

一般物体認識に適した visual word の作成法

西村 朋己[†] 呉 海元[†] 和田 俊和[†]

[†] 和歌山大学システム工学部, 和歌山市栄谷 930

E-mail: †nishimura@vrl.sys.wakayama-u.ac.jp, ††{wuh,y,twada}@sys.wakayama-u.ac.jp

あらまし 制約の無い一般的な画像から対象物体の名称や領域などを認識する一般物体認識は、コンピュータビジョンの究極の課題の1つである。この分野の現在の主流な手法として局所特徴 (Bag of Feature or BoF) + 認識モデルの構築 (pLSA, SVM, ... etc) がある。認識精度を向上するために、新しい認識モデルの構築法等が次々と提案されてきている。様々な認識方法で共通して良く用いられる局所特徴の抽出部分では、現在主流として用いられている方法として、ランダムやエッジ、グリッド等を用いた中心点検出+ランダムスケール設定+ SIFT 特徴量記述といった方法が挙げられる。しかし、この方法では特徴点を中心とした周辺スケールに一致するような保障は無く、認識結果に悪影響があるのではないかと考えられる。そこで本論文では、一般物体認識に適した局所特徴の中心点とそのスケールを探す方法について考察する。共通のデータベースを用いて、提案手法の有効性を確認した。

キーワード 一般物体認識, 特徴量抽出, SVM, pLSA, SIFT 特徴量

Generating method of visual word for generic object recognition

Tomoki Nishimura[†], Wu HAIYUAN[†], and Toshikazu WADA[†]

[†] Wakayama University system department of engineering, 930, Sakaedani, Wakayamashi

E-mail: †nishimura@vrl.sys.wakayama-u.ac.jp, ††{wuh,y,twada}@sys.wakayama-u.ac.jp

Abstract Generic object recognition aims at enabling a computer to recognize objects on non-constraint general images with their category names, which is one of the ultimate problems in computer vision research. Current main techniques in this field are generation of local feature (Bag of Feature or BoF) + construction of understanding model (pLSA, SVM, ... etc). To improve the recognition accuracy, many new methods for understanding model construction have been proposed. In respect to local feature extraction that is commonly used in many recognition methods, The center points of feature are detected by using random selection or edge points or grid, and their scale information are given by random. Then the SIFT feature vectors are calculated by SIFT feature descriptors. However, there is not indemnity to conform neighboring scale on the feature points, and this may affect the recognition result adversely. In this paper, we study the method to determine the center and the scale of local feature that are appropriate to generic object recognition. The effectiveness of the proposed technique was confirmed by using the common data base.

Key words General object recognition, detection of feature vector, SVM, pLSA, SIFT feature vector

1. はじめに

伝統的な画像認識に関する研究では特定の制約の下で撮影された画像を認識対象としてきた。これとは違い、「一般物体認識」とは、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である。近年、デジタルカメラの普及やハードディスクの大容量化によって、一般の個人が大量のデジタル画像を蓄積できるようになった。しかし、計算機が画像の意味を理解することができないため、画像の取り扱いに関する人間と計算機のセマンティックギャップ

は狭まることは無く、現状では大量の画像データの分類や検索には人の手の介入が必要不可欠である。一般物体認識はこのような視覚情報処理におけるセマンティックギャップの解消のための技術として期待されている。たとえば、画像に対する自動キーワード付けや、画像の意味内容に関する分類や検索が可能になると考えられる。また、一般物体認識は、機械による人間の認識機能の実現というサイエンス的な観点からみても興味深い研究といえる。

しかし、一般物体認識は画像認識の研究において最も困難な研究課題の1つである [1]。これは、制約の無い画像における

「一般的な名称」が表す同一クラスの範囲が広く、同一クラスに属する対象のアピアランスの変化が極めて大きいので、対象の特徴量抽出、認識モデルの構築、学習データセットの構築、それぞれ難しいからである。

