

## 特定物体認識のためのデータベース容量削減法の検討 局所特徴量の量子化と取捨選択

本道 貴行<sup>†</sup> 黄瀬 浩一<sup>†</sup>

<sup>†</sup> 大阪府立大学大学院 工学研究科 〒599-8531 大阪府堺市中区学園町 1-1  
E-mail: †hondo@m.cs.osakafu-u.ac.jp, †kise@cs.osakafu-u.ac.jp

あらまし SIFT(Scale-Invariant Feature Transform)などの局所特徴量を用いて、大規模特定物体認識を行う場合には、データベースに保持しておく局所特徴量(特徴ベクトル)の数が増大する。そのため、メモリ容量の削減が課題となる。本稿では、局所特徴量のベクトル量子化の手法と、取捨選択の方法によって、メモリ容量の削減を試みる。実験の結果、ベクトル量子化では、好ましい結果は得られなかった。一方、局所特徴量の取捨選択では、スケール耐性を犠牲にすることにはなるものの、入力画像のスケールがおおよそ決まっていれば、無削減のデータベースの1/10程度にしても、認識率はほとんど変化しないことが分かった。

キーワード 局所特徴量, 大規模特定物体認識, メモリ削減, ベクトル量子化, k-means 法

## Inspection of Memory Reduction Methods for Specific Object Recognition Approaches by quantization and Selection of Local Features

Takayuki HONDO<sup>†</sup> and Koichi KISE<sup>†</sup>

<sup>†</sup> Graduate School of Engineering, Osaka Prefecture University  
1-1 Gakuen-cho, Naka, Sakai, Osaka, 599-8531 Japan  
E-mail: †hondo@m.cs.osakafu-u.ac.jp, †kise@cs.osakafu-u.ac.jp

**Abstract** In case of conducting large-scale specific objects recognition using local features such as SIFT, the number of local features increases. Hence, reduction of the memory utilization is an important issue. In this report, we attempt memory reduction with two approaches; one is a method using vector quantization, and the other is one using selection of local features. From experimental results, we confirm that good results could not be acquired by vector quantization. On the other hand, if we employ feature selection as the method, the recognition rate hardly decreases with a database whose size is 10% of its original.

**Key words** Local feature, large-scale specific object recognition, memory reduction, vector quantization, k-means

### 1. はじめに

特定物体認識(specific object recognition)とは、画像に写っている物体が、どの物体とまったく同じなのかを言い当てる処理のことである。このような処理は、部品の過不足の検出や、偽造品などの検出、バーコードなどの代替などへの用途が考えられ、実用性が高いといえる。

特定物体認識の一手法として、局所特徴量(local feature)を用いる手法がある。この手法は、画像から抽出される局所特徴量(特徴ベクトル)で画像を表現し、特徴ベクトルを比較することにより、認識・識別を行うものである。局所特徴量

の例として、SIFT(Scale-Invariant Feature Transform)[1]や、PCA-SIFT(Principal Component Analysis-SIFT)[2]などがある。この手法の利点は、画像上から特徴ベクトルを局所的に複数抽出するため、多少の隠れや変動があっても、高精度で認識ができる点にある。

1枚の画像から抽出される局所特徴量の数は、VGAサイズの場合で、数千程度、多い場合には数万にもなる。そのため、認識対象の画像を大規模化した際には、これらの局所特徴量の照合に要する処理時間や、記憶に必要となるメモリ容量が問題となる。

これらの問題を解決するため、野口らは、個々の局所特徴量

の記録に必要なメモリ容量を削減するというアプローチを採用している [3]。具体的には、局所特徴量の各次元の記録に必要なビット数を削減し、個々の局所特徴量を記録するのに要するメモリ量を減らすことで、全体のメモリ容量を削減している。この手法は、事前に各次元の値の分布を調べておくことにより、量子化を比較的簡単に行うことができるというメリットがある。これに対して、ベクトル量子化という概念も提唱されている。D.Nistér らは、ベクトル量子化の方法の1つとして、Vocabulary Tree を使ったものを提唱している [4]。しかしながら、この手法では高い認識率を維持するために、木の高さを高くしなければならず、削減効果が十分に見込めないという問題点もある。

