

見かけ特徴の組み合わせと距離尺度の学習を用いた 3 次元形状類似検索

古屋 貴彦[†] 大 淵 竜 太 郎[†] (正会員)

[†] 山梨大学

Visual Feature Combination and Distance Metric Learning for 3D Shape Retrieval

Takahiko FURUYA[†], Ryutarou OHBUCHI[†] (Member)

[†] University of Yamanashi

〈あらまし〉既存の 3 次元形状類似検索手法の多くは、限定的な種類の形状 (例えば、剛体機械部品の CAD モデル) が限定的な形状表現法 (単連結の閉じたメッシュなど) で表現されていることを想定している。しかし、3 次元モデルの急増と多様化に伴い、複数の形状表現で定義され、多様な形状をもつ 3 次元モデルを対象とした 3 次元モデル検索システムへの要求が高まってきた。我々が先に提案した、3 次元モデルを多視点からの見かけで比較する手法¹⁾は、姿勢変化 (関節の屈曲等) に対し不変で、幅広い形状表現を扱うことができる。同手法は、3 次元モデルを多視点でレンダリングし、その画像群から顕著点に基づく画像の局所特徴を抽出して形を比較する。評価の結果、同手法は、姿勢変化を許した 3 次元モデル群に対して良い検索精度を示したが、反面、姿勢変化がなく、複雑な形を持つモデル群の検索精度が低かった。本論文では、手法¹⁾を元に、姿勢変化に対する不変性を備えつつ、多種の形状を精度よく検索できる手法を目指す。提案手法は、多視点レンダリング画像から密に抽出した多数の局所特徴で、形状を比較する。また、大域的な形状特徴を補うため、見かけの大域特徴を併用する。さらに、距離空間の学習により、特徴分布を考慮した距離比較を行う。複数の標準ベンチマークや 3 次元モデル検索コンテストによる評価実験の結果、提案手法は従来法より高い検索精度を示した。

キーワード : 3 次元モデル, マルチメディア情報検索, 形状モデリング, 距離尺度の学習, 特徴の組み合わせ

<Summary> Majority of existing algorithms for shape-based 3D model retrieval presumes a specific shape class (e.g., rigid-body CAD model of mechanical parts) defined by using limited shape representation methods (e.g., singly-connected, closed mesh). Recently, however, need has arisen for a more versatile algorithm capable of handling wider class of shapes (e.g., articulated models) represented by using diverse shape representations. We have previously proposed an appearance based algorithm for 3D model retrieval that possesses invariance to articulation (global deformation) and is able to handle diverse shape representations¹⁾. The algorithm extracts local image descriptors at interest points of 2D depth images rendered from multiple viewpoints about 3D models. The algorithm achieved good retrieval accuracy for articulated, simpler 3D shapes. However, retrieval accuracy was not satisfactory for some other classes of shapes, e.g., complex and rigid models. In this paper, we propose a 3D model retrieval algorithm that can handle a wider class of shapes. The proposed algorithm is based on¹⁾, but employs randomly and densely sampled local visual features as well as a global visual feature. Distances among 3D models are computed by using distance metric learning. Experimental evaluations using multiple standard benchmarks as well as international 3D model retrieval contests have shown that our proposed algorithm outperforms many existing methods.

Keywords: 3D shape retrieval, multimedia information retrieval, distance metric learning, feature combination

1. はじめに

工業, 医療, 娯楽等の分野における 3 次元モデルの利用拡大, 安価な 3 次元スキャナや 3 次元プリンタの普及, Trimble 3D Warehouse²⁴⁾に代表されるユーザ投稿型データベースの登場, 等により, 多様な形を持つ 3 次元モデルの数が

爆発的に増えてきた。こうした多量の 3 次元モデルを効率良く管理し再利用する為に, 3 次元形状類似検索への要求が高まっている。

3 次元モデルの形状比較では, (1) モデルの形の種類 (例えば, 機械部品の CAD モデル, 人の顔モデル等), (2) モデルの形状表現 (例えば, 多様体メッシュ, B-rep ソリッド, 点群,

ポリゴンスープ等), (3) 大域幾何変換 (例えば, 回転や相似変換等), の 3 種類の不変性が要求される. さらに, 場合によっては, (4) 姿勢変化や大域変形に対する不変性も要求されることがある.

既存手法のほとんどは大域幾何変換に対して一定の不変性を備える. しかし, 多様な形の種類からなるモデル群に対して高い検索精度を示す手法は少ない. 例えば, 姿勢変化モデルの検索を狙った手法の多く¹⁾⁻⁵⁾は, 他種のモデルの検索精度が低下する傾向にある. また, 乗り物や家具など, 多様なカテゴリの剛体モデル群に対して高い検索精度を示す手法^{6), 7), 8), 10)}も, 例えば姿勢変化モデル群に対しては検索精度が低下する. さらに, 既存手法の一部は形状表現に対する不変性に欠け, 例えば, 密にサンプルされた多様体メッシュ同士しか比較できない. その結果, これらの既存手法は, Trimble 3D Warehouse のように, モデルの種類や形状表現が多様なデータベースの検索には不向きである. 本論文では, 多様な形状表現を扱え, かつ, 多種多様な形状のモデルを高精度に検索可能な手法を目指している.

形状表現に対する不変性が高い手法として, 3 次元モデルをレンダリングした見かけに基づいて比較する手法がある. 見かけで比較する手法の先駆けとなった Chen らの LFD⁶⁾は, 10 視点からレンダリングして生成したシルエット画像群の画像のそれぞれから, 画像全体の輪郭特徴と画像全体のモーメント特徴を抽出し, これらを組み合わせることで高い検索精度を得た. 後に LFD を改良した手法も複数提案されている^{7), 8)}. これらの手法はいずれも, 剛体モデル群に対して比較的高い検索精度を示す. しかし, 関節を持ち姿勢が変化する動物等のモデルを, 姿勢変化を無視して検索するには不向きである.

姿勢変化に対する不変性を得るため, 3 次元モデルの部分領域から複数の局所特徴を抽出し比較する手法³⁾⁻⁵⁾や, 部分形状間の位相情報を比較する手法^{1), 2)}が提案された. 例えば, Jain らは, メッシュスペクトル解析により形状の幾何情報と位相情報を同時に捉え, 姿勢変化による影響を抑えた特徴を抽出した¹⁾. また Smeets らは, メッシュに沿った測地線距離を局所特徴とした⁴⁾. これらの手法は姿勢変化モデル群に対して高い検索精度を示すが, 剛体モデルの検索精度が低い傾向にある. また, 多様体メッシュからしか特徴抽出できない等, 形状表現に対して不変でない手法が多い. さらに, 手法によっては多数の局所特徴を比較するために計算量が増え, 検索が遅い.

