GIFTS 画像特徴による大規模物体照合とその実利用における考察*

中野宏毅** 森 由美*** 森田千明† 長井真吾†

Large Scale Objects Recognition by using GIFTS Image Feature and
its Evaluation in Practical use

Hiroki NAKANO, Yumi MORI, Chiaki MORITA and Shingo NAGAI

We propose GIFTS (Goods Image Feature for Tree Search) local image feature for large scale object recognition system. GIFTS is a sort of keypoint feature and its feature vector consists of intensity delta of selected 128 pixel pairs around the keypoint. By generating KD-Tree from GIFTS feature vectors of training images and using the KD-Tree for searching nearest neighbor feature vectors of query image, order of $\log N$ query time for the specific object recognition is attained. We apply the proposed method to the query of book covers among 100 thousand training images of books, and performed over 99% recognition accuracy in the query time within one second.

Key words: object recognition, local feature, keypoint, KD-Tree

1. はじめに

近年の物体認識アルゴリズムの進歩と計算機の飛躍的な能力向上により、画像認識技術による多品種の商品の識別が可能となってきた。書店では、書籍にスマートフォンやタブレット端末をかざすことにより、本を手にとって ISBN バーコードをスキャンすることなく、売り上げランキングや在庫情報を書籍画像にオーバーラップ表示させて、店頭在庫管理の効率化をはかりたいという要求がある。しかしながら、商品の品種に比例して、マスターデータ作成や照合に要する時間が増大するという課題がある。筆者らは、10 万点規模の書籍マスターから 1 秒以内に 99% 以上の正答率で書籍の照合を行いたいというユーザーの要求に答えるために、GIFTS (Goods Image Feature for Tree Search) と呼ぶ画像局所特徴を使用した大規模特定物体照合システムを提案する。商品のマスター画像群の GIFTS 特徴ベクトルから KD-Tree (k-dimensional tree) を生成し、検索対象商品の画像特徴と類似の特徴ベクトルをもつキーポイントを KD-Tree から探索することにより、マスター画像群から得られるキーポイントの総数が膨大となった場合でも $O(\log N)$ オーダーの探索時間で照合が可能となる。10 万点規模の書籍の検索に提案方式を適用し、マスター画像中の書籍とクエリー画像中の書籍との鉛直方向からの傾きの差が 22.5 度以下の場合において、99% 以上の高い正答率で 1 秒以内に書籍照合が実現できることを検証したのでここに報告する。以降、2 章で GIFTS 画像特徴を提案し、3 章で GIFTS 画像特徴を使用した大規模商品照合システムについて述べる。4 章で実証実験の結果を報告し、その考察を行う。5 章で本論文をまとめる。

1.1 関連研究

特定物体認識のための画像局所特徴として、Lowe による

SIFT (Scale-Invariant Feature Transform) の発表以来¹⁾、その計算量を改善した SURF (Speeded Up Robust Features) や、特徴量の次元数を圧縮した PCA-SIFT (Principal Component Analysis - SIFT) などの局所特徴が発表され、高精度の特定物体照合技術が実用化されてきている²⁾⁻⁴⁾。一方、SIFT に代表される DoG (Difference of Gaussians) を利用した画像特徴とは別に、コーナー特徴を画像局所特徴とした ORB (Oriented FAST and Rotated BRIEF) が発表され高速な特定物体照合に活用されている。ORB はキーポイント検出に oFAST (Oriented Features from Accelerated Segment Test)、特徴量記述として BRIEF (Binary Robust Independent Elementary Features) を利用している。ORB は認識精度を維持しつつ、画像局所特徴の計算時間が飛躍的に改善された⁵⁾。しかしながら、マスター画像とクエリー画像との特徴ベクトルの照合には、マスター画像数に比例する処理時間が必要であり、マスター画像が数十万枚に達するような応用例では、実用的な照合時間が得られないという課題があった。

