

画像分類における Bag-of-features による 識別に有効な特徴量の傾向

永 橋 知 行^{†1} 伊 原 有 仁^{†1} 藤 吉 弘 亘^{†1}

Bag-of-features における識別に有効な特徴量を実験的に検討する。Bag-of-features では、ヒストグラムにより特徴を表現するため物体の位置情報は無視され、対象カテゴリからなる前景領域のみで特徴量を記述することで精度が向上すると考えられる。そこで、我々は予め画像セグメンテーションにより前景領域を抽出し、その領域のみで特徴量を記述する手法と、通常の Bag-of-features との比較実験を行う。AdaBoost による識別器を構築し、弱識別器で選択された特徴量を調査することで、前景特徴と背景特徴がどのように捉えられているかを確認する。実験結果から、前景領域のみで特徴量を記述した場合、通常の Bag-of-features より識別精度が低下した。選択された特徴量を調べた結果、Bag-of-features による画像分類では前景特徴だけでなく背景特徴も識別に使用しており、画像中のシーン全体をモデリングする手法であることが判明した。上記の調査結果に基づいて、前景と背景の局所特徴の共起性に着目した 2 次元ベクトル量子化ヒストグラムを検討し、実験により約 0.24 の認識率向上を確認した。

Tendency of Image Local Features that are Effective for Discrimination by using Bag-of-Features in Object Category Recognition

TOMOYUKI NAGAHASHI,^{†1} ARIHITO IHARA^{†1}
and HIRONOBU FUJIYOSHI^{†1}

In this paper, we investigate the tendency of image local features that are effective for object category recognition with a “bag-of-features” technique. With the bag-of-features technique, positional information of an object is disregarded because the technique expresses features by means of a histogram. Accordingly, it is considered that accuracy is improved by describing local features only in the foreground region that is the subject category. We experimentally compare the effectiveness between a standard bag-of-features technique and a technique that extracts the foreground region by means of pre-image segmentation and

describes local features in that region only. By constructing a final classifier with the AdaBoost and investigating local features selected by weak classifiers, it is possible to confirm the way in which foreground or background features are captured. According to the results of the experiments, the discrimination accuracy of the above-described technique, in which only the local features in the foreground are extracted, is lower than that of the standard bag-of-features technique. According to the result of investigating the selected features by the standard bag-of-features, background features -as well as foreground features- are used in the classification, and it was made clear that the standard bag-of-features technique is one way of modeling an entire scene of the image. Based on the research results, we considered a two-dimensional vector quantization histogram focused on co-occurrence of local features in the foreground and background, and it was confirmed by experiment that the accuracy of the recognition rate was improved by about 0.24.

1. はじめに

制約のない実世界シーンの画像に対して、計算機がその中に含まれる物体を一般的な名称で認識することを一般物体認識と呼ぶ¹⁾。一般物体認識問題における画像中の物体がどのカテゴリに属するかを求める画像分類問題に対して、近年では、Bag-of-features モデル²⁾が提案され、多くの研究が取り組まれている。Bag-of-features は、画像を局所特徴量の集合とみなし、局所特徴量のヒストグラムをその画像の特徴量としてカテゴリを識別する手法である。Csurka ら²⁾は、Bag-of-features に用いる局所特徴量にはアフィン変換に不変な特徴点³⁾を、識別器には SVM を用いる手法を提案している。また、Fei-Fei ら⁴⁾は、局所特徴量にグリッド点に対して SIFT 特徴量⁵⁾で記述し、識別器に generative model である LDA(Latent Dirichlet Allocation)を用いる手法を提案し、13 カテゴリの自然風景画像を約 64%で認識可能であることを報告している。

Bag-of-features では、画像特徴を局所特徴量のヒストグラムにより記述するため、局所特徴量の位置情報は利用しないアプローチである。近年では、Bag-of-features に局所特徴量の位置情報を考慮することによる認識精度の向上が試みられており、画像中の空間的な位置関係を記述する手法⁶⁾と画像中の前景領域から特徴量を記述する手法^{7),8)}が提案されている。局所特徴量の空間的な位置情報を記述する手法として、Lazebnik らは、位置を考慮

