

カメラ付き携帯電話を入力デバイスとした大規模画像認識

野口 和人[†] 氏原 慎弥^{††} 黄瀬 浩一[†] 岩村 雅一[†]

[†] 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

^{††} 大阪府立大学工学部 〒599-8531 大阪府堺市中区学園町 1-1

E-mail: {noguchi,ujihara}@m.cs.osakafu-u.ac.jp, {kise,masa}@cs.osakafu-u.ac.jp

あらまし カメラ付き携帯電話を入力デバイスとした画像認識では、撮影した画像のぶれやぼけが認識精度低下の原因となる。そのため、ぶれやぼけに対処する手法が重要となる。本稿では、局所特徴量の近似最近傍探索による認識手法に対して、原画像に様々がぶれやぼけを与えた画像を生成し学習する生成型学習を導入することによって対処する。生成型学習を導入するにあたって問題となるのは、学習データの増加にともなって最近傍探索に必要なメモリ量と処理時間が増大することである。これは、特に大規模なデータベースを用いた場合に問題となる。提案手法では、多段階化とスカラー量子化によってこれを解決する。1万枚の画像データベースを用いた実験の結果、生成型学習を用いない手法と比べて認識率が12.3%向上することがわかった。

キーワード 生成型学習, 画像認識, カメラ付き携帯電話, 局所特徴量, 多段階化, スカラー量子化

Large-Scale Image Recognition with a Camera Phone

Kazuto NOGUCHI[†], Shinya UJIHARA^{††}, Koichi KISE[†], and Masakazu IWAMURA[†]

[†] Graduate School of Engineering, Osaka Prefecture University

1-1 Gakuencho, Naka, Sakai, Osaka, 599-8531 Japan

^{††} College of Engineering, Osaka Prefecture University

E-mail: {noguchi,ujihara}@m.cs.osakafu-u.ac.jp, {kise,masa}@cs.osakafu-u.ac.jp

Abstract For image recognition with a camera phone, defocus and motion-blur cause a serious decrease of the image recognition rate. In this report, we employ generative learning, i.e., generating blurred images and learning based on them, for a recognition method using approximate nearest neighbor search of local features. Major problems of generative learning are long processing time and a large amount of memory required for nearest neighbor search. The problems become serious when we use a large-scale database. In the proposed method, they are sloved by cascading recognizers and scalar quantization. From experimental results with 10,000 images, we have confirmed that the proposed method improves the recogniton rate by 12.3% as compared to a method without generative learning.

Key words Generative learning, Image recognition, Camera phone, Local features, Cascade, Scalar quantization

1. はじめに

カメラ付き携帯電話の普及に伴って、単に写真を撮るだけでなく、カメラを入力デバイスとして利用するサービスの要求が高まっている。例えば、雑誌やカタログなどに掲載された商品を撮影することによって、商品の注文や関連情報の提示などを行うサービスがある。このような目的のためには、画像中の物体を高速かつ高精度に認識する必要がある。

我々はすでに、大規模な画像データベースから高速かつ高精度に画像を認識する手法を提案している [2], [3]。この手法は、局所特徴量として PCA-SIFT [1] を使い、画像データベースと

検索質問の特徴量同士を近似最近傍探索によって対応づけ、最も対応づいた画像を回答とすることで認識するものである。この手法の特徴は、画像によって近似の程度を適応的に調節することで高速化する多段階化 [2] やスカラー量子化によるメモリ使用量の削減 [3] にある。

しかし、この手法をカメラ付き携帯電話で撮影した検索質問に適用すると、十分な認識率が得られないという問題が生じる。その原因は、カメラ付き携帯電話でカタログなどを接写したときに起こるぶれやぼけなどの劣化により、局所特徴量が変化してしまうことである。