本稿では、認識のために必要なデータベースの容量の削減を、ベクトル量子化と、局所特徴量の取捨選択の観点から考察する。ベクトル量子化は、kd-tree を構築する際に特徴空間を分割する方法を用いて、特徴空間を分割し、分割された空間に存在する点の重心ベクトルを用いることで行う。局所特徴量の取捨選択は、特徴量のスケールと、画像空間上での分布を考慮して行う。実験の結果、ベクトル量子化の方法では、野口らの方法に匹敵する結果を得ることができなかつたが、局所特徴量の取捨選択では、無削減状態の10%程度のデータベースを用いた場合においても、98%の認識率を得ることができた。

## 2. 従来の削減法

本節では、特定物体認識に対して行われている従来の削減法と認識方式について述べる。

野口らは、特定物体認識に必要なメモリ容量を削減するため、スカラー量子化というアプローチをとっている。これは、個々の局所特徴量（特徴ベクトル）の各次元の取り得る離散値を制限することによって、メモリ容量の削減を実現するものである。データベースに登録する局所特徴量の数は、変わらないものの、個々の容量が小さくなるため、使用メモリが削減される。

野口らは、PCA-SIFT 特徴量の各次元を 2bit で表現しても、認識率はほとんど変化しないと述べている。特徴量の各次元を short 型整数で表現した場合、16bit で表現される。従って、特徴ベクトル単体では、1/8 程度の容量となり、その他の必要な容量を考慮したトータルでも 1/3 程度になることを述べている。

認識には投票方式を用いている。検索質問画像から抽出した局所特徴量を、データベース中の局所特徴量と距離計算を行い、近傍となったベクトルに付与されている画像 ID に投票する。そして、最大得票を得た画像を、認識結果として出力する。

## 3. 検討する手法

### 3.1 特定物体認識に適用できるメモリ削減法

従来手法として挙げたスカラー量子化以外で、データベースの容量削減方法の可能性として、どのようなものが考えられるであろうか。その可能性のある手法として、一般物体認識によく使われているベクトル量子化や、特徴ベクトルの取捨選択を行うことが挙げられる。ベクトル量子化を特定物体認識に適用することにより、認識率を落とさずに、メモリ削減をすること

が可能であろうか。また、局所特徴量の取捨選択をして、データベースに登録する局所特徴量を減らすことで、認識率を落とさずにメモリ削減ができるであろうか。

本稿では、このような従来とは異なったアプローチを用いて、認識率を保ったまま、メモリ容量を削減する方法について検討する。

### 3.2 ベクトル量子化の容量削減

#### 3.2.1 ベクトル量子化の方法

ベクトル量子化では、特徴空間上の一定領域に分布している特徴ベクトルをまとめることによって行う。そのため、何らかの方法により、特徴ベクトルをどのようにしてまとめるのかを定める必要がある。本稿では、以下のようにして、特徴ベクトルをまとめることにする。まず、kd-tree を作成するとき用いられている、standard kd-tree splitting rule を用いて特徴空間を分割する。これは、特徴空間上で、最も分散が大きい次元を選択し、その次元上に分布している点の座標の中央値で、空間を分割する方法である。分割空間に含まれる特徴ベクトルの最大数（バケットサイズ） $b$  を設定し、各空間内に含まれる特徴ベクトルの数を、 $b$  以下になるまで分割する。そして、分割された特徴空間に分布している特徴ベクトルの重心を求め、その空間上の特徴ベクトルを重心ベクトルに置換する。データベース中には、重心ベクトルを記録すると共に、置換した特徴ベクトルに付与されていた画像 ID を、この重心ベクトルに付与し直すことで、ベクトル量子化を行う。