^{†1} 中部大学
Chubu University

し多重解像度ヒストグラムで表現する Spatial Pyramid Matching⁶⁾ を提案した。Spatial Pyramid Matching は、画像をグリッド分割し、その小領域単位の位置関係を記述することができる。一方、前景領域の局所特徴量を利用する手法として、Marcin ら⁷⁾ は、学習データのマスク画像を用いて、特徴量の関係から入力画像の前景領域に合わせて重み分布を求め、この重み分布を利用してベクトル量子化ヒストグラムを作成することで、背景情報を抑制する手法を提案した。また、鈴木ら⁸⁾ は、抽出された特徴量を SVM により前景と背景に識別し、前景特徴のみで特徴量を記述することで認識精度を向上させている。これらの前景領域から特徴記述する手法では、背景情報はノイズと考え、背景を除去し、前景のみで特徴量を記述することで認識率が向上するという考えに基づいている。しかしながら、一方では物体間の関係をコンテキストとして利用することで、認識精度を向上させる手法が報告されている⁹⁾。この場合の対象カテゴリでない物体は、従来手法では背景に属していることになる。このように、画像分類問題において、Bag-of-features がどのような特徴を捉え、有効に働くかは明確でないといえる。

そこで、本研究は Bag-of-features の前景と背景領域の特徴量を解析し、カテゴリ認識に有効な特徴量の調査を目的とする。前景領域を既知とし、画像全体から特徴量を抽出する手法、前景領域のみから特徴量を抽出する手法、前景領域と背景領域からそれぞれ特徴量を抽出する手法の認識率を比較する。AdaBoost の弱識別器でどのような特徴量が選択されているかを調査することで、前景情報と背景情報がどのように有効であるかを述べる。次に、調査により得られた結果から、前景と背景の局所特徴の共起性を用いた Bag-of-features 手法を提案し、その有効性を示す。

2. Bag-of-features と画像局所特徴量

本章では、Bag-of-features による物体認識について述べる。Bag-of-features は、文書分類手法である Bag-of-words¹⁰⁾ を画像に適用した手法であり、Bag-of-words で文章を単語の集合と見なし、単語の語順を無視してその頻度で文章の分類を行うのと同様に、画像を局所特徴量の集合と見なし、その位置情報を無視して画像を認識する。Bag-of-features では、図 1 に示すように、まずはじめに画像から局所特徴量の抽出を行い、ベクトル量子化する。ベクトル量子化に用いるコードブックを、visual word dictionary と呼び、予め学習画像から作成しておく。ベクトル量子化された特徴量を用いて、ベクトル量子化ヒストグラムを作成する。得られたベクトル量子化ヒストグラムをその画像の特徴量として、識別器に入力することで物体カテゴリを計算する。




図 1 Bag-of-features の流れ

Fig. 1 Overview of Bag-of-features.

2.1 局所特徴量の抽出

本稿では、局所特徴量に SIFT 特徴量⁵⁾ と textron 特徴量¹¹⁾ を用いる。

2.1.1 SIFT 特徴量

SIFT 特徴量⁵⁾ は、あるピクセルの代表輝度勾配方向を決定し、その方向を基準とした輝度勾配ヒストグラムを作成し、多次元ベクトルで特徴を記述する。はじめに、注目画素の代表輝度勾配方向を決定する。画像 $L(x, y)$ の輝度勾配方向 $\theta(x, y)$ と大きさ $m(x, y)$ は以下

の式により求められる.