このような劣化を受けた画像の認識には、(1) 劣化を修復す

る, (2) 劣化にロバストな特徴量を利用する, (3) 原画像に劣化を加えて生成した画像を学習するという3つのアプローチが考えられる. 劣化を修復する方法は, 認識時に修復処理を行う必要があり, 処理時間の問題がある. 次に, 劣化に不変な特徴量であるが, 提案手法で利用する PCA-SIFT は [4] によるとぼけには比較的強いとされており, さらなる改善は容易ではない. そこで, 原画像から生成した劣化画像を学習する方法に着目する. この方法は生成型学習と呼ばれ, 文字認識などの分野で使われている [5]. 局所特徴量による画像認識の分野でも, 局所領域に対して数千種類のランダムな変換を加えたものを学習することで, 高い精度を得る手法 [6] が提案されている. しかし [6] では数千枚程度のデータベースでしか実証されておらず, 本研究で目指す大規模なデータベースでの認識では有効性が確認されていない.

以上から, 本稿ではぶれやぼけの問題を生成型学習によって解決する手法を提案する. 具体的には, 登録する画像からぶれやぼけの加わった画像を複数生成し, 特徴量を得ることで, 検索質問の特徴量に近づける. このとき生じる, メモリ量や処理時間の増加という問題は, 我々がこれまでに提案してきた多段階化とスカラー量子化によって解決可能であることを示す. 10万枚の画像データベースを用いた実験の結果, 認識率 91.6%, 処理時間 7.4ms が実現可能であることがわかった.

2. 提案手法

まず, 我々が以前提案した近似最近傍探索による物体認識手法について述べたあと, 生成型学習による学習データの作成について述べる.

2.1 近似最近傍探索による物体認識手法

この手法の特徴は, 多段階化による高速な認識とスカラー量子化によるメモリ削減である. 登録, 検索に共通のハッシュ関数について説明したあと, 登録, 検索の順に説明していく.

2.1.1 ハッシュ関数

まず基本となるハッシュ関数について説明する. PCA-SIFT によって得られる 36 次元の特徴ベクトル x は, 主成分分析の結果であり, 低次の方が固有値が大きいという性質がある. そこで, x の第 1 次元から第 d 次元 ($d \leq 36$) までをとり, $\hat{x} = (x_1, x_2, \dots, x_d)$ とする. 次に,

$$u_j = \begin{cases} 1 & \text{if } x_j - \mu_j \geq 0, \\ 0 & \text{otherwise,} \end{cases}$$

を用いて次元ごとに 2 値化を行いビットベクトル $u = (u_1, \dots, u_d)$ を作成する. ここで μ_j は, 認識対象となる画像すべての x_j の平均値である. そして,

$$H_{\text{index}} = \left(\sum_{i=1}^d u_i 2^i \right) \bmod H_{\text{size}} \quad (1)$$

によってハッシュ値を求める. ここで \bmod は剰余演算, H_{size} は, ハッシュ表のサイズである.

2.1.2 データ登録

前述のハッシュ関数を用いて特徴ベクトルをハッシュ表に登




図 1 多段階化による認識

録する. ハッシュ表には, 画像 ID とともにスカラー量子化によってデータ量を削減した特徴ベクトルを登録する. 登録時に衝突が生じた場合は, 複数の特徴ベクトルをリストとして登録する. このとき, リストが長くなりすぎると, 検索の際に距離計算のコストがかかりすぎるといった問題が生じる. そこで本手法では, リスト長 n に対する上限 c を設け, $n > c$ を満たすとリスト全体をハッシュ表から削除する. 同じハッシュ値を持つ特徴ベクトルが多いということは, その特徴ベクトルが画像の識別にあまり寄与しないことを意味する. 従って, 削除しても影響は比較的少ないと考えられる.

以上の処理を, データベースに登録する全ての特徴ベクトルに対して施すことにより, データの登録は完了する.

2.1.3 多段階化による検索

検索では, 図 1 に示す多段階化によって高速な処理を実現する. ここで, 0 から b の数字が付けられた矩形は識別器を表し, 数字が若いほど大幅な近似を行うものである. 各段では, 検索質問の特徴点とデータベース中の特徴点とを近似最近傍探索によって対応付け, 投票により最も多く対応づいた画像を回答とする. 検索質問の画像から得た特徴ベクトルの集合は, まず 1 段目の識別器によって認識される. この段階で後述する十分な証拠が得られれば, 認識処理を打ち切って結果を回答する. 一方, 証拠が不十分ならば, 特徴ベクトルの集合を, 次段の, より小幅な近似の識別器にかけて再度認識する. 処理を繰り返して最後の b 段まで到達しても十分な証拠が得られない場合には, 最大得票数のものを回答するか, その画像についてはリジェクトするかのいずれかをとる. 以上の処理によって, 早い段階で処理が打ち切られる画像については大幅な効率化が期待できると共に, 必要に応じて時間をかけた認識が可能となる.