この重心ベクトルが、ベクトル量子化の codeword（符号語）に相当するものであり、しばしば visual word と呼ばれる。

#### 3.2.2 認識方式

認識法の違いによる影響を調べるため、認識方式として、投票方式とベクトル空間法の2つを用いる。

まず、投票方式について述べる。検索質問画像から抽出した特徴ベクトル  $q_i$  が、データベース中にある特徴ベクトルのいずれに近いかを検索し、データベース中の対応したベクトルに付与されている画像 ID 全てに投票処理を行う。その結果、最大得票数を得た画像を認識結果とする。ベクトル同士の距離計算にはユークリッド距離を用いる。

データベース中の visual word の総数が少なくなればなるほど、1つの visual word に対応付く画像 ID の数が増えていくことが予想される。この場合、無削減状態において、データベース中に多くの特徴ベクトルが登録されている画像が、得票しやすくなりうるといえる。そのため、visual word に対応付いている画像 ID に投票を行う際には、画像ごとに重みをつけて投票を行うことにする。具体的には、その画像からデータベース中に登録されている局所特徴量の数  $n$  を調べ、特徴ベクトルあたり  $1/\sqrt{n}$  の重みをつけて投票を行う。この重みの程度は、予備実験の結果から経験的に定めたものである。

また、投票処理によって認識を行うため、データベースの画像が得た票数によって認識結果が決まる。つまり、正解の画像が最大得票数となっていれば、特徴ベクトル  $q_i$  の照合時に多少の誤りが発生しても問題がないといえる。そこで、本稿では、ベクトルの照合に ANN (Approximate Nearest Neighbor) [5]




図1 ANN の概念図

を用いる。ANN は、木構造を用いて、近似最近傍探索を高速に行う手法である。近似を行うことにより、ベクトル照合の精度は低下するものの、検索にかかる処理時間を削減することが可能となる。

ANN による近似最近傍探索の概念を図1に示す。ただし、簡単のため、説明に關与するセルのみを描いている。いま、 $q$  を検索質問の特徴ベクトル、 $p_1 \sim p_6$  をデータベース中の画像の特徴ベクトルとし、現在、 $p_1$  が近傍のベクトルとして発見されているとする。最近傍探索を実行する場合、実線で示される超球と重なるセルには、 $p_1$  より近傍の特徴ベクトルが存在する可能性があるため、探索の対象となる。一方、近似最近傍探索を行う場合、 $p_1$  までの距離  $r$  に対して、許容誤差  $\varepsilon$  を用いて定義される半径  $r/(1+\varepsilon)$  の超球を考え、それと交わるセルのみを探索の対象とする。これにより、最近傍の特徴ベクトル(図1の場合は  $p_3$ )を発見できない可能性は出てくるが、対象となるセルの数が減少するため、探索時間を削減できる。

続いて、ベクトル空間法について述べる。

ベクトル空間法は、主に文書検索で用いられている手法である。文書を高次元空間上のベクトルで表現し、そのベクトル同士を比較することにより、類似度を調べるものであり、現在では一般物体認識にも用いられている。本稿では、これを特定物体認識に適用する。

データベース中の局所特徴量は、全て、データベース中の visual word に対応しているため、画像ごとに、各 visual word に対応している局所特徴量の数を調べることができる。また、検索質問画像についても、各特徴ベクトルを ANN で検索して、visual word に対応づけることで、同じように、各 visual word に対応している局所特徴量の数を計算できる。これによって、visual word を横軸、その visual word に対応している局所特徴量の数(頻度)を縦軸にとれば、各画像をヒストグラムで表現できる。