マスター画像の枚数に比例しない照合方法として、KD-Tree を使用する手法と、LSH (Locality Sensitive Hash) と呼ばれるハッシュテーブルを使用する方法が知られている⁶⁾⁻⁷⁾。SIFT のような実数の特徴ベクトルは KD-Tree が、また、ORB のようなバイナリー・ビットパターンで特徴ベクトルを現す方式では、LSH が向いているとされている⁸⁾。本稿で提案する GIFTS 特徴ベクトルは 128 次元の実数であるため、特徴ベクトルの配置には KD-Tree を採用する。KD-Tree では、 $O(\log N)$ オーダーの計算コストで木構造の探索が可能なが知られている⁹⁾。ここで N は KD-Tree 生成に使用した特徴ベクトルの数である。これ以外の関連研究としては、ハッシュ構造と近似最近傍探索による高速かつ省メモリを特徴とした大規模特定物体認識の研究や¹⁰⁾、特定物体認識の問題を一般物体認識におけるクラス分類の問題として画像間の類似度を定式化する提案¹¹⁾および、複雑なテクスチャと一緒に写りこみ多数のコーナー候補点を検出されるような場合に適用可能な Cascaded Fast¹²⁾ が提案されているが、10 万点規模の書籍マスターとの 1 秒以内の高精度の照合を実現したという報告は関連研究に見当たらない。

* 原稿受付 平成 27 年 4 月 24 日

掲載決定 平成 27 年 9 月 4 日

** 正 会 員 日本 IBM (東京都中央区日本橋箱崎町 19-21)

*** 非 会 員 横浜国立大学 (神奈川県横浜市西区高島 1-1-2)

† 非 会 員 日本 IBM

1.2 関連応用

特定物体認識としてGoogle画像検索が知られている¹³⁾。商品をカメラで撮影し、その写真をアップロードすると候補となる商品名または類似した画像が概ね 1 秒以内に提示される。街で見かけた気になる商品の名称や詳細を知りたい場合に非常に有効と思われる。しかしながら、複数の商品が 1 枚の写真に写り込んでいる場合や商品が斜めから撮影された場合には正しく認識されないことがあるため、画像検索に使用できる写真には制限がある。

1.3 実利用のための課題

商品の認識など実利用に特定物体認識技術を応用するためには、高い認識精度や高速処理に加えて、実利用の際の利便性やインターフェースも重要である。たくさんの商品をすべて認識したい場合には、1 枚の写真の中に納まる複数の商品を一度に認識できれば効率化が図れる。また、商品がある程度斜めから撮影された写真であっても認識できるようなロバスト性も実用には重要な要素である。このように実利用を見据えた課題においても、本研究によって他の応用事例に対する優位性を示すことができた。

2. GIFTS 画像局所特徴および KD-Tree

2.1 GIFTS 画像特徴

GIFTS画像特徴には、キーポイント、特徴ベクトルおよび 2 つのキーポイントの類似尺度の 3 つの要素が含まれる。GIFTS では、回転および拡大縮小に不変な画像特徴点 (キーポイント) の検出方式として、ORBで使用されているoFAST (Oriented FAST)を採用した⁵⁾。oFASTでは、まず、原画像および、原画像を $1/\sqrt{2}$ 倍ずつ繰り返し 7 回縮小した、8 オクターブの多重解像度画像を得る。それぞれの画像の各画素について、半径Rの円周上にある 16 画素を、濃淡差により明画素、暗画素および類似画素に分類し、明画素あるいは暗画素が 9 個以上連続している場合に、その画素をキーポイントとする。図 1 に、注目画素pとその周囲の円周上の 16 個の画素 (番号 1~16) のpとの濃淡差について示す。