認識誤りを引き起こす画像には, そもそも得票数が少ない, 得票数がある程度得られる場合でも第 2 位の候補と得票数に開きが殆どない, という性質がある. これらの点に着目すると, 証拠が十分であるか否かは次のように判定できる. 1 位の得票数を V_1 , 2 位の得票数を V_2 とすると, $V_1 > t, rV_1 > V_2$ を同時に満たすならば, 処理を打ち切って 1 位得票の画像を回答とする. ここで, t は得票数の閾値, r は 1 位と 2 位の得票数の比の閾値である.

2.1.4 各段の識別器

各段の識別器では, 検索質問の画像から得た各特徴ベクトル q に対して, ハッシュ表から特徴ベクトルを検索する. ここで得られた特徴ベクトルの集合を X とする. 次に, q をスカラー量子化したベクトルと, X に含まれるベクトルとのユークリッド距離を計算し, 最近傍となる特徴ベクトル x_* を求める

そして、 x_* に対応する画像 ID に投票する．最近傍となる特徴ベクトルが複数ある場合には、それらすべてに対して投票処理を施す．検索質問のすべての特徴ベクトルに対してこの処理を行い、最終的に最も得票数の多いものを回答とする．

この処理において、近似の程度を決定するのは、 q に対する特徴ベクトルの集合 X を検索する部分である．最も近似する場合 (1 段) では、登録時と同様に q に対してビットベクトルを求め、ハッシュ関数によって同じハッシュ値を持つ特徴ベクトルを求める．

近似の程度を緩める場合には、特徴ベクトルの各次元の値が撮影条件によって変動することを考慮し、変動を考慮した探索を行う．具体的には、値の変動幅 e をパラメータとして、変動への次の対処を施す． $q = (q_1, \dots, q_d)$ とするとき、 $|q_j - \mu_j| \leq e$ を満たす次元 j に対しては、 u_j だけではなく $u'_j = (u_j + 1) \bmod 2$ (0 ならば 1, 1 ならば 0) も用いて、特徴ベクトルを検索する．この処理を特徴ベクトルの高次の方から行っていき、多段階化の段階が進むごとに、処理の対象となる次元を増加させる．最終段 (b 段) まで到達した場合には 2^b 個のビットベクトルを試すことになる．このとき、前の段で既に試したビットベクトルとの差分のみを容易に検索することができるため [2]、多段階化による処理の増加は最小限に抑えることができる．

2.2 生成型学習


本や写真といった平面物体を撮影した際におこる劣化の原因はいくつか考えられるが、本研究では光学ぼけとぶれが最も大きい要因であると考え対策する．

ぼけやぶれに対処する最も単純で効果的な方法は、生成型学習によるものであろう．これは、様々なぼけやぶれを与えた画像を生成し、そこから特徴抽出をして認識に用いる手法である．抽出された特徴ベクトルは、識別器の学習データとなる．


提案手法は、局所特徴量の最近傍探索によって認識しているため、学習データの増加は、必要なメモリ量と処理時間の増加につながる．そこで、学習データを出来るだけ少なくするために、ぶれについて以下のように仮定する．撮影対象である本や写真が移動することは考えづらいので、ぶれは画像の撮影時に撮影ボタンを押すことで起こる．そのためぶれの方向は垂直または水平のみであると仮定する．

以上より、学習セットとして、図 2 に示すものを用いる．画像データベース中の画像をカーネルサイズを変えつつガウシアンフィルタによってぼかしたものを用意し、含まれるぼけぐあいの種類によってセット A から D を作成する．カーネルサイズは縦横それぞれ 1, 7, 13, 19 [画素] の組み合わせについて試す．カーネルサイズが縦と横で異なるものがぶれに対応している．なお、実験に用いる画像データベースはほぼ QVGA サイズ (320 × 240) である．