$$m(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (1)$$

$$\theta(x, y) = \tan^{-1} \left(\frac{f_y(x, y)}{f_x(x, y)} \right) \quad (2)$$

このとき,

$$f_x(x, y) = L(x + 1, y) - L(x - 1, y) \quad (3)$$

$$f_y(x, y) = L(x, y + 1) - L(x, y - 1) \quad (4)$$

である. 輝度勾配の大きさ m を方向 θ を用いて, 各方向のヒストグラムを求める. このヒストグラムの最大値の方向をその位置での代表輝度勾配方向とする. この代表輝度勾配方向を基準とした周囲の輝度勾配ヒストグラムを作成する. 正規分布から得られる領域を 4×4 の領域に分割し, それぞれの位置で 8 方向の輝度勾配ヒストグラムを作成する. 4×4 の領域にそれぞれ 8 方向ヒストグラムを作成するため, 128 次元ベクトルの特徴量を持つことになる. SIFT 特徴量は, 画像のスケール変化, 回転変化, 輝度変化に対して頑健な局所領域の記述を行うことができるため, Bag-of-features の局所特徴に有効とされている.

2.1.2 texton 特徴量

texton 特徴量¹¹⁾ は, さまざまな種類, 方向, サイズのフィルタの応答を特徴量としたものであり, テクスチャを表現することができる. このとき, 各フィルタの集合を filter bank と呼ぶ.

本研究で使用する texton は, Winn ら¹²⁾ が用いた filter bank を使用する. Winn らは, ガウシアンフィルタ, LoG フィルタ, ガウシアン 1 次微分フィルタの応答から 17 次元の特徴量を得る. はじめに, 画像を RGB から CIE Lab 色空間に変換する. そして, 各チャンネルに対して, ガウシアンフィルタをかける. このとき, ガウシアンフィルタの σ は 1, 2, 4 の 3 種類用いる. そのため, ガウシアンフィルタに基づく特徴量は 9 次元になる. 次に, L チャンネルに対して, LoG フィルタをかける. このときのスケールは $\sigma = 1, 2, 4, 8$ の 4 種類用いる. そのほかのフィルタとして, ガウシアン x と y の各方向ごとの 1 次微分フィルタを用いる. このときのスケールは $\sigma = 2, 4$ の 2 種類用いるため, 4 次元の特徴量が抽出される. ガウシアンフィルタ 9 次元, LoG フィルタ 4 次元, ガウシアン 1 次微分フィルタ 4 次元の 17 次元の特徴量が抽出される. 図 2 に, texton 特徴量の抽出に用いられる filter bank を示す. texton 特徴量を Bag-of-features に用いることで, 画像中にどのようなテクスチャが多いかを表現することができる.






フィルタ	カラー	スケール
ガウシアン	L*	 $\sigma=1$ $\sigma=2$ $\sigma=4$
	a*	 $\sigma=1$ $\sigma=2$ $\sigma=4$
	b*	 $\sigma=1$ $\sigma=2$ $\sigma=4$
LoG	L*	 $\sigma=1$ $\sigma=2$ $\sigma=4$ $\sigma=8$
x 方向 1 次微分 ガウシアン	L*	 $\sigma=2$ $\sigma=4$
y 方向 1 次微分 ガウシアン	L*	 $\sigma=2$ $\sigma=4$

図 2 filter bank
Fig. 2 Filter bank.

2.2 ベクトル量子化ヒストグラムの作成

各カテゴリの画像から得られた局所特徴量をベクトル量子化する. Bag-of-features では, ベクトル量子化に用いられるコードブックを visual word dictionary, コードブックのセントロイドを visual word と呼ぶ. visual word dictionary は, 各カテゴリの学習サンプルから得られる局所特徴量をクラスタリングすることで得る. 本手法では, クラスタリング手法に k-means を用いる. 入力された局所特徴量がクラスタリングの結果, visual word dictionary のどのクラスタに属するかを計算することでベクトル量子化し, 1 枚の画像から visual word を要素とするヒストグラムを特徴量とする.

2.3 AdaBoost による識別

Bag-of-features における識別器には, 通常マルチクラス SVM が用いられる. 本稿では,




図 3 特徴抽出法

Fig.3 Feature extraction method.