我々は先に, 大域的変形や姿勢変化に強く, かつ形状表現に不変な手法を目指し, 多視点画像から画像の局所特徴集合を抽出して 3 次元モデルを比較する BF-SSIFT 法を提案した¹¹⁾. BF-SSIFT 法では, 3 次元モデルを多視点 (例えば 42 視点) からレンダリングして得た多数 (42 枚) の 2 次元深さ画像の各々から SIFT 法¹²⁾を用いて複数の顕著点を検出する. 次に各顕著点において, 画像のスケール変化, 平行移動,




図 1. SSIFT, DSIFT, 1SIFT 特徴点の例 (N_p : 特徴点数).

Fig. 1. Examples of keypoints due to SSIFT, DSIFT and 1SIFT.




図 2. MSB, PSB, ESB の 3 次元モデルの例.

Fig. 2. Examples of 3D shapes in the MSB, PSB and ESB.

回転等に変性を持つ SIFT 特徴¹²⁾を計算する. 図 1(a), 1(d) は人のモデルと鉢に植えられた植物のモデルの深さ画像から顕著点を検出した例である. この図では, 赤い点が顕著点の位置, 緑の円が顕著点のスケールを示す. 局所特徴数は 1 画像当たり平均で数十個程度, 42 視点を合わせると 1 モデル当たり平均で数千個程度になる.

これら多数の局所特徴の集合をそのまま, 他の 3 次元モデルから得た同様の集合と比べると, その比較の計算量が大きくなり, 実用的でない. 3 次元モデルが多数の局所特徴の集合で記述された場合に, 3 次元モデル間の比較を効率化するため, BF-SSIFT 法では Bag-of-Features (BF) 法 (例えば¹³⁾)を用いて多数の局所特徴を 1 つの特徴ベクトルに統合した. BF 法では, 予めデータベースの 3 次元モデルから抽出した大量の局所特徴群に対してクラスタリングを適用し, 局所特徴を符号 (視覚単語)として量子化する為のコードブック (代表ベクトル群) を学習する. モデルから抽出された数千個の局所特徴は, ベクトル量子化によりいずれかの代表ベクトル (視覚単語)に置換され, これら視覚単語の出現頻度ヒストグラムがそのモデルの BF 特徴ベクトルとなる. モデル当たり n 個の局所特徴を 1 対の 3 次元モデルの間で全対比較する場合

の計算量が $O(n^2)$ なのに対し、BF 法の場合は $O(1)$ である。

BF-SSIFT 法を実験的に評価した結果、図 2(a)のような姿勢変化モデル群から成る McGill 3D Shape Benchmark (MSB)¹⁴⁾において、当時、最高性能を持つとされた Jain らの手法¹⁾と同等以上の検索精度を示した。しかし、図 2(b)のような多様なカテゴリの剛体モデル群から成る Princeton Shape Benchmark (PSB)¹⁴⁾では、BF-SSIFT 法の検索精度は、当時、比較的高性能とされた LFD⁶⁾や、改良版 LFD^{7),8)}と比べて同等、または劣る結果となった。剛体モデルの検索精度が落ちた原因の 1 つとして、顕著点検出の失敗が挙げられる。例えば、図 1(d)では、植物の葉に多数の (ある意味で過剰な) 顕著点が検出されている一方で、鉢の部分には顕著点がほとんど検出されていない。図 1(a)でも人間の胴体部分の形を十分に捉えるための顕著点が検出されたとはいえない。

本論文では、多様な形状表現方法で表された、多種多様な形を持つ 3 次元モデルを、姿勢変化や大域変形も考慮したうえで、高精度かつ高速に比較・検索する手法を提案する。

本論文で提案する手法では、顕著点検出をせず、密かつランダムに特徴点を配置する。モデルの見かけ画像において、モデル上、またはモデルの周辺にランダムに特徴点を配置し、各特徴点から SIFT 特徴を抽出する (BF-DSIFT²⁵⁾)。図 1(b), 1(e)は、密かつランダムに配置した特徴点の例である。胴体あるいは鉢にも一定数の特徴点が置かれ、顕著点検出で見落とされた形状特徴を捉えるであろう事が見て取れる。

さらに本論文では、検索精度向上のため、複数特徴の組み合わせと、距離空間の学習による距離計算精度の改善を導入する。まず、見かけの大域特徴 VM-1SIFT²⁶⁾を提案し、局所特徴 BF-DSIFT と組み合わせる。BF-DSIFT は局所特徴であるため、例えば U 字型のパイプと S 字型のパイプを区別するのに不向きである。モデルの種類によっては、既存手法と同様、大域特徴で比較した方が有利である。VM-1SIFT は、図 1(c), 1(f) の例のように、画像全体を覆う特徴領域から、画像当たり 1 個の SIFT 特徴を抽出する。さらに、検索精度の更なる向上を狙って距離空間の学習を導入する。BF-SSIFT では、ほとんどの既存手法同様、モデルの特徴ベクトル間を、固定距離 (L1 距離、Kullback-Leibler Divergence (KLD) 等) で比較した。しかし、特徴ベクトルは、特徴空間において一般に非線形な部分空間 (多様体) に沿って分布する傾向にあるため、特徴分布に適応した距離で比較することで、検索精度の向上が期待できる。Ohbuchi ら¹⁷⁾は、非線形な次元削減法を特徴空間に適用し、非線形な低次元空間で特徴同士を比較した。Tatsuma ら¹⁸⁾は、Spectral Clustering によって得たクラスタ群を利用し、特徴空間上の測地線距離を近似して比較した。また Ohbuchi ら¹⁹⁾は、Zhou らの Manifold Ranking (MR)²⁰⁾を用い、特徴の多様体上で有意度を拡散して得た測地線距離で、モデルの類似度順位を求めた。本提案手法も、Manifold Ranking を用いた、適応的距離尺度でモデルを比較する²⁶⁾。

本論文で提案する手法を、姿勢変化モデル群から成る MSB、

多様な剛体モデル群から成る PSB、CAD モデル群から成る Engineering Shape Benchmark (ESB)¹⁶⁾を用いて評価した。その結果、提案手法は既存手法よりも有意に高い検索精度を示した。また、3 次元形状類似検索の国際コンテスト SHape REtrieval Contest (SHREC) にも参加し、本手法は、姿勢変化モデルや多様な剛体モデルを対象とする複数の部門で 1 位を獲得した^{4),23)}。