ところで、PCA-SIFT はぼけの程度を変えた複数枚の画像によりスケールスペースを構築し特徴点を求めることでスケール不変を実現している．そのため、カーネルサイズが縦と横で異なるぶれに対応した画像では、原画像と異なる特徴量が得られても不思議ではない．一方、カーネルサイズが縦横同じになるぼけに対応した画像では、原画像と同じ特徴点しか得られないと思われるかもしれない．しかし、スケールは離散的にしか試




(a) 学習セット A (原画像) : 対応数 9, 右画像の特徴点数 199




(b) 学習セット B : 対応数 31, 右画像の特徴点数 575



(c) 学習セット C : 対応数 36, 右画像の特徴点数 839



(d) 学習セット D : 対応数 36, 右画像の特徴点数 1059



(e) 学習セット D_{diag} : 対応数 16, 右画像の特徴点数 342

図 3 携帯電話で撮影した画像 (左) と各学習セット (右) との対応
左画像の特徴点数は 134

さないため、ぼけに対応した画像を入力すると異なる特徴点が得られることが多い．これを検証するために、学習セット D に含まれる画像のうちカーネルサイズの縦横のサイズが同じもの

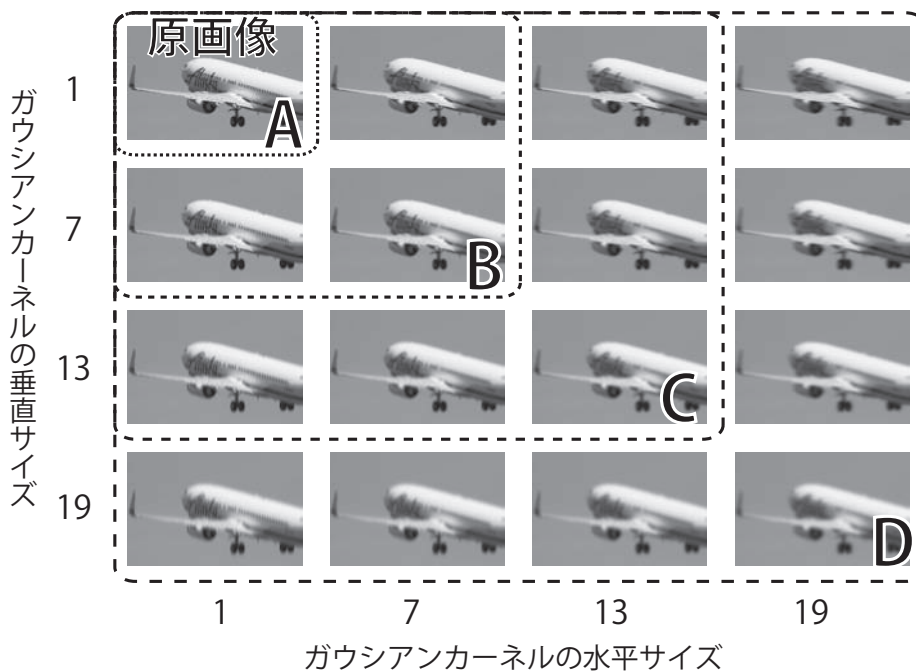


図 2 ぼかした画像の例

(図 2 の対角成分)のみを抜き出した学習セット D_{diag} を作成した。図 3 は学習セットと携帯電話で撮影した画像の一対一で対応をとったものである。具体的には、撮影画像の特徴点に最も近い学習セット中の特徴点の距離が閾値以下の場合に対応が取れたとする。図中の点は特徴点、線は対応を表している。ぼかした画像の枚数が多いほど対応の数が増加していることがわかる。 D_{diag} でもぼかしのない A より多くの対応が得られており、効果があることがわかる。これらのことから、生成型学習により、携帯電話で撮影した画像の特徴点と学習セット中の特徴点が近づいていることがうかがえる。なお、この対応は対応する画像のみを対象として処理した結果であるため、多数の画像を登録した場合の認識結果については実験で取り扱う。