識別に用いられる特徴量の解析が容易な AdaBoost¹³⁾ を識別器に利用する。AdaBoost 識別器は、対象カテゴリであるかないかの 2 クラスの分類しかできない。AdaBoost によるマルチクラス識別には、カテゴリごとに識別器を構築し、それぞれの識別器の応答の最大値からカテゴリを決定する。

3. Bag-of-features における有効な特徴量の調査

本章では、Bag-of-features において前景領域のみで特徴記述する手法と背景情報を含んだ特徴記述法の比較実験を行う。AdaBoost により選択された弱識別器の解析と、特徴量を可視化した結果から認識に有効な特徴量の傾向を調査する。

3.1 実験概要

Bag-of-features において、前景と背景がどのように捉えられているかを確認するために、以下の異なる特徴抽出手法の比較を行う。

- **画像全体** 画像全体から局所特徴量を抽出し、ベクトル量子化ヒストグラムを作成する (図 3(a)).
- **前景のみ** 抽出された局所特徴量の位置が前景領域内にある局所特徴量のみを用いてベクトル量子化ヒストグラムを作成する (図 3(b)).
- **前景/背景領域** 局所特徴量の位置により、前景領域と背景領域に分離し、それぞれの領域に対して、ベクトル量子化ヒストグラムを作成する (図 3(c)).

SIFT 特徴量と texton 特徴量から、これらの手法により特徴記述をし、AdaBoost により識別器を構築する。

評価には、画像分類のためのデータベースである Caltech256¹⁴⁾ を用いる。Caltech256 にはセグメンテーションデータがないため、各画像のセグメンテーション領域は手動により求めたものを使用する。すべてのセグメンテーションデータを用意することが困難なため、




図 4 各手法の認識率

Fig.4 Recognition rate.

Caltech256 から、画像枚数が多い butterfly, elephant, hawkbill, helicopter, motorbikes, airplanes, car-side, faces-easy, toad の 9 カテゴリを評価実験に用いる。各カテゴリから 30 枚ずつ選びそれらを学習用画像とし、残りを評価用画像とする。また、ベクトル量子化に用いる visual word dictionary のサイズは 100, 500, 1000 とする。識別器には AdaBoost を使用し、弱識別器の数を 100 とする。評価には、f-measure を用いる。

3.2 調査項目

本稿で調査する内容を以下に示す。

- **認識率から得られる有効な特徴の傾向** 各特徴抽出法の認識率を比較し、背景情報を利用する有効性を確認する。
- **背景情報の有効性** 学習データから得られるベクトル量子化ヒストグラムの visual word を調査することで、Bag-of-features において、前景と背景がどのように処理されているかを確認する。
- **選択された特徴量の可視化** 認識に利用された特徴量を可視化することで、画像上のどのような特徴量を利用しているかを確認する。

3.3 認識率から得られる有効な特徴の傾向

図 4 に、SIFT 特徴量と texton 特徴量を用いた画像全体から特徴記述する手法、前景のみから特徴記述する手法、前景と背景から特徴記述する手法の認識率を示す。はじめに、visual word 数の違いによる認識率の変化に着目する。図 4 より、SIFT 特徴量は visual word が 100 の前景と背景から特徴記述する手法で 0.49, texton 特徴量は visual word が 1000 の




図 5 ベクトル量子化ヒストグラム
Fig.5 Vector quantization histogram.