本論文の貢献をまとめると以下の通りになる。

- 幅広い種類の形状に対して高い検索精度を持ち、幅広い形状表現に適用でき、かつ姿勢変化や大域変形に対し一定の不変性を備えた、見かけの画像から密に抽出した局所特徴の集合で比較する 3 次元形状比較手法を提案した。
- 上記の手法に大域特徴を組み合わせ、さらに、特徴分布に適応した高精度な距離比較を導入した。
- 提案手法を複数のベンチマークデータベースと検索コンテストの課題で実験的に評価し、提案手法の有効性を示した。

2. 提案手法

幅広い種類の形のモデル群に対する検索精度向上を狙い、以下の 3 点を改良する。(1) 密な局所特徴抽出: BF-DSIFT では、多様な特徴を捉えるため、レンダリングした画像上で密かつランダムに画像の局所特徴を抽出する。(2) 大域特徴との組み合わせ: BF-DSIFT で不足する大域的な特徴を補うため、大域特徴 VM-1SIFT を組み合わせる。(3) 適応的距離計算: Manifold Ranking (MR)を利用して、特徴分布に適応した距離比較を行う。さらに、BF-SSIFT, BF-DSIFT, VM-1SIFT の適応的距離を結合する。

2.1. 見かけから抽出する密な局所特徴 BF-DSIFT

3 次元モデルの多様な特徴を捉えるため、密な局所特徴抽出を行う。ただし、密な特徴抽出は、モデル当たりの特徴数を数万個に増加させ、局所特徴抽出とベクトル量子化の手間が増える。そこで、SIFT 計算の高速化のため、SIFT の GPU 実装の 1 つ SiftGPU²¹⁾を実装に用いる。また、ベクトル量子化の高速化のため、BF-SSIFT で用いた k -means によるコードブック学習と最近傍探索によるベクトル量子化に替え、乱雑化クラスタリング木の一種 Extremely Randomized Clustering Tree (ERC-Tree)²²⁾を用いる。図 3 に BF-DSIFT のモデル比較の流れを示す。

2.1.1. 多視点レンダリング

3 次元モデルを囲む多面体の頂点または面の重心 (視点数 N_i) からモデルを深さ値画像にレンダリングし、 N_i 個の 2 次元の見かけ画像群を生成する。多くの方向からモデルを捉えることで、重要な特徴の見落としを防ぐ。本手法では、正 20 面体に細分割処理を行うことで多面体を生成する。なお、3 次元モデルには予め位置 (x, y, z の 3 自由度) と大きさ (一様ス




図 3. BF-DSIFT 法によるモデル比較.

Fig. 3. Comparing a pair of 3D models by BF-DSIFT.

ケーリングの 1 自由度) の正規化を施しておく。レンダリングする深さ値画像のサイズは、予備実験の結果 256×256 [pixel] とした。本手法では、深さ値画像にさえレンダリングできれば、その後は 2 次元画像からの特徴抽出となる。したがって、本手法は、多様体メッシュ、ポリゴンスプ等の幅広い範囲の形状表現に適用可能である。

2.1.2. 密かつランダムな局所特徴抽出

多視点レンダリングで得た深さ画像の各々から、SIFT 特徴を抽出する。SIFT は、スケール変化、回転、アフィン変換等の幾何変換に対してある程度の変換性を持つ 128 次元の局所特徴である。さらに SIFT は画像の多重解像度表現を用いるため、モデルの大域的特徴と局所的特徴の双方を捉えることができる。

先行研究 BF-SSIFT では、SIFT 本来の顕著点検出アルゴリズムを用いた。顕著点検出による特徴数は、モデルにより異なり、PSB では平均 1,200 個程度であった (視点数 $N_i = 42$ の場合)。しかし、SSIFT では、図 1(a), 1(d) のように、人間の胴や植物の鉢からの特徴が不足していた。

提案手法 BF-DSIFT では、多重解像度表現の各画像において、輝度値が 0 でない部分にランダムに特徴点を配置する。この結果、モデルの上および周辺に、特徴点が密に配置され

る。次いで、各特徴点から、SIFT 特徴を抽出する。密に特徴を抽出することで、重要な特徴の見落としを防ぐ。特徴点の数は任意であり、例えば、モデル当たり約 1 万個の特徴が抽出される。図 1(b), 1(e) のように、人間の胴や植物の鉢にも多数の特徴点が配置される。

2.1.3. 局所特徴の統合

BF 法を用いて、多数の局所特徴をモデル毎に 1 個の BF 特徴に統合する。局所特徴はコードブックに入力され、最も距離の近い代表ベクトル (視覚単語) にベクトル量子化される。各視覚単語の頻度ヒストグラムが BF 特徴となる。

コードブックは、検索対象となるデータベースの全 3 次元モデルから抽出した局所特徴群を特徴空間でクラスタリングして得る。各クラスタの重心である代表ベクトルがそのクラスタを代表する視覚単語となる。先行研究 BF-SSIFT で用いた k -means は、分類性能が比較的高いが、計算量が大きかった。局所特徴の次元数を d 、学習サンプル数を N_i 、クラスタ数 (語彙数) を N_v とした場合、コードブック学習の計算量は、 $O(d \cdot N_i \cdot N_v)$ である。 k -means では、クラスタ重心が代表ベクトルとなる。各局所特徴は、最近傍探索により、最も距離の近い視覚単語に量子化される。モデル当たりの局所特徴数を N_f とした場合のベクトル量子化の計算量は、 $O(d \cdot N_f \cdot N_v)$ である。故に k -means は、多数の局所特徴に対するコードブック学習、ベクトル量子化手法として、計算量の面で不向きであった。

そこで提案手法では、コードブック学習とベクトル量子化の高速化のため、ERC-Tree を用いる。ERC-Tree では分割により得たクラスタ当たりの局所特徴数がパラメータ S_{min} 以下になるまで、再帰的に、かつランダムに特徴空間を分割し、これを木で表現し、その葉ノードが視覚単語となる。(葉 1 つあたりの特徴数は S_{min} 以下である。) 語彙数 N_v は、学習サンプル数 N_i とパラメータ S_{min} に依存するが、乱雑化アルゴリズムであるため多少ばらつく。コードブック学習の計算量は $O(N_i \cdot \log N_v)$ であり、 k -means より高速である。ベクトル量子化の際、コードブックに入力された局所特徴は、根から葉へ辿ることでベクトル量子化される。モデル当たりのベクトル量子化の計算量は、 $O(N_f \cdot \log N_v)$ である。ERC-Tree の分割超平面は軸に鉛直な向きに限定されるため、ERC-Tree のクラスタは k -means のそれよりも質が低い可能性がある。しかし、ERC-Tree の計算量は k -means の計算量よりも圧倒的に小さい。

