクトが得られていることが多い．第 2 位以降のアスペクトを用いたランキングで典型的画像の集合が得られているとき、それが最上位になるようにアスペクトをランキングすることは今後の課題である．

実験の結果、一部のクエリにおいて提案手法の精度が検索エンジンの精度を下回ることも




図 20 トロピカルフルーツカテゴリにおける検索エンジンによるランキングの精度分布
Fig.20 Precision distribution for “tropical fruit” category by search engine.




図 22 スパイス/ハーブカテゴリにおける検索エンジンによるランキングの精度分布
Fig.22 Precision distribution for “spice / herb” category by search engine.




図 21 トロピカルフルーツカテゴリにおける最上位アスペクトを用いたランキングの精度分布
Fig.21 Precision distribution for “tropical fruit” category by top aspect.




図 23 スパイス/ハーブカテゴリにおける最上位アスペクトを用いたランキングの精度分布
Fig.23 Precision distribution for “spice / herb” category by top aspect.

あった。しかし検索エンジンは周辺テキストやリンク構造等、多様な指標を利用して画像のランキングを行っているのに対し、提案手法で利用されているのは画像特徴量のみである。それにもかかわらず平均して検索エンジンを上回る精度を得ていることから、手法として有望であるといえる。

6. おわりに

本研究では Web 画像検索結果の画像に対し、輪郭追跡によるオブジェクト領域の推定、ならびにアスペクトモデルを用いて典型的画像の抽出を行うシステムを構築した。

今回の実験ではアスペクト推定の対象となる記号的特徴はオブジェクト領域内の画素と色

相との対応という単純なものだったが、今後はさらに複雑な記号的特徴も対象としていく予定である。特徴量の次元の増加にともない、学習手法の高速化も課題になると考えられる。

提案手法ではエントロピーを使用してフィルタリングを行っているが、訓練データを利用してその閾値を最適化することも今後の課題である。また、領域分割の精度が提案手法の精度に対する制約となっている可能性があるため、手動で領域分割を行った画像集合を用いて提案手法を評価することが考えられる。

評価実験では野草やトロピカルフルーツ等、視覚的特徴が顕著であるものを使用した。これらのオブジェクトには色情報に関する特徴が強く存在している。視覚的特徴が顕著でない画像についても提案手法を適用していくことは今後の課題である。より広いカテゴリに対し

て効果を持たせるために、色情報に加え、形状とテクスチャを用いた特徴量の導入を計画している。

謝辞 本研究は、文部科学省私立大学戦略的研究基盤形成支援事業「芸術・文化分野の資料デジタル化と活用を軸とした研究資源共有化研究」(事業番号：S0991041)、文部科学省科学研究費補助金若手研究(B)「Webからの画像データ自動収集と機械学習を用いたオブジェクト識別システムの構築」(研究代表者：手塚太郎、課題番号：21700121)によるものです。ここに記して謝意を表すものとします。

参 考 文 献

- 1) Smith, J.R. and Chang, S.: Visually searching the Web for content, *IEEE Multimedia*, Vol.4, No.3, pp.12-20 (1997).
- 2) Jing, Y. and Baluja, S.: PageRank for product image search, *Proc. 17th International World Wide Web Conference*, Beijing, China, pp.307-316 (2008).
- 3) 竹内謹治, 黄瀬浩一: 類似画像とキーワードを利用した Web 画像の説明文抽出, 情報処理学会研究報告, NL-171, pp.7-12 (2006).
- 4) Rui, X., Li, M., Li, Z., Ma, W.Y. and Yu, N.: Bipartite graph reinforcement model for web image annotation, *Proc. ACM International Conference on Multimedia 2007*, Augsburg, Germany, pp.585-594 (2007).
- 5) 獅々堀正幹, 小泉大地, 柘植 寛, 北 研二: 画像知識データベースを用いた WWW 画像検索システムの開発, 電子情報通信学会論文誌, Vol.J87-D-I, No.2, pp.154-163 (2004).
- 6) 柳井啓司: 確率的 Web 画像収集, 人工知能学会論文誌, Vol.22, No.1, pp.10-18 (2007).
- 7) 市川哲彦, 佐々木英文, 和田忠之: 画像類似度でのクラスタリングによる適合性フィードバックを利用した Web 画像検索 (続報), 第 18 回データ工学ワークショップ (DEWS2007), 広島 (2007).
- 8) Vogel, J. and Schiele, B.: On Performance Characterization and Optimization for Image Retrieval, *Proc. 7th European Conference on Computer Vision*, Copenhagen, Denmark, pp.51-55 (2002).
- 9) Fei-Fei, L. and Perona, P.: A Bayesian Hierarchical Model for Learning Natural Scene Categories, *Proc. IEEE International Conference on Computer Vision and Pattern Recognition 2005*, San Diego, California, pp.524-531 (2005).
- 10) Kennedy, L. and Naaman, M.: Generating diverse and representative image search results for landmarks, *Proc. 17th International World Wide Web Conference*, Beijing, China, pp.297-306 (2008).
- 11) Wu, W. and Yang, J.: Object fingerprints for content analysis with applications to

street landmark localization, *Proc. ACM International Conference on Multimedia 2008*, Vancouver, Canada, pp.169-178 (2008).

- 12) 君田和也, 山肩洋子, 角所 考, 美濃導彦: 視覚イメージ伝達のための典型的画像集合の対話的探索, 映像情報メディア学会技術報告, Vol.25, No.35, pp.31-36 (2005).
- 13) 山本祐輔, 山本岳洋, 中村聡史, 田中克己: 関連画像集合内における典型度と特殊度を用いた画像の信憑性分析, Web とデータベースに関するフォーラム (WebDB Forum 2008), 東京 (2008).
- 14) Gonzalez, R.C. and Woods, R.E.: *Digital Image Processing*, p.976, Pearson Prentice Hall, New Jersey (2008).
- 15) Hoffman, T., Puzicha, J. and Jordan, M.I.: Learning from Dyadic Data, *Advances in Neural Information Processing Systems*, Vol.11, pp.466-472 (1999).
- 16) Google Image Search. <http://images.google.com/>
- 17) API for Google Image Search.
http://www.codeproject.com/KB/IP/google.image_search_api.aspx

(平成 21 年 12 月 20 日受付)

(平成 22 年 4 月 7 日採録)

(担当編集委員 小口 正人)



手塚 太郎 (正会員)

立命館大学情報理工学部メディア情報学科講師。2005 年京都大学大学院情報学研究科博士後期課程修了。博士 (情報学)。主に Web 情報検索システム, Web マイニングの研究に従事。電子情報通信学会, 日本データベース学会各会員。



前田 亮 (正会員)

立命館大学情報理工学部メディア情報学科准教授。2000 年奈良先端科学技術大学院大学情報科学研究科博士後期課程修了。博士 (工学)。デジタル図書館, 情報アクセス技術に関する研究に従事。ACM, IEEE CS, 電子情報通信学会, 日本データベース学会, 言語処理学会各会員。