近年一般物体認識は、part-based と呼ばれる新しい物体表現法の登場、機械学習方法の進歩、計算機の高速度大容量化等により、急速に進歩をとげてきている。最新の研究では、局所特徴量を簡単に利用する方法である bag of Features(BoF) [2]、局所特徴量に文書分類のための確率的トピック認識法である Probabilistic Latent Semantic Analysis(pLSA) を組み合わせた研究 [6] [7]、判別モデル Support Vector Machine(SVM) を利用する研究 [3] [4] [5]、物体同士の空間コンテキストを利用する研究 [8] [9] などが行われている。最近日本で研究発表された認識手法として、星座モデルを取り入れた手法 [10] がある。このような星座モデルといった局所領域の特徴とその位置関係を用いる方法では、画像内の対象のポーズに制限があるほど高い認識率が得られている。しかし、制限をかけると一般性は失ってしまう。

以上より、現在一般物体認識の主流研究では、BoF+認識モデルの構築法を用いている。我々は、認識精度を向上するためには、認識モデルの構築が重要でありながら、よい局所特徴の獲得も同様に重要であると考え。通常、一般物体認識では、共通データセット [11] [12] などを用いた際の認識率をもって他の認識手法との比較を行うことが多い。同じ共通データセットと同じ認識モデルを用いても抽出される局所特徴（例えば、ランダム、エッジ、グリッド）の違いにより認識率は変化することを知られている。一番良く用いられる局所特徴の抽出部分では、ランダムやエッジ、グリッド等を用いた中心点検出+ランダムスケール設定+ Scale Invariant Feature Transform(SIFT) 特徴量記述 [13] といった方法が挙げられる。しかし、この方法では設定されたスケールと、検出された特徴点を中心とした周辺スケールに一致するような保障はない。

そこで本論文では、よい局所特徴の獲得法に焦点を与え、一般物体認識に適した局所特徴中心点の検出法と、特徴中心点周辺のスケールの探索法について考察する。

本論文では、第2章で関連アルゴリズムについて簡単に述べる。第3章で従来の特徴量抽出法の問題点と提案手法について述べる。第4章では実験とその考察について述べる。第5章では全体のまとめについて述べる。

2. 関連アルゴリズム

2.1 認識モデル (pLSA)

BoFを用いることによって、統計的言語処理の分野で提案された確率的な手法が応用可能になった。その一つが、文書分類のための確率的トピック抽出の手法として提案された pLSA である。これは、学習情報として単語とトピックの関係を把握しておき、文章中にどのような単語がどれだけ含まれているかを調べることで、文章全体のトピックスを推定する方法である。画像の分野では、文章全体を画像とし、トピックスをクラス名とし、単語を局所特徴とするように置き換えることで適用する

ことができる。つまり、画像における各物体の出現確率を求め、その中で最大確率となるものを探することで認識を行う。

具体的には、学習画像から局所特徴を抽出しクラスターリングを行い visual words (単語) を作成する。学習モデルと画像とラベルの関係は以下の様に求められる。

$$P(w_i | d_j) = \sum_{k=1}^K P(w_i | z_k) P(z_k | d_j) \quad (1)$$

ここで、ラベルを z 、その数を K 個、visual words を w 、その数を N 個、画像を d 、その数を M で表す。この時の $P(w | d)$ は、EM アルゴリズムを用いて尤度 L が最大のものを選ぶ。

$$L = \prod_{i=1}^M \prod_{j=1}^N P(w_i | d_j)^{n(w_i | d_j)} \quad (2)$$

さらに、 $P(w | d)$ を分解して visual words とラベルの関係性を示す $P(w | z)$ を得ることができる。作成した確率モデルによって表現される生成モデルを認識モデルとして用いる。

最終的に、認識クラスの判別は、ラベル未知の画像と visual word の関係調べることで画像における各クラスの出現率

$$Z = \operatorname{argmax}_z P(z | d) \quad (3)$$

を求め、所属のクラスを判定する。

2.2 認識モデル (SVM)

SVM は、特徴空間に分布している局所特徴を分類する境界面を求める判別モデルである。少ないデータより汎用性のあるモデルを作れるので、認識モデルとしてよく使われている。