2.1.4. 距離計算

先行研究 BF-SSIFT 同様、BF 特徴同士を KLD で比較する。モデル i と j の距離の計算式を式 (1) に示す。ただし、 $\mathbf{x}_i$ と $\mathbf{x}_j$ は i と j の BF 特徴、 x_{iw} は $\mathbf{x}_i$ における視覚単語 w の頻度、 N_v は語彙数である。KLD は対数関数の計算が必要なため遅い。しかしヒストグラムである BF 特徴の要素は整数であり、

その範囲も小さく、ほとんどのビンで要素数は 256 未満である。そこで、256 要素の対数値テーブルを利用し、高価な対数関数の計算を避けることで KLD の計算を高速化した。

$$d(i, j) = d_{KLD}(\mathbf{x}_i, \mathbf{x}_j) = \sum_{n=1}^{N_v} (x_{iwn} - x_{jwn}) \ln \frac{x_{iwn}}{x_{jwn}} \quad (1)$$

2.2. 大域特徴 VM-1SIFT

局所特徴 BF-DSIFT で不足する大域的な特徴を補うため、本来は局所特徴である SIFT を大域特徴化する。図 4 に VM-1SIFT のモデル比較の流れを示す。

BF-DSIFT と同様、3 次元モデルの位置とスケールの正規化を行い、多視点レンダリングして N_i 個の深さ画像を生成する。次いで、 N_i 個の深さ画像の各々から、見かけの大域特徴を抽出する。図 1(c), 1(f) の例のように、画像の中央に特徴点を置き、モデル全体を覆う範囲を特徴領域とし、1 個の SIFT を抽出する。モデル当たり視点数 N_i 個の SIFT 特徴が抽出される。

距離計算では、モデル当たり N_i 個の SIFT 特徴を全対で比較する。モデル i と j の距離の計算式を式 (2) に示す。ただし、 $\mathbf{x}_{ip}$ と $\mathbf{x}_{jq}$ は視点 p と q の 1SIFT 特徴、 N_i は視点数である。

$$d(i, j) = \sum_{p=1}^{N_i} \min_{1 \leq q \leq N_j} d_{KLD}(\mathbf{x}_{ip}, \mathbf{x}_{jq}) \quad (2)$$




図 4. VM-1SIFT 法によるモデル比較。

Fig. 4. Comparing a pair of 3D models by VM-1SIFT.

2.3. 適応的な距離による比較と特徴の組み合わせ

2.3.1. 適応的な距離の学習

Manifold Ranking (MR)²⁰⁾を利用して、特徴分布に適応した距離でモデル同士を比較する。図 5 は、3 次元の特徴空間に生成したトイデータ群に対して MR を行った結果例である。MR では特徴空間上で重み付きのメッシュグラフ $\mathbf{W}$ を生成し、

グラフの辺を介して有意度を拡散させる。有意度の拡散元 (検索要求モデル) から、より多くの有意度が流れ込んだ頂点 (検索対象モデル) ほど、検索結果の上位にランク付けされる。

メッシュグラフ $\mathbf{W}$ におけるモデル i と j の重み W_{ij} を式 (3) で求める。 $d(i, j)$ は、BF-SSIFT, BF-DSIFT, VM-1SIFT のいずれかで求めた距離、 σ は拡散範囲を決定するパラメータである。図 5 の例では近傍数個の頂点を接続したメッシュグラフを生成したが、実際には頂点の全対で接続する。

$$W_{ij} = \begin{cases} \exp(-d(i, j)/\sigma) & \text{if } i \neq j \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

式 (4) により、グラフラプリアン $\mathbf{L}$ を生成する。ただし、 $\mathbf{D}$ は対角行列で、 $\mathbf{D}$ の対角成分は $D_{ii} = \sum_j W_{ij}$ である。

$$\mathbf{L} = \mathbf{D}^{-1/2} (\mathbf{D} - \mathbf{W}) \mathbf{D}^{-1/2} \quad (4)$$

式 (5) を解く。 $\mathbf{Y}$ は有意度の拡散元を定義する。本論文の評価実験では、全モデルから拡散を発生させるため、 $\mathbf{Y} = \mathbf{I}$ (単位行列) とする。 $\mu > 0$ は拡散の強さを決定する正則化パラメータである。 F_{ij} がモデル i から j へ拡散した有意度を示す。 F_{ij} は類似度を表すため、実際には $-F_{ij}$ が適応的距離となる。

$$\mathbf{F} = (\mathbf{I} + (1/\mu) \mathbf{L})^{-1} \mathbf{Y} \quad (5)$$

BF-SSIFT, BF-DSIFT, VM-1SIFT に MR を適用した手法を、それぞれ MR-BF-SSIFT, MR-BF-DSIFT, MR-VM-1SIFT と呼ぶ。




図 5. Manifold Ranking による拡散の例 (トイデータ)。

Fig. 5. Example of relevance diffusion by Manifold Ranking (Toy data).




図 6. 適応的距離の組み合わせ。

Fig. 6. Combination of adaptive distances.

2.3.2. 特徴の組み合わせ

画像等の内容に基づく検索等の場合、複数の特徴を何らかの方法で組み合わせると検索精度が向上することが多い。本論文の手法では、MR-BF-SSIFT, MR-BF-DSIFT, 及び MR-VM-1SIFT の各々で求めた適応的距離を重みなしで線形

結合し、これを最終的なモデル間の距離とする (図 6)。予備実験において重みを一定の範囲で変えて実験を行ったが、重みを変えても検索精度にほとんど影響しなかった。そこで、同一重みによる線形結合を採用した。

3. 実験と結果

評価実験では、3つのベンチマークを用いた。MSB¹⁴⁾は、人、手、ペンチ、鋸など 255 個、10 カテゴリーの姿勢変化モデル群から成る (図 2(a))。MSB のモデルは密にサンプルされた閉メッシュであるが、形状そのものは単純である。PSB¹⁵⁾ではその Test セットを用いた。PSB Test セットは、乗り物、家具、植物など多様な形状を持つ、剛体を中心とした 907 個の 3 次元モデルモデルが、92 カテゴリーに分類されたデータベースである (図 2(b))。PSB は閉じたメッシュ、開いたメッシュ、ポリゴンスプ等、座標値にノイズを含むメッシュ、疎にサンプルされたメッシュ、等を含む。ESB¹⁶⁾は、ネジ、パイプ、歯車など 867 個、45 カテゴリーの機械部品 の CAD モデル群を比較的疎な閉メッシュで表現した 3 次元モデルから成る (図 2(c))。MSB と PSB ではデータベース内の全モデルを検索要求として検索を行って評価する。ESB では 867 個の検索対象モデルとは別に用意された 45 個の CAD モデルが検索要求となる。

検索精度の評価尺度は、R-Precision とした。R-Precision [%] は、検索要求 Q が属するカテゴリのモデル数を q とした場合の、検索結果上位 q 個中に含まれる正解モデルの割合である。

BF-SSIFT、BF-DSIFT の BF コードブック生成に用いる学習サンプルは、評価に用いるデータベースの 3 次元モデル群から抽出した大量の SIFT 特徴から $N_t = 500,000$ をランダムに選択して用いた。BF コードブックの語彙数は検索精度を左右する。3.4 節の実験では語彙数と検索精度の関係を調べるが、それ以外の実験では表 1 の語彙数を用いた。

MR のパラメータは、 $0.0025 \leq \mu \leq 50.0$, $0.01 \leq \sigma \leq 0.5$ の範囲で値を変化させて予備実験を行い、最も検索精度が高い μ と σ の値を用いた。

表 1. 実験に用いたコードブックの語彙数 N_v

Table 1. Vocabulary sizes used for the experiments.