ここでは右回りに番号 12~16, 1~7 の 12 個の画素が暗画素として連続しており、注目画素 p がキーポイントであることがわかる。また、キーポイントのオリエンテーションは、中心座標を起点として、半径 R の円周内部の画素値の重心座標を終点としたベクトルの向きとする。GIFTSでは、キーポイントの特徴ベクトルとして、キーポイントの周囲 31×31 画素の中で 128 個の画素ペアを選択し、その画素ペアの画素値の差を特徴ベ

Fig.1 GIFTS keypoints

トルとしている。

図 2 に、GIFTS特徴ベクトル生成のための画素ペアを示す。128 個の画素ペアの座標の選択方法は以下のとおりである⁵⁾。

Step 1:

マスター画像群からランダムに10万個のキーポイントを選択し、キーポイントの周囲31×31画素のすべての画素ペアについて、画素値の差分の分散を計算し、最も分散の大きい画素ペアを選択する。

Step 2:

残りの画素ペアの中で最も分散が大きく、かつ、すでに選択されたすべての画素ペアとの相関の絶対値がある閾値以下の画素ペアを選択する。

Step 3:

128 個の画素ペアが選択できるまで Step2 を繰り返す。マスター画像群のキーポイントから画素ペアを選択することにより、検索対象物体の画像局所特徴に合致した画素ペアが選択される。

特徴ベクトルの要素は 128 次元の実数であり、キーポイントのオリエンテーションをもとに図 2 の画素ペアの座標を回転させて特徴ベクトルを計算することにより、物体の回転にロバストなキーポイントとなっている。一方、ORBでは 256 個の画素ペアの画素値の差を二値化して 256 ビットの特徴ベクトルを得ており、これが GIFTS と ORB との特徴ベクトルの違いとなっている。2 つのキーポイントの類似度として、特徴ベクトルの大きさを 1 に正規化し、2 つの特徴ベクトルのユークリッド距離を使用する。上記のキーポイント検出、特徴ベクトル計算および 2 つのベクトルの類似尺度を総称して GIFTS と呼ぶ。

2.2 KD-Tree

KD-Treeは二分木のk次元への拡張である。K次元のベクトル群から木構造を生成し、クエリー対象ベクトルと最も距離の近いノードに配置されたベクトルを探索する。KD-Treeでは、 $O(M \cdot \log N)$ オーダーの探索時間でマスター画像とクエリー画像との照合が可能と考えられる⁶⁾。ここでMはKD-Tree生成に使用したマスター画像群のキーポイント総数、Nはクエリー画像のキーポイント数である。

マスター画像が 1 万枚の場合、マスター画像 1 枚あたり平均 1000 個のキーポイントがあるとする、1000 万個の特徴ベクトルによりKD-Treeが生成される。照合時にはKD-Treeを探索し、クエリー画像の特徴ベクトルそれぞれについて、最も距離の近い特徴ベクトルの含まれるマスター画像に投票する。投票数が閾値以上で最も投票数の多いマスター画像を検索結果とする。KD-Treeの生成および探索には FLANNライブラリーを使用した¹⁴⁾。

Fig.2 128 pixel pairs for generating feature vectors of GIFTS keypoints

3. 大規模書籍照合システム

本稿で対象とする書籍は、日本で流通しているものだけで数十万種類と言われている。マスター書籍は出版社ごと、あるいは出版時期ごとに分けて複数のKD-Treeを生成する。マスター書籍数の増加に伴い、計算機で使用するコアを増やし、複数のコアにKD-Treeを配置して並列にクエリーを実行する。このようなシステム構成をとることにより、マスター画像の枚数が増加しても、探索時間を一定時間以内に収めることが可能となる。

この実験では約1万枚のマスター画像ごとにKD-Treeを生成し、プロセッサコアに配置する。照合時には各コアのKD-Treeを探索し、最も一致するキーポイントの多いマスター画像を検索結果とする。