このヒストグラムをベクトルとして、ベクトル空間法を適用する。重みとして、 $tf \cdot idf$  重み  $w$  を用い、類似度として、cosine 尺度を用いる。そして、cosine 尺度が最大となったものを認識結果とする。なお、 $tf$ (term frequency) は、画像中での visual word の出現頻度、 $idf$ (inverse document frequency) は、全画像での visual word が出現した画像数の逆数であり、以下で定義されるものである。

$$w = tf_w \cdot idf_w$$

$$tf_w = \begin{cases} (\log tf) + 1 & (tf > 0) \\ 0 & (tf = 0) \end{cases}$$

$$idf_w = \log \frac{N}{m}$$

ここで、 $N$  は総画像数、 $m$  はある visual word を含む画像数である。

### 3.3 取捨選択による容量削減

#### 3.3.1 取捨選択の方法

まず、データベースの作成方法について述べる。抽出される局所特徴量の数は、画像によって異なる。そのため、無削減状態のデータベースでは、画像から抽出された局所特徴量を全て登録するため、画像によって、記録されている局所特徴量の数が大きく異なっている。抽出される局所特徴量が多い画像では、特定の部分から類似した局所特徴量が多数抽出されることがある。これらの局所特徴量は、全てをデータベースに登録しておく必要がない。よって、画像1枚からデータベースに抽出する局所特徴量の数の最大値を  $R$  とし、使用するメモリ容量が増大することを防ぐことにする。抽出された局所特徴量の数が  $R$  を越えない場合には、抽出された局所特徴量を全てデータベースに登録する。越えた場合には、以下の手順によって、登録する局所特徴量を選択する。本研究では、特定物体の認識を目的としており、検索質問画像では、画像全体が写っている可能性は低くはないといえる。そこで、角度耐性に比較的強いと考えられる、スケールの大きな局所特徴量を選択し、データベースに登録する。しかしながら、スケールの大きな特徴量が、画像の一部領域に偏って存在している場合、その領域以外の部分が撮影された検索質問に対して、認識が困難となる。それに対処するため、局所特徴量が抽出された画像上の座標値で、最大クラスタ数を  $R$  とし、k-means クラスタリングをして、分割された各クラスタから、スケールが最も大きな局所特徴量を優先して登録する。これにより、画像上から満遍なく局所特徴量を選択することになり、画像中に物体が一部分しか写っていない場合においても、認識できる可能性を高めることができると考えられる。

認識には、投票方式を用い、ベクトルの照合には、ANN を用いる。局所特徴量の削減のため、本来対応づくベクトルに対応づかないことも考えられる。そのため、ANN の結果で返ってくる、クエリ点と検索質問のベクトルの点との距離  $d$  が、閾値  $t$  よりも近い場合にのみ、画像に投票を行う。

## 4. 実 験

### 4.1 実験データベース

#### 4.1.1 画像データベース

ベクトル量子化のデータベースには、画像1万枚、局所特徴量の取捨選択のデータベースには、画像10万枚を用いた。画像1万枚データベースは、A, B, C の3種類のデータセットで構成されている。A は、Google イメージ検索を用いて収集した、



表1 データベースに登録されている局所特徴量の数 (ベクトル量子化)

$b$	局所特徴量の数	無削減比 [%]
20	$1.05 \times 10^6$	5.1
10	$2.10 \times 10^6$	10.1
5	$4.19 \times 10^6$	20.3
3	$8.40 \times 10^6$	40.5
2	$1.23 \times 10^7$	59.5
1	$2.07 \times 10^7$	100.0

表2 データベースに登録されている局所特徴量の数 (取捨選択)

$R$	局所特徴量の数	無削減比 [%]
50	$4.99 \times 10^6$	2.7
75	$7.49 \times 10^6$	4.1
100	$9.98 \times 10^6$	5.5
200	$1.98 \times 10^7$	10.9
300	$2.94 \times 10^7$	16.1