手法	PSB	MSB	ESB
BF-SSIFT	1,200	900	600
BF-DSIFT	30,215	31,770	35,736

3.1. 計算時間

表 2 に、PSB (モデル数 907 個)における検索 1 回あたりの計算時間を示す。多視点レンダリングの視点数は $N_f = 42$ とした。SIFT 特徴抽出には SiftGPU²¹⁾を用いた。ベクトル量子化には、BF-SSIFT は k -means コードブック、BF-DSIFT は ERC-Tree コードブックを用いた。計算環境は、CPU が Intel Core i7 3930K 3.2GHz (シングルスレッド動作)、GPU が

NVIDIA GeForce GTX 670、メモリ容量が 64 GBytes である。

BF-SSIFT は、2.1.3 節で述べたように、最近傍探索によるベクトル量子化の計算量が大きい。しかし、モデルあたりの平均特徴数が約 1,200 個と DSIFT より少ないため、検索 1 回あたり 0.66 秒と、比較した手法の中では最も高速であった。

BF-DSIFT は 3 次元モデル 1 つあたりの特徴数が約 13,000 と、BF-SSIFT の約 10 倍に増えた。それにも関わらず、GPU の並列処理により SIFT 特徴抽出時間の増加は 3 倍程度に抑えられた。また、BF-DSIFT の語彙数は約 30,000 と、BF-SSIFT より大幅に増加したにも関わらず、木構造コードブックの利用により、ベクトル量子化は約 10 倍高速化した。結果として、検索 1 回あたり 1.37 秒と、実用に耐え得る時間での検索が可能となった。

VM-1SIFT は、3 次元モデル 1 つあたりの特徴数は 42 と少数だが、特徴 1 つがカバーする画素数が多いために SIFT 特徴抽出が遅く、3.54 秒要する。また、特徴の全対比較を行う距離計算に、0.547 秒要する。結果として検索 1 回あたり 4.17 秒要した。

MR-BF-DSIFT では検索 1 回あたりでは 5.39 秒要したうち、MR 法に 4.08 秒と大部分の時間がかかっている。約 5 秒の処理時間は、「インタラクティブ」な検索システムと呼ぶには少々遅い。MR 法は、検索要求が与えられる毎にメッシュグラフの生成と拡散処理を行う必要があるため、計算量が大きい。MR 法の検索精度は高いが、その計算量はモデル数が増えた時に課題となる。

BF 法の前処理であるコードブック学習では、128 次元の SIFT 特徴の学習サンプル数を $N_t = 500,000$ とした場合、 k -means クラスタリング (語彙数 $N_v = 1,200$)では約 1,700 秒、ERC-Tree クラスタリング (語彙数 $N_v = 30,053$)では約 1 秒を要した。同じ語彙数では ERC-Tree の方が、わずかに検索精度が落ちる。しかし、 k -means では長時間を要する語彙数の大きなコードブックも、ERC-Tree ならば高速に学習可能である。

表 2. 検索 1 回あたりの計算時間 (PSB)

Table 2. Computation time per query for the PSB.

手法	特徴数 N_f	語彙数 N_v	PSB における検索 1 回の時間 [s]				
			Rend.	SIFT	VQ	Dist.	合計
BF-SSIFT	1,206	1,200	0.08	0.39	0.19	0.004	0.66
VM-1SIFT	42		0.08	3.54		0.547	4.17
BF-DSIFT	12,881	30,053	0.08	1.21	0.02	0.057	1.37
MR-BF-DSIFT	12,881	30,053	0.08	1.21	0.02	4.080	5.39

(Rend.: 多視点レンダリング, SIFT: 局所特徴抽出,


VQ: ベクトル量子化, Dist.: 距離計算)

3.2. 多視点レンダリングの視点数と検索精度


図 7 に、PSB, MSB, ESB における多視点レンダリングの視点数と検索精度の関係を示す。BF-DSIFT の視点当たりの特徴数は $N_p = 300$ 、またコードブックの語彙数は BF-DSIFT

で $N_v = 30,215$ ($S_{min} = 90$), BF-SSIFT で $N_v = 1,200$ とした.


PSB, MSB では, BF-SSIFT, BF-DSIFT, VM-1SIFT のいずれも, 視点数の増加に伴って検索精度が向上した. より多くの方向からモデルを捉えることで多様な特徴が抽出されたと考えられる. BF-DSIFT は, PSB では 80 視点, MSB では 20 視点程度で検索精度が飽和した. VM-1SIFT は PSB, MSB のいずれも 80 視点程度で検索精度が飽和した. 飽和した理由は, 視点が密に配置されるにつれ, 見かけの類似した画像群が生成され, 特徴の多様さが飽和したためであろう. 一方で, BF-SSIFT は, 6 視点では検索精度が低く, 320 視点まで検索精度が向上し続けた. BF-SSIFT は視点当たりの特徴数が少ないため, 多くの深さ画像が生成されることでモデル当たりの特徴数が増加し, 検索精度が向上した. ESB では視点数を増



(a) PSB (剛体モデル)



(b) MSB (姿勢変化モデル)



(c) ESB (CAD モデル)

図 7. 視点数と検索性能.

Fig. 7. Number of views and retrieval performance.

やしても, BF-DSIFT, VM-1SIFT の検索精度がほとんど変化しなかった. 理由としては, ESB の CAD モデルは形が比較的単純であり少ない視点でも特徴の種類が飽和したこと, 反対に, ESB に多い管や貫通穴等の形状特徴は見かけだけではとらえにくく, 視点数を増やしても効果が薄かったこと, 等が理由であろう.

以降の実験では, 検索精度と計算量のバランスを考慮し, 視点数は $N_i = 42$ を用いる.