3. 実験

3.1 実験条件

実験には以下に述べる画像データベース、検索質問画像を用いた。局所特徴量としては、PCA-SIFT^(注1)を用いた。ハッシュ表のサイズは $H_{size} = 2^d$ とした。以下に示す処理時間は、検索質問の画像 1 枚あたりの認識に要した時間を表す。ただし、特徴ベクトルの抽出に必要な時間は含めていない。使用計算機は、CPU が AMD Opteron 2.8GHz、メモリ 64GB のものである。

3.1.1 画像データベース

実験に用いた画像について説明する。画像データベースは、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 10 万枚の画像からなる。主に図 4 に示すような物体や自然の写真、人物の写真などを含む。なお、画像の長辺が 320 pixel 以下になるように縮小した。




図 4 登録画像の例

表 1 学習セットの種類

学習セット	ぼかした画像の生成数 (原画像を含む)	抽出された特徴点数の合計 (原画像が 1 万枚の場合)
A	1	5.0×10^6
B	4	1.6×10^7
C	9	2.6×10^7
D	16	3.3×10^7
D_{diag}	4	9.8×10^6

2.2 節で述べた各学習セットを作成した時の特徴点数を表 1 に示す。画像から得られる PCA-SIFT 特徴点の数は画像がぼけているほど少ないため、画像の枚数ほど特徴点数は増加していない。

実験では、スカラー量子化の閾値はどの枚数のデータベースを用いる場合でも、1 万枚の画像データベースから得たものを用いた。

3.1.2 検索質問画像

検索質問としては、表 2 に示すように認識用とリジェクト用の 2 種類を作成した。認識用は画像データベースから無作為に選択した 1000 枚を撮影したものである。具体的な作成手順は以下の通りである。まず、A4 用紙 1 枚に画像を 4 枚または 16 枚並べて印刷した。印刷には、カラーレーザープリンタを用い

(注1): <http://www.cs.cmu.edu/~yke/pcasift/>で提供されている。

表 2 検索質問の種類

撮影者	撮影用紙	マクロ	特徴点数
1	認識用 16 分割	あり	335
2			324
3		なし	194
4			95
5	認識用 4 分割	なし	310
6			314
7			258
8			227
9	リジェクト用	なし	133
10			73

た．撮影者ごとに別の携帯電話を用い、各々の画像全体が写るように撮影した．このとき、画像サイズは QVGA(320×240)とし、マクロモードは表 2 のように設定した．リジェクト用としては、画像データベースに含まれない画像 1000 枚を印刷したものを類似の手法で撮影して用いた．画像 1 枚あたりの特徴点数を表 2 に示す．

3.2 リジェクトなしの実験

3.2.1 学習セット

まず、生成型学習が認識率に与える影響について調べた．登録画像数は 1 万枚とし、認識率に悪影響を与える可能性のある多段階化、量子化は行わなかった(各次元 16bit で表現)．処理のパラメータは、 $b = 10, c = 100, d = 28, e = 400$ とした．結果を表 3 に示す．学習セットを A,B,C,D と変えるにつれ認識率が向上し、D を用いた場合には認識率 93.3%と A(原画像)の 81.0%から 12.3%向上している．撮影者ごとに比較すると、撮影者 3 が最も効果が大きく、認識率 57.0%であったのが 88.7%と 31.7%向上した．次に効果があったのは、撮影者 4 であった．撮影者 3 と 4 は、表 2 に示すように、A4 用紙 1 枚に 16 枚の画像を印刷し、マクロモードなしで撮影したものである．そのため、他の検索質問に比べぼけの程度が大きく、提案手法の効果が高かったと考えられる．学習セット D_{diag} を見ると、認識率は D には劣るものの A から 10%向上した． D_{diag} では、ぶれへの対処は行っていないため、ぼけのみへの対処でもある程度の効果が得られることがわかる．