なお、表紙の類似した書籍が検索結果となる場合があるため、上位 n 個の検索結果を求める。図3にシステム構成を示す。書籍約1万冊ごとにグループ分けした表紙の画像をマスター画像群 $G1, G2, \dots, Gx$ とする。検索サーバーにおいて各々の画像の GIFTS 特徴量を抽出し(a), マスター画像群ごとにKD-Treeを生成してプロセッサコアに配置しておく(b)。ユーザーは検索対象の書籍の表紙をタブレット端末で撮影し、それをクエリー画像として検索サーバーに送信する(c)。検索サーバーにおいてクエリー画像から GIFTS 特徴量を抽出し、各プロセッサコアでマスター画像群の GIFTS 特徴量とのKD-Tree探索による照合を行って一致する画像の候補を抽出する(d)。その結果をタブレットに送信し、タブレットは受信した探索結果を表示する(e)。本論文では、手順(c)から(e)に相当する、タブレット端末から画像を送信してから照合結果が表示されるまでの時間を書籍照合時間と呼び、手順(d)に相当する、検索サーバーが画像を受信してから、サーバー内部で照合結果を得るまでの時間を探索時間と呼ぶ。タブレット端末に表示された照合結果の例を図4に示す。書籍画像に検索結果がオーバーレイ表示される。表示されるデータは、書籍名・ISBN・在庫数・入れ替え指示などであり、書店での店頭在庫管理に必要な表示内容となっている。複数の書籍を一括して照合できることは、バーコードにはない利点と考えられる。

Fig.3 System configuration

4. 実証実験と考察

GIFTS 特徴を使用した画像照合手法の認識性能と処理速度とを測定した。インターネットから書籍の表紙画像を10万点収集し、これをマスター画像とした。マスター画像のサイズは 120×180 画素から 300×450 画素である。実験には IBM Power8 サーバー (3.72GHz, 20 core, 512GB memory, OS: RHEL) を使用した。プロセッサの1コアごとに1万枚前後のマスター画像を割り当て、探索時間の実測を行った。ここではコアあたりの実験結果を示す。マスターに含まれる書籍1000冊と、マスターに含まれない書籍1000冊について、それぞれの書籍を鉛直方向から0度、15度、22.5度および30度傾けた4つの画像を用意し、合計8000枚のクエリー画像を作成した(図5)。

4.1 予備実験

マスターに含まれない書籍もクエリー画像となる可能性があるため、マッチするキーポイント数の下限を設定し、それ未満のキーポイント数であれば該当書籍なし(リジェクト)という判定が必要となる。このキーポイント数のしきい値を設定するための予備実験を行った。マスター画像を1万枚登録し、8000枚のクエリー画像に対して、キーポイント数のしきい値を変化させて Precision および Recall を測定した(図6)。

Precision および Recall は以下のように定義される。

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

ここで、TP (True Positive) は正解クエリーの数、FP (False Positive) は、クエリー画像はマスターに存在しないが、いずれかのマスター画像をクエリー結果と誤判定した数であり、FN (False Negative) は、クエリー画像はマスターに存在するが、マスターにないと誤判定した数である。

Precision と Recall との調和平均はF値と呼ばれ、F値が高いほど検索システムの精度が高いとされる¹⁵⁾。GIFTSのF値を図7に示す。この図よりキーポイント数のしきい値をF値が極大となる50とした。

Fig.4 An example of query results on a tablet PC

Fig.5 Examples of query images having 4 tilt angles

Fig.6 Precision / Recall curve (GIFTS)

Fig.8 Recognition accuracy and reject ratio by the tilt angles of the query images (GIFTS)

Fig.7 F-measure (GIFTS)

Fig.9 Average query time by the number of master images (GIFTS)