前景と背景から特徴記述する手法の 0.57 で認識率が最も高いことがわかる。SIFT 特徴量は、128 次元と局所領域の記述能力が高く、1 枚の画像から得られる局所特徴の数が少ないため、visual word の数が少なくても高い認識精度が得られたと考えられる。次に、特徴記述手法の違いによる認識率に着目すると、visual word の数に関係なく、前景のみで特徴量を記述するよりも、画像全体から特徴記述する手法は SIFT 特徴量で約 0.03, texton 特徴量で 0.07 認識精度が向上した。前景と背景から特徴記述する手法は、SIFT 特徴量で 0.07, texton 特徴量で 0.11 の精度向上が見られた。この結果から、前景のみで特徴量を記述した手法が最も認識精度が低く、背景にもカテゴリ分類に重要な情報が含まれているといえる。前景と背景から特徴記述する手法は、画像全体から特徴記述する手法や前景のみで特徴量を記述した手法と比較し、高い認識率を得ることができた。この手法で得られる特徴は、前景のみで特徴記述する手法に背景情報を加えた特徴であるため、背景情報を加えることで認識率が向上したといえる。以上より、Bag-of-features による画像分類では、前景情報だけでなく背景情報も認識に影響を与えていると考えられる。また、認識結果から前景と背景を分けて記述することは認識に有効であるといえる。

3.4 背景情報の有効性

次に、一般的な Bag-of-features である画像全体から特徴量を抽出する手法における有効な特徴量について調べる。この手法では、図 5 に示すように、ベクトル量子化ヒストグラムの各 visual word に前景と背景の特徴が混在しているため、弱識別器だけでは背景情報をどのように使用しているかを判断することが困難である。そこで、AdaBoost により選択されたベクトル量子化ヒストグラムの visual word に対し、学習データに前景と背景が混在




図 6 特徴量の比率
Fig.6 The ratio of selected features.

しているかを調査する。各識別器のポジティブデータ 30 枚と弱識別器数 100 から、選択される visual word の総数は 3000 個となり、その中で、前景のみで作成された visual word, 背景のみで作成された visual word, 投票がない visual word, 前景と背景の両方が混在した visual word の比率を求める。図 6 に、前景、背景、投票なし、混在した特徴の比率を示す。図 6 から、SIFT 特徴量と texton 特徴量ともに、前景と背景の特徴が選択されていることがわかる。この結果から、画像全体から特徴記述をしても、前景だけでなく背景情報も用いた認識を実現しているといえる。以上より、Bag-of-features では、前景と背景の情報を利用してシーン全体をモデリングしているといえる。そのため、前景のみで特徴量を記述した場合、背景情報であるシーンコンテキストが無視され認識率が低下したと考えられる。

3.5 選択された特徴量の可視化

AdaBoost の各弱識別器が、どのような位置情報を持つ特徴量を選択しているかを調査する。選択された特徴量を画像上に可視化することで、対象カテゴリに対する位置情報の傾向を確認する。visual word が画像中のどの位置から抽出された特徴なのかを調べることで、識別に使用されている特徴の位置情報を確認することができる。図 7, 8 に、選択された特徴量の可視化例を示す。ここで、可視化画像の輝度値は AdaBoost の弱識別器の重みを表現しており、輝度値が高いほど有効な特徴となる。SIFT 特徴量の可視化結果では、各カテゴリにおいて共通性が見られなかった。しかし、texton 特徴量の可視化結果においては、faces-easy では顔の頬等の内部のテクスチャを捉える特徴が多いが、その他のカテゴリは画



図 7 選択された特徴量の可視化例 1

Fig. 7 Example of visualization of select features.

像中のエッジを捉える特徴が多いことがわかる。そこで、エッジを捉えた特徴が多く選択されることを定量的に評価するために、Canny オペレータによりエッジを検出し、そのエッジからの距離に対して AbaBoost で選択される確率を図 9(a) に示す。また、選択されたエッジ上の特徴の位置が前景、背景、前景と背景の境界であるかを図 9(b) に示す。図 9(a) から、エッジに近いほど選択される確率が高くなることがわかる。そのため、texton による認識には、エッジ情報が有効であるといえる。また、図 9(b) から、選択されたエッジ特徴のうち前景と背景の境界付近の点が 10% 存在することがわかる。このような点は、前景と背景に分類することは困難であり、境界情報として別に記述する必要があると考えられる。

4. 前景と背景を用いた識別に有効な特徴記述

これまで、Bag-of-features において、前景と背景の特徴がどのように利用されているかを調査した。その結果、認識には前景特徴だけでなく背景情報も使用しており、Bag-of-features





図 8 選択された特徴量の可視化例 2

Fig. 8 Example of visualization of select features.