一方、処理時間について見ると、学習セット中の特徴点の増加にともなって、増加していることがわかる．例えば、セット C は A の約 5 倍の特徴点が含まれ、処理時間は 2 倍程度かかっている．特徴ベクトル以外の部分やオーバーヘッドも含む実際に使用しているメモリ量は、学習セット A から順に 2.5GB, 3.5GB, 4.3GB, 4.5GB と増加していた．このように、学習セット内の画像の増加による認識率の向上は、処理時間やメモリ量を犠牲にすることで成立している．

図 5 に学習セット A では認識に失敗したが、学習セット C では認識に成功した画像を示す．図からぶれやぼけの激しい画像でも認識できることがわかる．

3.2.2 スケーラビリティ

ここまでの実験で、学習セット中の特徴点数を増加させることで認識率を改善できることがわかった．しかし、ハッシュ表に登録する特徴点数の増加によって、提案手法のスケーラビ



図 5 学習セット C で認識に成功した検索質問の例

リティに悪影響を与えることが考えられる．そこで、本節では学習セット C を用い登録画像数を 10 万枚まで増加させ、認識率、処理時間、メモリ量の 3 点について調べた．パラメータは $b = 400, c = 100, d = 28, e = 400, t = 4, r = 0.4$ 、多段階化はありとなし、スカラー量子化における次元あたりの bit 数は 2, 16(量子化なし)とした．

認識率を図 6 に示す．量子化なしの場合には、登録画像数を 10 万枚まで増加させた場合でも、認識率は 92.5%とほぼ一定であった．各次元を 2bit で量子化した場合には、認識率が最大で 1%ほど低下することがわかる．一方、多段階化による認識率の低下は、ほとんど見られなかった．

処理時間を図 7 に示す．多段階化により処理時間を 1/10 程度に削減できることがわかる．量子化ありの場合には、検索質問の特徴ベクトルを量子化する処理のために、時間が余分に必要であった．

10 万枚を登録した場合のメモリ量は、量子化なしの場合に 22.6GB、各次元 2bit で量子化した場合に 6.7GB と約 1/3 になった．1 万枚の場合には 2bit で量子化すると認識率 92.4%、処理時間 1.7ms、メモリ量 2.7GB となった．3.2.1 節で述べた学習セット A を用いた場合、すなわち生成型学習なしの場合には、認識率 81.0%、処理時間 7.7ms、メモリ量 2.5GB であったので、多段階化と量子化を組み合わせることにより、ほぼ同じメモリ量でより高速かつ高精度な認識を実現できたといえる．

3.3 リジェクトありの実験

最後に、登録画像数を 1 万枚とし学習セット C を用いたリジェクトをする場合の実験結果について述べる．結果の評価尺度を次の様に定める．まず、対応する画像のある検索質問に対しては、認識率 C_1 、誤認識率 E_1 、リジェクト率 R_1 ($C_1 + E_1 + R_1 = 1$)

表 3 学習セットと検索質問の種類ごとの認識率 [%], 処理時間 [ms]

撮影者	A(原画像)		B		C		D		D _{diag}	
	認識率	処理時間	認識率	処理時間	認識率	処理時間	認識率	処理時間	認識率	処理時間
1	90.8	10.6	95.3	16.5	96.1	19.9	96.6	22.1	95.4	12.8
2	87.7	11.4	93.1	17.6	93.3	21.4	93.7	23.0	91.4	13.9
3	71.8	5.3	81.7	8.4	86.7	10.6	88.5	11.5	85.2	6.6
4	57.0	2.5	78.3	4.0	87.2	5.1	88.7	5.8	85.2	3.2
5	91.3	9.7	94.7	15.0	95.1	18.1	95.5	20.4	94.1	11.7
6	89.2	9.2	95.0	14.4	96.3	18.1	96.4	20.3	94.4	11.4
7	87.0	6.9	96.2	10.9	97.0	13.4	97.1	15.2	95.6	8.8
8	73.5	6.2	85.2	9.3	88.9	11.8	90.2	13.3	86.8	7.6
平均	81.0	7.7	89.9	12.0	92.6	14.8	93.3	16.4	91.0	9.5