3.3. モデル当たりの特徴数と検索性能

図 8 に, PSB における BF-SSIFT と BF-DSIFT のモデル当たりの特徴数と検索精度を示す. なお, MSB, ESB でも同様の傾向を示した. BF-SSIFT (N_i) と BF-DSIFT (N_i) は, 視点数を変化させた場合 (BF-DSIFT の視点当たりの特徴数は $N_p = 300$ に固定)の結果である. BF-DSIFT (N_p) は, 視点当たりの特徴数を変化させた場合 (視点数は $N_i = 42$ に固定)の結果である.

PSB では, いずれの場合もモデル当たりの特徴数 N_f が増加するにつれ, 検索精度が向上した. 視点または特徴点を密に配置することで多様な特徴を捉えることができたためである. DSIFT は $N_f = 13,000 \sim 20,000$ 程度で検索精度が飽和した. 飽和後は, 同様の特徴しか抽出されなくなり, 視覚単語の頻度分布に変化がなくなるため, 検索精度が横這いとなった.




図 8. モデル当たりの特徴数と検索性能 (PSB).

Fig. 8. Number of features per model and retrieval performance for the PSB.




図 9. コードブックの語彙数と検索性能 (PSB).

Fig. 9. Vocabulary size and retrieval performance for the PSB.

以上の結果より、視点数 $N_i=42$ の場合、BF-DSIFT の視点当たりの特徴数 N_p は、 $13,000/42 \approx 310$ 個程度が妥当である。

3.4. コードブックの語彙数と検索精度

図 9 に、PSB における BF-SSIFT と BF-DSIFT のコードブックの特徴数と検索精度を示す。なお、MSB、ESB でも同様の傾向を示した。視点数は $N_i=42$ 、BF-DSIFT の視点当たりの特徴数は $N_p=300$ (モデル当たり約 13,000 個) とした。コードブック学習アルゴリズムは、ERC-Tree とした。

BF-SSIFT の検索精度は、語彙数 $N_v=1,000$ 程度でピークを持ち、語彙数を増やすと検索精度が低下した。SSIFT は特徴数が少ないため、モデルの多様な特徴が捉え切れておらず、語彙数を増やしてもかえって性能が低下したと推測する。一方で、BF-DSIFT の検索精度は、BF-SSIFT の性能ピークよりも大きな語彙数 ($N_v=20,000\sim30,000$ 程度) で飽和し、横這いになった。BF-DSIFT でより大きな語彙数が必要になった理由として、密かつランダムな特徴抽出により、局所特徴群が特徴空間において張る部分空間が広がったことが考えられる。また、検索精度が横這いになった理由として、語彙数が数万の BF-DSIFT 特徴は、ビンの値がほとんど 0 の疎なヒストグラムとなるため、語彙数が増加しても、頻度 0 のビンが増えるだけで、距離計算への影響がなかったためと考察する。

3.5. 適応的距離による比較と特徴組み合わせ

表 3 に、BF-SSIFT、BF-DSIFT、VM-1SIFT を組み合わせた際の検索精度を示す。視点数は $N_i=42$ 、BF-DSIFT の視点当たりの特徴数は $N_p=300$ (モデル当たり約 13,000 個) とした。表 3 内の “No” は、KLD で計算した固定距離を線形結合させた結果、“Yes” は、MR で計算した適応的距離を線形結合させた結果を示す。PSB、MSB、ESB のいずれにおいても、適応的距離による比較の方が、固定距離による比較より高い検索精度を示した。例えば、BF-DSIFT では、PSB で約 6 %、MSB で約 15 %、ESB で約 7 % の向上が見られた。特徴空間において特徴同士を固定距離で比較するよりも、特徴分布に適応した距離尺度 (多様体に沿った測地線距離) で比較する方が、適切にモデル比較を行うことができた。

PSB では、BF-DSIFT と VM-1SIFT を組み合わせた場合に、最も検索精度が高くなり、R-Precision = 64.0 % を示した。密な局所特徴のサンプリング (DSIFT) で不足した大域的な特徴を、1SIFT が補うことで検索精度が向上した。MSB では、BF-DSIFT と BF-SSIFT を組み合わせた場合に、最も検索精度が高くなり、R-Precision = 91.9 % を示した。姿勢変化モデル群から成る MSB では、姿勢変化に対して頑強な局所特徴の方が有利に働いた。MSB において大域特徴 VM-1SIFT は、R-Precision = 54.9 % と、BF-SSIFT と BF-DSIFT よりも 30 % 以上低い検索精度を示した。しかしながら注目すべきは、組み合わせに検索精度の低い特徴を用いても、検索精度の低下が僅かであった点である。例えば MSB において、3 特徴全ての

組み合わせでは R-Precision = 90.3 %、BF-DSIFT と VM-1SIFT の組み合わせでは R-Precision = 88.0 % と、実験した中で最も高かった R-Precision = 91.9 % と比較して、検索精度の低下は、数 % 程度に抑えられた。この結果から、提案手法は、含まれる 3 次元モデルのカテゴリが不明であるデータベース (例えば、ウェブクロールによって収集した多様な 3 次元モデル群) に対する検索手法として、一定の検索精度が期待できる。ESB では、BF-DSIFT と BF-SSIFT を組み合わせた場合に、最も検索精度が高くなり、R-Precision = 50.4 % を示した。局所特徴が CAD モデルの詳細な形状特徴を捉えた。

表 3. 特徴の組み合わせと検索性能

Table 3. Feature combination and retrieval performance.

手法	MR ?	R-Precision [%]		
		PSB	MSB	ESB
BF-SSIFT のみ	No	44.8	75.7	42.6
	Yes	50.3	86.8	41.4
BF-DSIFT のみ	No	54.1	75.4	42.5
	Yes	60.4	* 90.7	49.2
VM-1SIFT のみ	No	50.9	48.2	38.3
	Yes	56.5	54.9	40.7
BF-SSIFT + BF-DSIFT	No	53.8	76.1	44.0
	Yes	59.9	* 91.9	* 50.4
BF-SSIFT + VM-1SIFT	No	54.5	69.0	43.8
	Yes	59.3	82.0	43.1
BF-DSIFT + VM-1SIFT	No	57.6	70.8	42.7
	Yes	* 64.0	88.0	48.7
BF-SSIFT + BF-DSIFT + VM-1SIFT	No	57.1	73.8	44.4
	Yes	* 63.6	90.3	* 49.7