はシーン全体をモデリングしている手法であるということが判明した。これは、対象物体とその背景に関係があると考えられ、前景と背景の局所特徴の共起性を表現することで、認識精度の向上が期待できる。



(a) 選択された特徴量のエッジからの距離

(b) 選択されたエッジ特徴量の比率

図 9 選択された textron 特徴量のエッジからの距離とその種類
Fig. 9 The selected features to the distance from edge.




図 10 2次元ベクトル量子化ヒストグラムの作成
Fig. 10 Two-dimensional vector quantization histogram.

図 11 SIFT 特徴量による各手法の認識率
Fig. 11 Recognition rate.

4.1 前景と背景の共起性に着目した特徴記述

前景と背景のそれぞれの領域で有効とされる特徴量の共起性に着目することで認識率の向上が期待できる。前景と背景の共起性の表現には、図 10 に示すような 2 次元ベクトル量子化ヒストグラムを用いる。はじめに、前景の局所特徴と背景の局所特徴のペアを選択し、それぞれをベクトル量子化する。ベクトル量子化された局所特徴のペアを前景と背景を軸とした 2 次元空間に投票する。この 2 次元ベクトル量子化ヒストグラムを入力特徴とし、SVM により識別する。図 11 に、SIFT 特徴量による前景と背景の 2 次元ベクトル量子化ヒストグラムの結果を示す。図 11 より、visual word が 100 のとき、前景と背景から特徴量を抽出する手法より認識率が約 0.24、visual word が 500 のとき、約 0.26 向上させることがで




図 12 境界に着目した特徴記述

Fig. 12 Feature extraction using boundary region.

図 13 textron 特徴量による各手法の認識率
Fig. 13 Recognition rate.

きた。以上により、前景と背景の共起性を捉えることの有効性を確認した。

4.2 境界に着目した特徴記述

選択された textron 特徴量の可視化結果から、画像中のエッジが有効であることが判明した。ここで、エッジ特徴が有効とした場合、前景と背景の境界付近のエッジ情報は、セグメンテーション結果の少量の変化でも大きな影響を受ける。図 12 に示すように、物体と背景の境界を境界情報とし、前景、背景、境界の 3 つの領域から抽出することで、安定した特徴抽出が可能と考えられる。本稿では、前景と背景の境界からユークリッド距離が 15 以内の領域を境界の領域とした。textron 特徴量を用いて 3.1 章で述べた 3 種類の手法と前景、背景、境界の 3 つの領域から特徴量を抽出する手法を比較する。図 13 に、textron 特徴量による各手法の識別率を示す。図 13 より、前景と背景から特徴記述する手法と比較し、visual word が 100 のとき 0.03、500 のとき 0.02 認識率が向上した。しかし、visual word が 1000 のときは、認識率が 0.01 低下していることがわかる。これは、領域を 3 つに分けたことにより、ベクトル量子化ヒストグラムを作成するデータが分散し、十分なヒストグラムを作成することが困難となったためと考えられる。visual word が 100, 500 では、ヒストグラムを作成するデータ数が十分であったため、認識精度が向上したと考えられる。

5. おわりに

Bag-of-features における識別に有効な特徴量を実験的に検討した。前景領域を既知とし、画像全体から特徴量を抽出する手法、前景領域のみから特徴量を抽出する手法、前景領域と背景領域からそれぞれ特徴量を抽出する手法の認識率を比較した。その結果、すべての特徴