表 4 リジェクトをする場合の結果

パラメータの決定基準 (学習セットに対して)		認識用検索質問				リジェクト用検索質問		
		C_1 [%]	E_1 [%]	R_1 [%]	処理時間 [ms]	E_2 [%]	R_2 [%]	処理時間 [ms]
基準 A	$\min(E_1 + E_2 + R_1)$, 処理時間 1ms 以下	84.6	1.0	14.4	0.5	3.9	96.1	0.8
基準 B	$\min(E_1 + E_2 + R_1)$, 処理時間 10ms 以下	88.1	0.4	11.5	1.3	0.9	99.1	5.5
基準 C	$\min(E_1 + E_2 + R_1)$, 処理時間 100ms 以下	90.1	0.3	9.6	13.8	1.7	98.3	68.8

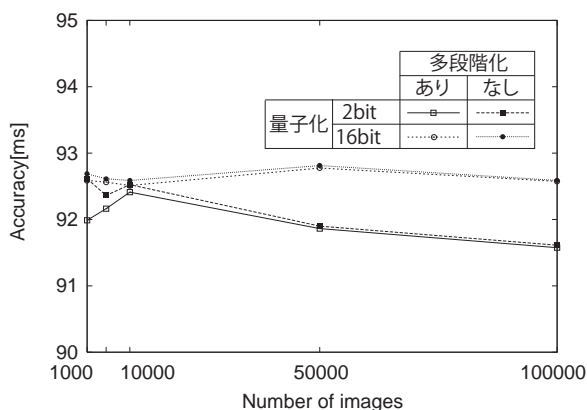


図 6 登録画像数と認識率




図 7 登録画像数と処理時間

とする．対応する画像のない検索質問に対しては，誤認識率 E_2 ，リジェクト率 R_2 ($E_2 + R_2 = 1$) とする．実験には，10-fold cross validation を用いた．学習サンプルに対して，表 4 の 3 通りの基準を用いてパラメータを求め，テストサンプルに適用した．パラメータについては， $b = 5, 10, 15$ ， $c = 2, 5, 10, 100$ ， $d = 20, 24, 28$ ， $e = 200, 400, 600$ ， $r = 0.2, 0.4, 0.6$ ， $t = 4, 8, 12$

のすべての組み合わせについて試した．結果を表 4 に示す．処理時間については，リジェクト用検索質問の方が長くなっている．これは，リジェクトとして回答するためには最終段まで到達する必要があるためである．処理時間を 10ms，リジェクト率 R_1 を 10% 程度許容すると，誤認識率が 1% 以下という誤りにくい認識を実現できた．

4. まとめ

本稿では，局所特徴量の最近傍探索による画像認識手法において，カメラ付き携帯電話を画像入力デバイスとして利用すると問題となるぶれやぼけを生成型学習により解決した．1 万枚の画像を用いた実験の結果，認識率が 12.3% 改善することがわかった．

今後の課題としては，さらなるメモリ削減などがある．

文 献

- [1] Y. Ke and R. Sukthankar, PCA-SIFT: A more distinctive representation for local image descriptors, Proc. of CVPR2004, Vol. 2, pp.506–513, 2004.
- [2] 野口和人, 黄瀬浩一, 岩村雅一, “近似最近傍探索の多段階化による物体の高速認識,” 画像の認識・理解シンポジウム (MIRU2007) 論文集, pp.111–118, July, 2007.
- [3] 野口和人, 黄瀬浩一, 岩村雅一, “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, pp.251–258, July, 2008.
- [4] K. Mikolajczyk and C. Schmid, “A performance evaluation of local descriptors,” IEEE Transactions on Pattern Analysis & Machine Intelligence, vol.27, no.10, pp.1615–1630, 2005.
- [5] 石田皓之, 高橋友和, 井手一郎, 目加田慶人, 村瀬洋, “手ぶれ情報を利用したカメラ入力型低品質文字の認識法,” 画像の認識・理解シンポジウム (MIRU2006) 論文集, pp.180–186, July, 2006.
- [6] M. Özuysal, M. Calonder, V. Lepetit and P. Fua, “Fast key-point recognition using random ferns,” IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.99, no.1, 5555.