2クラス認識においては、データを2種類に分類するために、各特徴点との距離が最大となる分離境界面を求めるマージン最大化という考え方をしている。一般物体認識では、各クラスの画像から得た特徴等を visual words として考え、visual words の分類を考える。また、その境界面は以下の関数で表される。

$$D(x) = w^T g(x) + b \quad (4)$$

ここでは、 w は1次元ベクトル、 $g(x)$ は x を1次元特徴空間に写像する写像関数、 b は定数項を示す。

多クラス認識においては全クラス中から2クラスを選び、その識別境界を求める one against one と、ある1クラスとその他のクラスの識別境界を求める one against all がある。いずれも複数の境界面を組み合わせで分類を行うが、 N クラスでの認識を行う場合前者では、 ${}_N C_2$ 個、後者では N 個の境界面が識別の為に必要となる。認識方法を簡単に説明すると、ラベル未知の画像から抽出した局所特徴を (4) の式に当てはめることで、識別境界面のどちら側に分類されるのかを調べる。全ての局所特徴について同様に調べ最も多く分類されたクラス名をラベル未知の画像のラベルとする。

2.3 SIFT

SIFT は、特徴検出と特徴量記述を行う2段階のアルゴリズムである。特徴検出では、特徴点検出とスケールの決定を行う。特徴量記述では、特徴点のスケール、及びオリエンテーションを用いて、周辺領域を定義し、その周辺領域が持つ勾配情報を用いて特徴量を求める。




図1 DOGによるスケールスペース構築

2.3.1 SIFTの特徴検出

特徴検出段階では、図1に示すように、スケールの異なる平滑化画像間の差分処理であるDOG(Difference of Gaussian)を行、DOG画像の極値を検出し、特徴点とする。入力画像を $I(x, y)$ 、ガウス関数を $G(x, y, \sigma)$ 、平滑化画像を $L(x, y, \sigma)$ とした時、DOG画像 $D_i(x, y, \sigma)$ は次のように求められる。

$$L(x, y, \sigma) = G(x, y, \sigma) \times I(x, y) \quad (5)$$

$$G(x, y, \sigma) = \frac{\sqrt{2\pi}\sigma^2}{1} \exp\left(\frac{2\sigma^2}{-(x^2 + y^2)}\right) \quad (6)$$

$$D_i(x, y, \sigma) = L(x, y, \sigma_{i+1}) - L(x, y, \sigma_i) \quad (7)$$

上のような処理で、スケールを変化させてDOG画像 $D_i(x, y, \sigma)$ を求め、図1のようなDOG画像のスケールスペースを構築し、DOG画像から極値の検出を行い、キーポイント(特徴点)を求める。また、このとき極値となるDOG画像のスケールを特徴量記述の段階に用いる。

2.3.2 SIFTの特徴量記述

特徴量記述の段階では、特徴検出の段階で決定した各局所領域の平滑化画像の各画素の勾配 $m(x, y)$ と $\theta(x, y)$ 勾配方向を以下のように求める。

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

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

$$\begin{cases} f_x(x, y) = L(x+1, y) - L(x-1, y) \\ f_y(x, y) = L(x, y+1) - L(x, y-1) \end{cases} \quad (10)$$

求めた勾配 $m(x, y)$ の大きさと勾配方向 $\theta(x, y)$ から、図2のように36方向の重み付方向ヒストグラムを作成する。作成したヒストグラムの最大値の80%以上となる方向をキーポイントのオリエンテーションとする。なお、80%以上のピークが複数ある場合、それら全てをオリエンテーションとして割り当てる。また、その様子を図2にて表す。

まず、図3(a)のようにキーポイントの周辺の領域を割り当てられたオリエンテーション方向に回転することによって、キーポイントの向きに合わせて特徴量を記述でき、回転に対する不変性を得られる。次に、図3(b)のようにガウス窓を用いて中

心付近が重くなるように重み付けることによって、スケール変化に対する不変性を得られる。この時のガウス窓の大きさは、キーポイントが検出されたDOG画像の平滑化スケールにより決定する。最後に、図3(c)のように定めた周辺領域を 4×4 の16個に分割し、各領域で8方向の輝度勾配ヒストグラムを求める。輝度勾配ヒストグラムはオリエンテーションを求めるときと同じ方法で計算する。このようにして、 $4 \times 4 \times 8 = 128$ 次元のSIFT特徴量を記述できるようになる。




図2 オリエンテーションの割り当て




図3 特徴量の記述

3. 一般物体認識に適した局所特徴量の決定

3.1 従来的特徴量抽出法の問題点

現在、一般物体認識での特徴量取得方法として最も良く使われている手法は、局所領域の中心点の位置とその周辺領域の大きさを決定した後、SIFTでその特徴点周辺の特徴量を記述するといった手法である。