3,100 枚の画像である。検索キーワードとしては、ポスター”、雑誌”、”表紙”などを用いた。Bは、PCA-SIFTのサイトで公開されている3,450枚の画像である。Cは、写真共有サイトの flickr において、”animal”、”birthday”、”food”、”japan”などのタグにより収集した3,450枚の画像である。主に物体や、自然の写真、人物の写真などを含む。10万枚データベースの構成は、データセットは同じであるが、データセットの枚数が、Aは3,100枚、Bは18,500枚、Cは78,400枚となっている。これは、1万枚データベースの画像を含んでいる。画像例を図2に示す。

なお、収集の際には、600×600 pixel 以下のサイズの画像は除外し、画像の長辺が640pixel 以下になるように縮小した。画像サイズは、およそVGAサイズである。そして、この画像に対して、PCA-SIFT<sup>(注1)</sup>で、局所特徴量を抽出した。抽出された局所特徴量の数は、1万枚データベースでは、全部で、 $2.07 \times 10^7$ 、10万枚データベースでは、 $1.82 \times 10^8$ である。

そして、各データベースに対して、3.で述べた、局所特徴量のベクトル量子化の方法、並びに、局所特徴量の取捨選択の方法で、データベースを作成した。ベクトル量子化の方法でデータベースを作成する際に用いた  $b$  の値は、 $b = 1, 2, 3, 5, 10, 20$ 、局所特徴量の取捨選択でデータベースを作成する際に用いた  $R$  の値は、 $R = 300, 200, 100, 75, 50$  である。また、そのとき、データベース内に登録されている局所特徴量の数は表1, 2の通りである。

#### 4.1.2 検索質問画像

検索質問としては、データセットA, B, Cのそれぞれから100, 200, 200枚の合計500枚を無作為に選択した。次に、これらをA4の用紙に印刷し、カメラを用いて撮影した。得られた画像の例を図3に示す。図3に示すとおり、紙面全体が写る配置で、紙面に対するカメラの光軸の角度  $\theta$  を90°, 75°, 60°に変化させた。また、角度を90°として紙面の一部分を撮影した。その結果、1枚の紙面に対して、合計4通りの画像を得た。

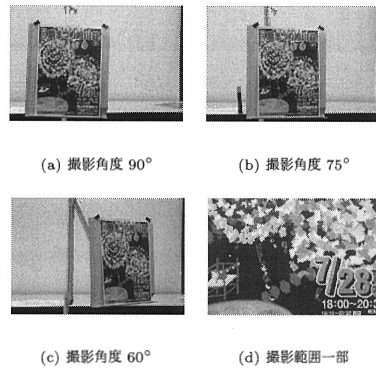


図3 検索質問の例

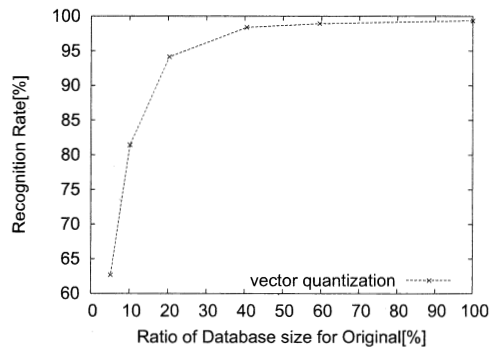


図4 投票による認識率

さらに、撮影した画像を512×341 pixelに縮小し、PCA-SIFTにより特徴ベクトルを求めた。その結果、画像1枚あたり平均612個の特徴ベクトルが得られた。


### 4.2 ベクトル量子化

#### 4.2.1 投票による実験結果


前節で述べたデータベース、検索質問画像を用いて、ANNの近似パラメータ  $\epsilon = 5$  として、求めた実験結果を図4に示す。横軸に visual word の数、縦軸に認識率を示している。図4より、バケットサイズが大きくなり、データベース中に記録する visual word の数が減少するにつれ、認識率の低下が起きていることが分かる。また、野口らのスカラー量子化では、無削減状態の1/8(12.5%)のサイズのデータベースを用いた場合でも、98%以上の認識率を得ていることから、その結果に及んでいないことが分かる。