4.2 実証実験

マスター画像を1万枚登録し、クエリー画像の鉛直方向からの傾きごとの、マスターに存在する4000枚のクエリー画像に対する正答率および、マスターに存在しない4000枚の画像のリジェクト率を測定した(図8)。正答率%は、

$$(\text{正解クエリー数} / \text{クエリー画像枚数}) \times 100$$

と定義し、リジェクト率%は、

$$(\text{正解リジェクト数} / \text{クエリー画像枚数}) \times 100$$

と定義する。

マスター画像中の書籍とクエリー画像中の書籍との傾きの差が22.5度以下の場合には99%以上の正答率が得られ、またどの傾き角においても99%以上のリジェクト率を得た。また、マスター画像が10万枚の場合においても同等の正答率を得ることができた。なお、実証実験では、マッチするキーポイント数がしきい値50以上の上位3個までの検索結果を表示する。同じコンテンツの書籍が単行本と文庫版で出版されている場合など、類似の表紙デザインの書籍が検索結果として複数表示されることがある。ただし、このような場合でもクエリー画像と同じ書籍のマスター画像のスコアが最大となるため、2番目以降の順位の検索結果が正解となるケースは見られなかった。

図9に登録したマスター画像枚数ごとの平均探索時間を示す。画像あたりの最大キーポイント数は、マスター画像・クエリー画像ともに1000とした。KD-Treeに約1万枚のマスター画像の特徴ベクトルを配置した場合は探索時間が0.15秒となり、 $O(M \cdot \log N)$ オーダーの探索時間であることが確認できた。さらに、図3のシステム構成において、10コアのKD-Treeに10万枚のマスター画像の特徴ベクトルを配置した場合においても0.2秒以内の探索時間であることを確認した。

4.3 GIFTSとSIFTとの比較

SIFTにおいてもGIFTSと同様にPrecision/Recall曲線およびF値を求め、キーポイント数のしきい値を30に設定した(図10および図11参照)。マスター画像を1万枚登録し、クエリー画像の傾き角ごとの正答率を測定した。マスター画像の枚数が1万枚、クエリー画像が4000枚の場合のGIFTSとSIFTとの正答率の比較を図12に、リジェクト率の比較を図13に示す。

GIFTSでは、マスター画像あたりの最大キーポイント数が1000の場合と300の場合(GIFTS-2とする)の2種類で正答率を計測した。その理由は、一般的にキーポイントの数が多いほどマスター画像とクエリー画像とでマッチするキーポイント数が多くなるため、全マスター画像のキーポイント総数がSIFTの3倍程度となるGIFTSは正答率で有利になる可能性があるためである。GIFTS-2(マスター画像あたりの最大キーポイント数:300)では、キーポイント総数が約260万個となり、ほぼSIFTのそれに近く、同程度のキーポイント総数での比較となる。

GIFTSは平均探索時間がSIFTより長いものの、総じてSIFTより高い正答率が得られた(表1および図12参照)。GIFTSでは8オクターブの多重解像度画像からコーナー特徴を検出してキーポイントとするため、一般的にSIFTと比べて検出されるキーポイントの数が多い。そのため、KD-Treeの探索回数に比例して探索時間が長くなると考えられる。また、同じ理由により、GIFTSではクエリー画像中の書籍の傾きが大きくなっても、マスター画像とクエリー画像とで一致するキーポイントの数を確保しやすいため、高い正答率が得られたものと考えられる。次に、SIFTと同程度のキーポイント総数であるGIFTS-2とSIFTとを比較する(表1、図12および図13参照)。

Fig.10 Precision / Recall curve (SIFT)

Fig.11 F-measure (SIFT)

Fig.12 Recognition accuracy by the tilt angles of query images

総じて GIFT-2 の方が正答率およびリジェクト率が高く、かつ、平均探索時間が短いことがわかる。この理由は、SIFTは平面内での回転および拡大・縮小にロバストなキーポイントであるが、鉛直方向からの傾きに対しては、高い照合精度が得にくいためと考えられる¹⁶⁾¹⁷⁾。また、GIFTS-2 の正答率およびリジェクト率は GIFTS より低く、同じキーポイント特徴同士の比較では、画像あたりの最大キーポイント数が照合精度に影響することが見てとれる。以上の実証実験の結果より、GIFTS は正答率・リジェクト率ともに高く、高い照合精度の要求される書籍照合システムに実利用可能であると考えられる。