SIFTの特徴抽出の段階では、キーポイントによって、開口問題が発生しやすいものがあるので、コントラストの低い点やエッジ上のキーポイントを削除し、より頑健なキーポイントを選択するように工夫している。しかし、このような処理のせいで、認識物体の特徴表現に必要な点(局所領域の中心点)が得られなくなる。この問題を解決するために、局所領域の中心点の位置はSIFTの特徴検出結果を使わず、以下のような方法で選択する：

- (1) 画像からランダムに一定の点数
- (2) 画像をグリッド分割してできた領域の中心
- (3) Canny等の方法で検出したエッジから一定の点数



図4 実験に使用する画像データ例 (Caltech101 データセットより)

一方、これらの方法で選択された局所領域の中心点の周辺のスケール情報が分からないので、10~30 画素といった様に範囲を指定しておき、その範囲の中でランダムにスケールを決定する方法が一般的に用いられる。

以上の方法で選択された局所領域の位置とランダムに決定されたスケールを SIFT の特徴量記述の部分を用いて、128 次元の特徴量を記述する。

しかし、このような方法では、ランダムに与えられたスケールの情報は局所領域の中心位置の周辺情報に一致するような保障は無いので、正しい局所特徴量が得られない可能性が高く、認識結果に悪影響があると考えられる。

3.2 提案手法

本論文では一般物体認識に適した局所特徴点の位置とその点の周辺のスケールの決定法について考察する。

基本的な考え方として、画像からエッジが得られる所ならびにその付近に認識対象の輪郭や内部の模様など情報が保持しているはずなので、対象物体を表現するのに有用な特徴点であり、正しく積極的にそこの特徴量を獲得すべきである。そのために、その特徴点付近のスケール情報もできるだけ正確に獲得すべきである。

そこで、提案手法の局所特徴点の決定は、SIFT の特徴検出段階を用いてキーポイントの位置とその周辺領域のスケールを検出する。得られたキーポイントから画像のエッジ点との最短距離を求め、閾値以下の付近の点を一般物体認識に用いる局所領域の中心点として $n(= 200)$ 個選択し、残りの点を捨てる。また、閾値は次の式で求める。 $w(= 15)$ を重みとする。

$$w \times \max(\text{image_height}, \text{image_width}) / n \text{ (pixel)} \quad (11)$$

そして、提案手法のスケールの決定は、選択された特徴点ごと、SIFT の特徴点検出の段階で得られたスケールを用いる。このように、提案手法では画像や対象の大きさの違いによるスケール変化による不変性を得ることができる。

4. 実験

4.1 実験方法

提案手法の有効性を確認するために、特徴量取得の手法を第3章で説明した2通りの

表1 実験に使用する画像のクラス名とその枚数

クラス名	Face	Leopard	Motorbike	airplane	guitar
画像数	435	200	798	800	75
クラス名	piano	menorah	revolver	scorpion	stop_sign
画像数	99	87	82	84	64

(a) 従来の一般的な方法 (BoF_{old}): Edge 位置決定+ランダムスケール+ SIFT での特徴量記述

(b) 提案手法 (BoF_{pro}): SIFT+Edge での位置・スケール決定で BoF の記述を行った。

それぞれの特徴点の取得方法による認識率が異なることを確かめるために、BoF を用いた一般物体認識の手法である以下の2種類の手法、

(1) 文書分類のための手法である pLSA

(2) 分類器のひとつである SVM

を利用し、それぞれ認識率の比較を行った。

最終的に、認識手法 (1 と 2) と特徴量取得法 (a と b) を組み合わせた4種類の方法で比較実験を行った。さらに、2クラス分類と N クラス分類の評価実験を行った。学習画像とテスト画像は毎回変更し、10 回実験を行いその平均認識率で評価を行った。

4.2 実験条件

実験には共通データセット Caltech-101 を用いた。Caltech-101 では 101 種類の画像セットが各クラス 31 枚から 800 枚の画像で構成されているので、モデル作成のための学習データ数は各カテゴリからランダムに選択した 30 枚とし、残りの画像を各カテゴリの評価画像とした。実験に使用する画像のクラス名とその枚数は表 1 に示し、その画像の例を図 4 に示す。対象画像中の物体は向きの変りがあり、見え隠れもある。