一般に、ベクトル量子化を行うと、1つの visual word に複数の画像IDが対応付くため、一度に複数の画像が得票する。このとき、visual word に対応付いている画像IDが同一のものばかりであれば、認識を誤らない。一方で、異なったものばかりであれば、誤認識の可能性が高くなるといえる。ここで、データベースに登録されている全ての局所特徴量に対して、ANN

(注1) : <http://www.cs.cmu.edu/~yke/pcasift/> で提供されていたものを用いた。



(a)



(b)



(c)

図 2 登録画像の例

表 3 ベクトル空間法による実験結果

$b$	認識率 [%]
10	84.0
20	66.3

の近似パラメータ  $\varepsilon = 5$  として、近傍点の検索を行った。そして、 $\mathbf{q}$  に付与されている画像 ID と、ANN で求めた  $\mathbf{v}$  に付与されている画像 ID が一致する場合と、一致しなかった場合について、点間の距離と、その出現頻度を調べた。その結果、画像 ID が一致する場合は、全体の 3.29%、画像 ID が一致しない場合は、96.7%であった。従って、データベース中の局所特徴量について、互いに距離が近いものを選択し、ベクトル量子化をすると、大半の場合、異なった画像 ID が付与されているものを、まとめてしまうことが分かった。その結果、認識率の低下を招いているといえる。

#### 4.2.2 ベクトル空間法による実験結果

$b = 10, 20$  のデータベースに対して行った実験の結果を表 3 に示す。表に示されているとおり、ベクトル空間法で評価しても、投票による認識と同程度の認識率となった。この数値は投票の場合と大きな違いはないため、認識法が異なっても、認識結果に及ぼす影響はそれほど変わらず、特定物体認識を目的としたメモリ削減をする場合には、ベクトル量子化は適さないと考えられる。

表 4  $t$  を変化させたときの認識率 ( $R = 50$ )

$t$	認識率 [%]					処理時間 [ms]
	平均	60°	75°	90°	一部	
$\infty$	92.6	94.4	96.8	96.2	83.0	440.7
4472	92.8	94.4	96.8	96.4	83.4	454.4
3873	93.3	94.0	97.2	97.0	84.8	465.5
3162	93.2	93.0	97.6	96.8	85.2	450.8
2236	90.1	79.8	97.4	96.8	86.4	448.9

### 4.3 局所特徴量の取捨選択

#### 4.3.1 距離の閾値 $t$ の実験

まず、距離の閾値  $t$  として、どの程度の値を定めるのが適切かを調べるため、作成したデータベースに対して、 $t$  の値を変化させて、認識率がどのように変化するかを調べる実験を行った。そのうち、 $R = 50$  の場合の結果を表 4 に示す。およそ、 $t = 3873, 3162$  の場合によくなっていることが分かる。 $R$  の値を変化させたときにおいても、総じて、 $t = 3873, 3162$  のあたりで結果がよくなっていることが分かった。よって、以降の実験では、 $t$  の値として、 $t = 3873$  を用いる。

次に、以下の 4 手法を比較した。k-means クラスタリングをして、その中でスケールの大きな局所特徴を選択する方法 (A) と、各画像から画像空間上で k-means クラスタリングをして、その中から、局所特徴量をランダムに選択する方法 (B)、各画像から、スケールの大きい局所特徴量を順に選択する方法 (C)、




図5 各手法の比較 ( $R = 50$ )

各画像からランダムに局所特徴量を選択する方法 (D) の 4 手法である。

上記 4 手法について、同じ  $R$  の値を用いてデータベースを作成し、認識率を比較した。距離の閾値は、 $t = 3873$  である。 $R = 50$  のときの結果を図 5 に示す。