量と visual word で前景領域のみで特徴記述する手法は認識率が低下する傾向が見られた。また、前景と背景を分離して記述することで認識精度が向上することを確認した。次に、画像全体から特徴量を抽出する手法の弱識別器を調べた結果、前景と背景のそれぞれの情報を認識に使用していることがわかった。このことから、Bag-of-features では、前景と背景の情報を利用してシーン全体をモデリングしているといえる。上記の調査結果から、前景と背景の局所特徴の共起性に着目した 2 次元ベクトル量子化ヒストグラムを検討し、約 0.26 の精度向上を確認した。また、texton 特徴量において、識別に有効な特徴量を可視化した結果、エッジを表現する特徴が多く選択されていることがわかった。そこで、特徴を抽出する領域を前景、境界、背景の 3 つに分割し、それぞれの領域から特徴記述する手法を検討し、前景と背景から特徴記述する手法より認識精度を約 0.03 向上させることができた。

今後は、前景と背景の分離する手法を含めた物体認識手法を検討する予定である。

参 考 文 献

- 1) 柳井啓司：一般物体認識の現状と今後，情報処理学会論文誌. コンピュータビジョンとイメージメディア， Vol.48, No.16, pp.1-24 (2007).
- 2) Csurka, G., Dance, C.R., Fan, L., Willamowski, J. and Bray, C.: Visual categorization with bags of keypoints, *ECCV International Workshop on Statistical Learning in Computer Vision* (2004).
- 3) Mikolajczyk, K. and Schmid, C.: An Affine Invariant Interest Point Detector, *ECCV (1)*, pp.128-142 (2002).
- 4) Li, F.-F. and Perona, P.: A Bayesian Hierarchical Model for Learning Natural Scene Categories, *CVPR '05: Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05) - Volume 2*, Washington, DC, USA, IEEE Computer Society, pp.524-531 (2005).
- 5) Lowe, D.G.: Distinctive Image Features from Scale-Invariant Keypoints, *Int. J. Comput. Vision*, Vol.60, No.2, pp.91-110 (2004).
- 6) Lazebnik, S., Schmid, C. and Ponce, J.: Beyond Bags of Features: Spatial Pyramid Matching for Recognizing Natural Scene Categories, *CVPR '06: Proceedings of the 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Washington, DC, USA, IEEE Computer Society, pp.2169-2178 (2006).
- 7) Marszałek, M. and Schmid, C.: Spatial Weighting for Bag-of-Features, *IEEE Conference on Computer Vision & Pattern Recognition*, Vol.2, pp.2118-2125 (2006).
- 8) 鈴木浩二, 松川 徹, 栗田多喜夫：サポートベクターマシンを用いた Bag-of-Features における局所特徴の初期特徴選択, 電子情報通信学会パターン認識・メディア理解研究会, PRMU2008-240, pp.7-12 (2009).
- 9) 岡部孝弘, 近藤雄飛, 木谷クリス真実, 佐藤洋一：カテゴリの共起を考慮した回帰による複数物体認識, 電子情報通信学会論文誌, Vol.92-D, No.8, pp.1115-1124 (2009).
- 10) Manning, C.D. and Schütze, H.: *Foundations of Statistical Natural Language Processing*, The MIT Press (1999).
- 11) Leung, T. and Malik, J.: Representing and Recognizing the Visual Appearance of Materials using Three-dimensional Textons, *Int. J. Comput. Vision*, Vol.43, No.1, pp.29-44 (2001).
- 12) Winn, J., Criminisi, A. and Minka, T.: Object Categorization by Learned Universal Visual Dictionary, *ICCV '05: Proceedings of the Tenth IEEE International Conference on Computer Vision*, Washington, DC, USA, IEEE Computer Society, pp.1800-1807 (2005).
- 13) Freund, Y. and Schapire, R.E.: A decision-theoretic generalization of on-line learning and an application to boosting, *EuroCOLT '95: Proceedings of the Second European Conference on Computational Learning Theory*, London, UK, Springer-Verlag, pp.23-37 (1995).
- 14) Griffin, G., Holub, A. and Perona, P.: Caltech-256 Object Category Dataset, Technical Report 7694, California Institute of Technology (2007).