今回の比較実験では、従来手法の特徴抽出を行う時、中心位置の決定は Canny を用いてエッジ検出を行い、そこから 200 個選択したものとし、スケールを範囲 10~30 画素からランダムに選ぶ方法で行った。さらに、全学習画像から抽出した特徴数万個に対して k-means クラスタリングを行い、 $k = 200$ 個の visual words を得る。このクラス数 k の数は過去発表された研究論文の実験結果から選定されたものとなっている。

本実験では BoF+pLSA の手法では Li Fei-Fei 氏の web 上で公開されているプログラム [14]、BoF+SVM の手法では台湾大学の Linlibsvm らによって作られた LIBSVM [15] を参考にしました。本論文の手法では SVM のカーネル関数を多項式とする。つまり識別境界面を非線形で表す。

また、提案手法の特徴抽出を行う時、各画像から抽出される局所特徴の数 $n = 200$ 個を目安とした、その前後の数としている。

4.3 実験結果

4.3.1 2クラスでの評価実験

認識結果を表 2, 3 に示す。表の横軸である 2 クラスの認識率の平均を総合認識率とし、その値で評価比較を行う。

BoF+pLSA の手法では、従来手法の特徴量取得法の総合認

表 2 2クラス分類の比較 (Leopard と BACKGROUBND)(単位%)

	Leopard	BACKGROUBND
pLSA + BoF _{old}	49.0	60.0
pLSA + BoF _{pro}	95.0	95.0
SVM + BoF _{old}	97.2	63.4
SVM + BoF _{pro}	79.9	71.1

表 3 2クラス分類の比較 (Face と BACKGROUBND)(単位%)

	Face	BACKGROUBND
pLSA + BoF _{old}	63.6	64.0
pLSA + BoF _{pro}	92.8	93.2
SVM + BoF _{old}	79.0	71.7
SVM + BoF _{pro}	82.6	69.5




図 5 pLSA + BoF_{old} の confusion matrix




図 6 pLSA + BoF_{pro} の confusion matrix




図 7 SVM + BoF_{old} の confusion matrix




図 8 SVM + BoF_{pro} の confusion matrix

表 4 10クラスでの実験におけるクラス名とクラス番号の対応関係

クラス番号	1	2	3	4	5	6	7	8	9	10
クラス名	Face	Leopard	Motorbike	airplane	guitar	piano	menorah	revolver	scorpion	stop_sign

表 5 10クラス分類の総合認識率 (単位%)

	総合認識率
pLSA + BoF _{old}	14.074
pLSA + BoF _{pro}	22.037
SVM + BoF _{old}	65.913
SVM + BoF _{pro}	67.372

認識率は表 2 の組み合わせでは 54.5%で、表 3 の組み合わせでは 63.8%、提案手法の総合認識率では表 2 の組み合わせでは 95.0%で、表 3 の組み合わせでは 93.0%であった。

BoF+SVM の手法では、従来手法の特徴量取得法での総合

認識率は表 2 の組み合わせでは 80.269%で、表 3 の組み合わせでは 75.354%で、提案手法の総合認識率では表 2 の組み合わせでは 75.499%で、表 3 の組み合わせでは 76.075%であった。

これらから、pLSA という認識方法を用いた場合、提案手法の局所特徴量の生成法が断然に有効であること確認できた。また、SVM という認識方法を用いた場合、従来手法で得られた局所特徴量での認識率は pLSA の方法より確実に向上することが確認できた。

4.3.2 10クラスでの評価実験

認識結果を図 5, 6, 7, 8 に示す。図では縦、横クラス番号

を表すコンフージョンマトリックスで示す。図中番号とクラス名は表4にその対応を示している。図の見方としては、縦軸のクラスの画像に対して認識を行った結果、そのクラスの画像が各クラスにどれ位の割合で認識されたかを横軸に示している。また、認識率を色によって表している。真っ白が認識率100%、真っ黒が認識率0%を表し、白いほど認識率が高いことを示している。