4.4 GIFTS と ORB との比較

ORB はキーポイント検出および特徴ベクトルの計算量が SIFT に比べて二桁程度少ないが、比較的高い認識精度を持つキーポイント特徴として知られている⁹⁾。ORB の特徴ベクトルは 256bit のビットパターンであるため、ハッシュテーブルを使用する LSH に向けた特徴ベクトルと考えられる。LSH は KD-Tree と同様に FLANN ライブラリーを使用した。

GIFTS と同様に、マスター画像の枚数ごと、クエリ画像の鉛

Fig.13 Reject ratio by the tilt angles of query images

Table 1 Comparison of GIFTS and SIFT (10 thousand master images case)

	GIFTS	GIFTS-2	SIFT
Max keypoints/image	1000	300	1000
Total keypoints	7,185,731	2,674,683	2,491,024
Keypoints generation sec	39	34	178
Feature vectors generation sec	25	17	367
KD-Tree generation sec	114	42	39
Average query time sec	0.148	0.044	0.112
Accuracy (0°) %	100.0	100.0	99.2
Accuracy (15.0°) %	99.7	99.1	96.8
Accuracy (22.5°) %	99.2	97.9	95.2
Accuracy (30.0°) %	96.9	92.4	91.4

直方向からの傾きごとの、合計 8000 枚のクエリ画像に対する正答率 (図 14) およびリジェクト率 (図 15) を測定した。

クエリ画像中の書籍の傾き角が 22.5 度以下では 98% 以上の正答率が得られたものの、同一の画像セットを使用して測定した GIFTS と比較すると、GIFTS のほうが正答率およびリジェクト率が高いことがわかる。この理由として、ORB では特徴ベクトルの計算時に画素ペアの差分を二値化してビットパターンを生成するため、二値化により情報が失われる。このため類似の表紙デザインをもつ書籍間の弁別能力が GIFTS より低いものと考えられる。

また、GIFTS と ORB のクエリ所要時間を図 16 に示す。いずれも $O(M \cdot \log N)$ オーダーのクエリ所用時間となっているが、ORB の探索時間が GIFTS より一桁長いという測定結果となった。探索時間については、KD-Tree と LSH という異なる探索アルゴリズムでの比較であり、定量的な議論は困難と思われる。

Fig.14 Recognition accuracy by the tilt angles of query images (GIFTS vs. ORB)

Fig.15 Reject ratio by the tilt angles of query images

4.5 GIFTS, SIFT および ORB の手法の相違

ここで使用した 3 つの手法の相違点について表 2 に示す。GIFTS はキーポイントとしてコーナー特徴を利用することにより SIFT と比較してチルト角の変化にロバストであり、特徴ベクトルが 128 次元の実数であることにより類似画像との照合において ORB よりも高い弁別性能が得られたと考えられる。

5. おわりに

GIFTS と命名した木構造探索に向けた画像局所特徴および KD-Tree の組み合わせによる大規模特定物体照合システムを提案し、実利用可能な認識精度および照合時間が達成できるかを検証した。10 万点規模の書籍の検索に提案システムを適用し、スター画像中の書籍とクエリー画像中の書籍との鉛直方向からの傾きの差が 22.5 度以下の場合において、99% 以上の高い正答率を得ることができ、そのときの検索サーバー内部での探索所要時間は 0.2 秒以内であった。また、SIFT および ORB との照合精度の比較を行い、GIFTS の優位性を確認した。実験システムはシングルユーザーのため、1 秒以内の応答速度でタブレット端末から照合結果を得ることができるが、システムを拡張することにより、マルチユーザーの場合においても 1 秒以内の応答時間を得ることは可能と考えられる。