3.6. 既存手法との検索精度比較

表 4 に、提案手法と既存手法の検索精度を示す。SPRH⁹⁾、SHD¹⁰⁾、LFD⁶⁾、VM-1SIFT が大域特徴、その他が局所特徴である。表 4 より、MR-BF-DSIFT、または MR-BF-DSIFT と MR-VM-1SIFT の組み合わせが、PSB、MSB、ESB の 3 つ全てで、最も高い検索精度を示した。先行研究 BF-SSIFT と比較すると、提案手法 MR-BF-DSIFT は、PSB で約 16 %、MSB で約 15 %、ESB で約 7 % の検索精度の向上が見られた。また MR-BF-DSIFT と MR-VM-1SIFT の組み合わせは、剛体モデルが多く含まれる PSB で約 19 % の向上を示した。

既存手法の中には、1 つのベンチマークの検索精度が高い一方で他のベンチマークで検索精度が低下するものがあった。例えば、LFD は、多様な剛体モデルから成る PSB で R-Precision = 44.7 % と、既存手法群の中では高い検索精度を示した。しかし、姿勢変化モデルから成る MSB や CAD モデルから成る ESB では検索精度が低下し、SPRH や SHD¹⁰⁾ の大域特徴と同程度だった。また、局所特徴 FoG⁵⁾ は、MSB で R-Precision =

80.9%と高い検索精度を示したが、PSB と ESB では他の大域特徴と同程度だった。一方で提案手法は、PSB, MSB, ESB のいずれにおいても、既存手法より高い検索精度を示した。この結果から、提案手法は、Trimble 3D Warehouse のような、幅広いカテゴリから成るデータベースの検索でも、他手法と比べて優位な検索精度を示すと期待できる。

我々は、国際的な 3 次元形状類似検索コンテスト SHREC に参加した。表 5 に結果を示す。表 5 の NN (Nearest Neighbor) は検索結果 1 件目の正解率、R-Pre. は R-Precision を示す。SHREC 2010 姿勢変化モデル部門⁴⁾では、我々の MR-BF-DSIFT は、Smeets らの DMEVD と同着 1 位を獲得した。NN で比べると Smeets らの手法が約 2% 高く、R-Precision では、我々の手法が約 5% 高かった。ただし、DMEVD は多様体メッシュを前提としており、広く用いられる形状表現であるポリゴンスーブには適用できない。一方で、MR-BF-DSIFT は形状表現に不変である点で優れている。また、SHREC 2012 多様体モデル部門²³⁾では、我々は 1 位を獲得した。MR-BF-DSIFT は、Tatsuma らの DVD+DB+GMR と比較して、NN で約 4%, R-Precision で約 5% 高い検索精度を示した。さらに MR-BF-DSIFT, MR-VM-1SIFT, MR-BF-GSIFT (密な格子点サンプリング) の 3 特徴を組み合わせた手法では、さらに他の手法を引き離れた。以上の結果からも、提案手法は、幅広い種類の形のモデル群の検索に有効であることが窺える。

表 4. 既存手法との検索性能比較。

Table 4. Comparison of retrieval performance with the existing methods.

手法	R-Precision [%]		
	PSB	MSB	ESB
SPRH ⁹⁾	36.3	53.0	34.7
SHD ¹⁰⁾	39.6	55.6	34.6
LFD ⁶⁾	44.7	55.5	34.7
FoG ⁵⁾	40.2	80.9	34.5
BF-SSIFT ¹¹⁾	44.8	75.7	42.6
BF-DSIFT	54.1	75.4	42.5
VM-1SIFT	50.9	48.2	38.3
MR-BF-DSIFT	* 60.4	* 90.7	* 49.2
MR-VM-1SIFT	56.5	54.9	40.7
MR-BF-DSIFT + MR-VM-1SIFT	* 64.0	* 88.0	* 48.7

4. まとめと今後の課題

本研究では、姿勢変化モデルなどの幅広い種類の形状モデルや、多様な形状表現から成る 3 次元モデルデータベースに対する検索精度の向上を狙い、先行研究 BF-SSIFT の特徴抽出と距離比較の方法に改良を施した手法を提案し評価した。提案手法の中核をなす局所特徴 BF-DSIFT は、密かつランダムに局所特徴を抽出することで、BF-SSIFT では捉えきれなかった多様な形状特徴を捉えた。さらに、大域特徴 VM-1SIFT

表 5. SHREC 2010, SHREC 2012 の結果

Table 5. Results for the SHREC 2010 and the SHREC 2012.

手法	SHREC 2010 姿勢変化モデル ⁴⁾		SHREC 2012 多様体モデル ²³⁾	
	NN [%]	R-Pre. [%]	NN [%]	R-Pre. [%]
CF	92.0	63.5		
DMEVD	* 100.0	86.1		
LSD			51.7	23.2
ZFDR			81.8	49.1
3DSP			70.8	36.1
DVD+DB+GMR			82.8	61.3
BF-DSIFT	98.0	76.6		
MR-BF-DSIFT	98.5	* 90.9	86.3	63.9
MR-BF-DSIFT + MR-BF-GSIFT + MR-VM-1SIFT			* 87.9	* 66.1

を BF-DSIFT と組み合わせて用いることで、BF-DSIFT 単体では不足していた大域形状への弁別性を高めた。加えて、特徴空間上の多様体に沿った距離の尺度を Manifold Ranking (MR)法で学習し、特徴分布に適応した距離で比較を行った。

評価実験の結果、我々の提案手法は、BF-SSIFT が元々得意としていた姿勢変化モデルに加え、多様な剛体モデルと CAD モデルの検索ベンチマークにおいても、従来法より有意に高い検索精度を達成した。また我々は、3 次元形状類似検索の国際コンテストに参加し、姿勢変化モデル群と多様な剛体モデル群の検索部門で、1 位を獲得した。

今後の課題は、検索の高速化、省メモリ化である。BF-DSIFT 抽出は、GPU や木構造コードブックの利用により高速化された。しかし、BF-DSIFT は約 3 万次元の高次元特徴であるため、記憶領域を大量に消費する。次元削減やハッシング等で特徴空間の圧縮を行い、距離計算の高速化と省メモリ化を図る。また MR 法は、特徴数の 3 乗オーダーの計算時間を要するため大規模データベースにそのまま適用できない。行列の低ランク近似等による MR のスケーラブル化を検討する。

参考文献

- 1) V. Jain, H. Zhang, A spectral approach to shape-based retrieval of articulated 3D models, *Computer Aided Design*, **39**, pp.298-407, (2007).
- 2) T. Tung, F. Schmitt, Augmented Reeb Graphs for Content-based Retrieval of 3D Mesh Models, *Proc. IEEE International Conference on Shape Modeling and Applications 2004 (SMI'04)*, pp.157- 166, (2004).
- 3) R. Gal, A. Shamir, D. Cohen-Or, Pose-Oblivious Shape Signature, *IEEE Trans. Visualization and Computer Graphics*, **13**(2), pp. 261-271, (2007).
- 4) Z. Lian, A. Godil, T. Fabry, T. Furuya, J. Hermans, R. Ohbuchi, C. Shu, D. Smeets, P. Suetens, D. Vandermeulen, S. Wuhler, SHREC'10 Track: Non-rigid 3D Shape Retrieval. In *Proc. Eurographics Workshop on 3D Object Retrieval (3DOR) 2010*, pp. 101-108, (2010).
- 5) S. Kawamura, K. Usui, T. Furuya, R. Ohbuchi, Local Geometrical Feature with Positional Context for Shape-based 3D Model Retrieval, poster paper, *Proc. Eurographics 2012 Workshop on 3D Object*