また、各クラスの画像の真値に対する確率の平均を総合認識率とし、表5に示す。この値で各手法の比較、評価を行う。BoF+pLSAの手法では、従来手法の特徴量取得法での総合認識率は14.074%で、提案手法での総合認識率は22.037%であった。BoF+SVMの手法では、従来手法の特徴量取得法での総合認識率は65.913%で、提案手法での総合認識率は67.372%であった。これらから、BoF+pLSA、BoF+SVMの手法において、10クラス分類では提案手法の方がそれぞれ7.964%、1.930%高く、その効果が確認できた。これらの結果から、一般物体認識における提案手法に有効性があると考えられる。また、BoF+pLSAとBoF+SVMでの認識では、BoF+SVMでの認識方法の方が総合認識率が高いことが認められた。

5. まとめ

本論文では、一般物体認識における局所特徴の獲得方法に注目し、より良い visual words を獲得する為の方法を提案した。その結果、従来の特徴量取得の方法と比べその有効性が確かめられた。特徴の位置とスケールの大きさを調整することで、画像によって異なる写り方をしている対象から類似した特徴を抽出しやすくなったことにより、一般物体認識に有効な効果を及ぼすことができたのではないかと考えられる。

星座モデルといった位置関係の情報を用いる手法では対象のアピアランス等に制約がかかっていたら、高い認識率が得られると報告している。今回の手法はそのような手法に適用できるだけでなく、画像に制約をかけない「真」の一般物体認識の場合でも高い認識率を獲得することを期待できると考えられる。

今後、101クラスの実験と他の共通データベースを用いた実験を行う予定しています。また、よりよい局所特徴生成方法に関してさらに研究を進めたいと考えている。

文 献

- [1] 柳井啓司, 一般物体認識の現状と今後, 情処学論, vol.48, no.SIG 16(CVIM), pp.1-24, Nov. 2007.
- [2] Csurka, G.: Bray, C., Dance, C. and Fan, L.: Visual categorization with bags of keypoints, Proc. ECCV Workshop on Statistical Learning in Computer Vision, pp.1-22, 2004.
- [3] K.Grauman, and T. Darrell, The pyramid match kernel: discriminative classification with sets of image features, Proc. IEEE Int. Conf. on Computer Vision, vol.2, pp.1458-1465, 2005.
- [4] M.Varma, and D.Ray, Learning the discriminative power invariance trade-off, Proc. IEEE Int. Conf. on Computer Vision, 2007.
- [5] J.Zhang, M.Marszalek, S.Lazebnik, and C.Schmid, Local features and kernels for classification of texture and object categories: A comprehensive study, Int. J. of Computer Vision, no.2, pp.213-238, 2007.
- [6] Horfmann, T.: Unsupervised Learning by Probabilistic Latent Semantic Analysis, Machine Learning, Vol.43, pp.177-196, 2001.
- [7] Fergus, R., Fei-Fei, L., Perona, P. and Zisserman, A.: Learning Object Categories from Google's Image Search, Proc. IEEE International Conference on Computer Vision, pp.1816-1823, 年???
- [8] Torralba, A., Murphy, K. and Freeman, W.T.: Using the Forest to See the Trees: A Graphical Model Relating Features, Objects and Scenes, Advances in Neural Information Processing System, 2003.
- [9] Hoiem, D., Efros, A.A. and Hebert, M.: Putting Objects in Perspective, Proc. IEEE Computer Vision and Pattern Recognition, pp.2137-2144, 2006.
- [10] 神谷 保徳, 高橋 友和, 井手 一郎, 村瀬 洋: 一般物体認識におけるマルチモーダル星座モデルの提案 (MIRU 2008) pp.210-216, 2008.
- [11] Caltech-101: http://www.vision.caltech.edu/Image_Datasets/Caltech101
- [12] Caltech-256: http://www.vision.caltech.edu/Image_Datasets/Caltech256
- [13] 都築 勇司, 藤吉 弘巨, 金出 武雄: SIFT 特徴量に基づく Mean-Shift 探索による特徴点追跡 (CVIM 2007) pp. 101-108.
- [14] <http://people.csail.mit.edu/torralba/shortCourseRLOC/index.html>
- [15] <http://www.csie.ntu.edu.tw/%7Eejlin/libsvm/>