今後の課題としては、書店での実運用による性能指標の改善

および書籍以外の商品への展開があげられる。また、視力の弱い方が店頭で商品を購入する際の商品認識などの支援ツールとしての活用も期待できる。類似のパッケージで種類の異なる商品群を識別することが可能であり、画像で識別した商品名をタブレットが音声で読み上げることにより介助することができる。

Fig.16 Average query time by the number of master images

Table 2 Comparison of GIFTS, SIFT and ORB

	GIFTS	SIFT	ORB
Keypoint	oFAST	SIFT	oFAST
Feature vector	128-dimension real number components	128-dimension real number components	256-dimension binary bit pattern
Distance of two keypoints	Euclidian distance of the two feature vectors	Euclidian distance of the two feature vectors	Hamming distance of the two feature vectors
Nearest neighbor search	KD-Tree	KD-Tree	LSH

参考文献

- 1) D. Lowe: Distinctive Image Features from Scale-Invariant Keypoints, International Journal of Computer Vision, 60, 2 (2004), 91.
- 2) Y. Ke and R. Sukthankar: PCA-SIFT: A More Distinctive Representation for Local Image Descriptors, CVPR, 2, (2004), 506.
- 3) H. Bay, T. Tuytelaars, and, L. Van Gool: Surf: Speeded up Robust Features, European Conference on Computer Vision, (2006), 404.
- 4) L. Juan and O. Gwun: A Comparison of SIFT, PCA-SIFT and SURF, International Journal of Image Processing, 3, 4 (2009), 143.
- 5) E. Rublee, et.al.: ORB: an Efficient Alternative to SIFT or SURF, ICCV2011, (2011), 2564.
- 6) S. Arya, et. al.: An Optimal Algorithm for Approximate Nearest Neighbor Searching in Fixed Dimensions, Journal of the ACM, 45, 6 (1998), 891.
- 7) A. Andoni: Near-optimal Hashing Algorithms for Approximate Nearest Neighbor in High Dimensions, 47th Annual IEEE Symposium on Foundations of Computer Science, (2006), 459.
- 8) M. Muja and D. Lowe: Fast Matching of Binary Features, Conference on Computer and Robot Vision (CRV'12), (2012), 404.
- 9) K. Kise, K. Noguchi, and, M. Iwamura: Simple Representation and Approximate Search of Feature Vectors for Large-Scale Object Recognition, BMVC2007, 1, (2007), 182.
- 10) 佐藤智一, 岩村雅一, 黄瀬浩一: 空間インデクシングに基づく距離推定を用いた高速かつ省メモリな近似最近傍探索, 電子情報通信学会技術研究報告(PRMU), 112, 441 (2013), 73.
- 11) Y. Uchida, K. Takagi and S. Sakazawa: An Alternative to IDF: Effective Scoring for Accurate Image Retrieval with Non-Parametric Density Ratio Estimation, Proc. ICPR, (2012), 1285.
- 12) 長谷川昂宏, 山内悠嗣, 安倍満, 吉田悠一, 山下隆義, 藤吉弘亘: Cascaded FASTによるキーポイント検出, 電子情報通信学会論文誌, Vol. J98-D, 4 (2015), 560.
- 13) <https://www.google.co.jp/imghp>
- 14) M. Muja and D. Lowe: FLANN: Fast library for approximate nearest neighbors, <http://www.cs.ubc.ca/research/flann>.
- 15) T. Fawcett: An Introduction to ROC Analysis, Pattern Recognition Letters, 27, 8 (2006), 861.
- 16) 藤吉弘亘: 画像局所特徴量 SIFT とそれ以降のアプローチ, MIRU2013 チュートリアル, 2013.
- 17) D. Bekel, M. Teutsch, and, T. Schucherty: Evaluation of Binary Keypoint Descriptors, ICIP2013, (2013), 3652.