- Retrieval, pp.55-58, (2012).
- 6) D.-Y. Chen, X.-P. Tian, Y.-T. Shen, M. Ouhyoung, On Visual Similarity Based 3D Model Retrieval, *Computer Graphics Forum*, **22**(3), pp. 223-232, (2003).
 - 7) P. Daras, A. Axenopoulos, A Compact Multi-view Descriptor for 3D Object Retrieval, *Proc. Seventh International Workshop on Content Based Multimedia Indexing*, pp. 115-119, (2009).
 - 8) Napoleon, T., Adamek, T., Shmitt, F., O'Connor, N. E. (2008). SHREC'08 entry: Multi-view 3D retrieval using multi-scale contour representation. In *Proc. IEEE International Conference on Shape Modeling and Applications 2008 (SMI'08)*, pp. 227-228 (2008).
 - 9) E. Wahl, U. Hillenbrand, G. Hirzinger, Surflet-Pair-Relation Histograms: A Statistical 3D-Shape Representation for Rapid Classification, *Proc. 3-D Digital Imaging and Modeling 2003*, pp. 474-481, (2003).
 - 10) M. Kazhdan, T. Funkhouser, S. Rusinkiewicz, Rotation Invariant Spherical Harmonics Representation of 3D Shape Descriptors, *Proc. Symposium of Geometry Processing 2003*, pp. 167-175 (2003).
 - 11) Ryutarou Ohbuchi, Kunio Osada, Takahiko Furuya, Tomohisa Banno, Salient local visual features for shape-based 3D model retrieval, *Proceedings of the IEEE International Conference on Shape Modeling and Applications 2008 (SMI'08)*, pp.93-102, (2008).
 - 12) D. G. Lowe, Distinctive Image Features from Scale-Invariant Keypoints, *Int'l Journal of Computer Vision*, **60**(2), pp. 91-110, (2004).
 - 13) G. Csurka, C.R. Dance, L. Fan, J. Willamowski, C. Bray, Visual Categorization with Bags of Keypoints, *Proc. European Conference on Computer Vision '04 workshop on Statistical Learning in Computer Vision*, pp. 59-74, (2004).
 - 14) McGill 3D Shape Benchmark, <http://www.cim.mcgill.ca/~shape/benchMark/>
 - 15) P. Shilane, P. Min, M. Kazhdan, T. Funkhouser, The Princeton Shape Benchmark, *Proc. IEEE International Conference on Shape Modeling and Applications (SMI) 2004*, pp. 167-178, (2004), <http://shape.cs.princeton.edu/benchmark/>
 - 16) Engineering Shape Benchmark, <http://shapelab.ecn.purdue.edu/>
 - 17) R. Ohbuchi, J. Kobayashi, Unsupervised Learning from a Corpus for Shape-Based 3D Model Retrieval, *proceedings of the ACM International Multimedia Conference, Proceedings of the international workshop on Multimedia Information Retrieval (MIR) 2006*, pp. 163-172, (2006).
 - 18) A. Tatsuma, M. Aono, Multi-Fourier spectra descriptor and augmentation with spectral clustering for 3D shape retrieval, *Visual Computer*, **25**(8), pp.785-804, 2009.
 - 19) R. Ohbuchi, T. Shimizu, Ranking on Semantic Manifold for Semantic 3D Model Retrieval, *Proceedings of the 1st ACM International Conference on Multimedia Information Retrieval (MIR) 2008*, pp.411-418, (2008).
 - 20) D. Zhou, J. Weston, A. Gretton, O. Busquet and B. Scholkopf, Ranking on Data Manifolds, *Proc. Advances in Neural Information Processing Systems (NIPS) 2003*, (2003).
 - 21) C. Wu, SiftGPU: A GPU Implementation of David Lowe's Scale Invariant Feature Transform (SIFT), <http://cs.unc.edu/~ccwu/siftgpu/>
 - 22) P. Guerts, D. Ernst, L. Wehenkel, Extremely randomized trees, *Machine Learning*, 2006, **36**(1), pp.3-42, (2006).
 - 23) B. Li, A. Godil, M. Aono, X. Bai, T. Furuya, L. Li, R. Lopez-Sastre, H. Johan, R. Ohbuchi, C. Redondo-Cabrera, A. Tatsuma, T. Yanagimachi, S. Zhang, In: M. Spagnuolo, M. Bronstein, A. Bronstein, and A. Ferreira (eds.): SHREC'12 Track: Generic 3D Shape Retrieval, *Eurographics Workshop on 3D Object Retrieval (3DOR) 2012*, pp.119-126, (2012).
 - 24) Trimble 3D warehouse, <http://sketchup.google.com/3dwarehouse/>.
 - 25) T. Furuya, R. Ohbuchi, Dense sampling and fast encoding for 3D model retrieval using bag-of-visual features, *Proc. ACM International Conference on Image and Video Retrieval (CIVR) 2009*, Article No. 26, (2009).
 - 26) R. Ohbuchi, T. Furuya, Distance metric learning and feature combination for shape-based 3D model retrieval. *Proc. ACM workshop on 3D object retrieval (3DOR) 2010*, pp. 63–68, (2010).

(2013 年 06 月 05 日 受付)



古屋 貴彦

2008 年, 山梨大学工学部コンピュータ・メディア工学科卒業。2010 年, 山梨大学大学院医学工学総合教育部修士課程コンピュータ・メディア工学専攻修了。同年ニスカ株式会社入社。2013 年, 山梨大学大学院医学工学総合教育部博士課程情報機能システム工学専攻入学。



大淵 竜太郎

(正会員)

1981 年, 上智大学理工学部電気電子工学科卒業。1983 年, 電気通信大学大学院計算機科学科修士課程修了。同年日本アイ・ビー・エム (株) 入社。1994 年, University of North Carolina at Chapel Hill より Ph. D. 取得。同年より IBM 東京基礎研究所勤務。1999 年, 山梨大学工学部コンピュータ・メディア工学科助教授。2007 年より同教授。興味は 3 次元モデルの検索や電子透かし。ACM, IEEE Computer Society, 情報処理学会, 各会員。