縦軸に認識率を示しており、横軸には、左より、全ての平均、 $60^\circ$  の検索質問の平均、 $75^\circ$  の検索質問の平均、 $90^\circ$  の検索質問の平均、一部分を撮影した検索質問の平均の、計 5 点をプロットしてある。図 5 より、画像全体が写っている場合においては、A が最もよい認識率となっている。

図 5 の (A, C) より、特定平面物体全体が写っている画像を認識する場合、角度変化への耐性が強い、大きなスケールが認識に有利であるといえる。しかしながら、スケールが大きいものだけを登録した場合 (C) においては、一部分のみが写っている検索質問画像を用いると、認識率が著しく下がっている。これの一つの原因として、大きなスケールの局所特徴量が、画像の撮影範囲外の部分に偏ってしまい認識ができなかったことが考えられる。k-means 法を適用し、画像上から満遍なく局所特徴量を選択する手法 (A) を用いると、認識率が大きく回復していることから、画像上からスケールの大きな局所特徴量を満遍なく選択することが重要であるといえる。

続いて、手法 A に対して、 $R$  の値を変化させたときの認識率を表 5 に示す。 $\infty$  は、局所特徴量をデータベースに登録する際に、その数の制限を設けなかった場合を示している。

表 5 より、元のデータベースの 10% 程度でも、98% 以上の認識率が実現されている。 $R$  が小さくなるにつれ、一部分のみを拡大した検索質問に対しては、認識率の低下の程度が大きくなっている。これは、スケールの大きい局所特徴量を選択したためであると考えられる。

## 5. まとめ

本稿では、局所特徴量のベクトル量子化と、取捨選択により、データベース容量を削減する方法について考察した。ベクトル量子化は、kd-tree を構築する際に特徴空間を分割する方法を用いて、特徴空間を分割し、分割された空間に存在する点の重心ベクトルを用いることで行った。認識実験の結果、特定物体

表 5  $R$  の値を変化させたときの認識率 ( $t = 3873$ )

無削減比	認識率 [%]					処理時間
	平均	$60^\circ$	$75^\circ$	$90^\circ$	一部	
[%]						[ms]
100	98.7	97.8	99.0	99.0	99.0	1038
16.1	98.8	98.4	99.0	99.0	98.8	778.6
10.9	98.4	98.2	98.6	98.6	98.0	658.8
5.5	97.6	97.6	98.2	98.6	95.8	553.5
4.1	96.7	96.8	98.2	97.8	94.0	537.2
2.7	93.3	94.0	97.2	97.0	84.8	465.5

認識においては、ベクトル量子化は、適さないことが分かった。一方、局所特徴量の取捨選択は、特徴量のスケールと、画像空間上での分布を考慮して行うことで、無削減状態の 1/10 程度のデータベースを用いた場合においても、98% の認識率を得ることができた。

今後の課題として、k-means 法を適用した場合に認識率が高くなる理由の追及、スカラー量子化と取捨選択法を組み合わせ、さらに認識に必要なデータベースの容量の削減を目指すことなどが挙げられる。

## 文 献

- [1] D. G. Lowe, "Distinctive image features from scale-invariant keypoints", *International Journal of Computer Vision*, 60, 2, pp.91-110, 2004.
- [2] Y. Ke, and R. Sukthankar, "PCA-SIFT: A more distinctive representation for local image descriptors", *Proc. CVPR'04*, vol.2, pp.506-513, 2004.
- [3] 野口, 黄瀬, 岩村: "局所記述子に基づく物体認識のためのメモリ削減の実験的検討", 画像の認識・理解シンポジウム (MIRU2008) 論文集, OS10-3, pp.251-258, 2008.
- [4] D. Nistér and H. Stewenius, "Scalable Recognition with a Vocabulary Tree", *Proc. CVPR2006*, pp.775-781, 2006.
- [5] S. Arya, D. Mount, R. Silverman and A. Y. Wu, "An optimal algorithm for approximate nearest neighbor searching", *Journal of the ACM*, vol.45, no.6, pp.891-923, 1998.