

多視点画像特徴の多様体を用いたスケッチによる 3D モデルの検索

松田隆広¹⁾, 古屋貴彦²⁾, 栗田侑希紀³⁾, 大淵竜太郎⁴⁾

1, 2, 3, 4) 山梨大学

Manifold of Multi-view Image Features for Sketch-based 3D Model Retrieval

Takahiro Matsuda¹⁾, Takahiko Furuya²⁾, Yukinori Kurita³⁾, Ryutarou Ohbuchi⁴⁾

1,2,3,4) University of Yamanashi

{ t10kf027, g13dm003, g11mk014, ohbuchi } @ yamanashi.ac.jp

アブストラクト

人の描く線画スケッチによる 3D モデル検索の先行研究では、線画スケッチから抽出した特徴と、3D モデルを多視点レンダリングして得た特徴線画像等の線画から抽出した特徴とを比較する。しかし、線画スケッチの抽象化や描画スタイルの多様性などにより、線画スケッチと 3D モデル特徴線画像が大きく異なる場合も多い。これが、先行研究手法における検索精度が低い原因の一つとなっていた。検索精度向上のアプローチの一つに、固定された距離尺度（例えば、L1, L2, Cosine）ではなく、特徴の分布に適応した距離尺度の利用がある。本論文では、クエリであるスケッチ画の特徴と、全 3D モデルを多視点からレンダリングした特徴線画像の特徴群との比較に適応的距離尺度を用いることで検索精度の向上を狙う。具体的には、まず、線画スケッチ画像の特徴および、全 3D モデルを多視点からレンダリングした画像群の特徴からなる特徴の多様体グラフを作成する。次いで、検索要求である線画スケッチから 3D モデルへの距離を多様体グラフ上での拡散距離として計算する。実験的評価の結果、提案手法による適応的な距離の方が、L1 等の固定距離よりも高い検索精度を示すことが分かった。

1. はじめに

近年、ゲーム、映画、医療、建築等の幅広い分野で 3 次元形状モデル (3D モデル) が利用されている。Microsoft Kinect に代表される安価な 3D スキャナや、3D プリンタの普及により、3D モデルの数が大幅に増加している。これら多数の 3D モデルを効率的に管理、利用するため、3D モデルをその形状の類似性に基づいて検索し整理する技術への要求が高まっている。

ユーザにとってより手軽な検索を実現するため、これまでの 3D モデルそのものを検索要求とした問い合わせに替え、線画スケッチやキーワードによる問い合わせに注目が集まっている [5][8][9]。中でも手書きの線画スケッチは、ユーザが使う言語の制約を受けず、手軽かつ直感的に形を指定して検索を行える利点がある。線画スケッチによる 3D モデル検索の応用例として、Shin らは、3D シーンに配置する 3D モデルを線画スケッチで検索することで、ユーザにとって直感的なシーン生成を可能とした [15]。

スケッチによる 3D モデル検索では、異種のデータである 2D 線画スケッチと 3D 形状モデルとを、効果的かつ効率的に類似比較する手法が課題となる。

スケッチによる 3D モデル検索の先行研究の殆どは、3D モデルを多視点から線画に類似する 2 次元画像 (例えば特徴線画像 [1]) にレンダリングし、これを線画スケッチと比較する [2][7][8][9][10][11][13][14][17]。Shao らの手法 [14]、Li らの手法 [10][11] では、スケッチ線と特徴線の上にそれぞれサンプル点を配置し、サンプル点集合間の距離の総和が最小となるような点の

対応付けを探索することで、スケッチと 3D モデルを比較する。Yoon らの手法 [17] は、局所領域におけるスケッチ線の向きを特徴ベクトル化し Cosine 類似度で比較する。Saavedra らの手法 [13] では、スケッチと特徴線画像の画面上に線分を当てはめ、線分同士的位置関係の特徴ベクトル化して χ^2 距離で比較する。Eitz らの BF-GALIF 法 [2] は、線の向きを記述した局所特徴を画像から多数抽出し、これらを Bag-of-Features (BF) 法で画像あたり 1 個の特徴ベクトルに統合し、Cosine 類似度で比較する。

これらの既存手法で良い検索精度が得られるのは、スケッチと特徴線が類似する場合に限られる。人が描くスケッチには形状の抽象化、省略、変形が含まれる。図 1 に示す 4 つの意味カテゴリ (自転車、椅子、車輪、馬) の画像例では、スケッチと特徴線はある程度類似しているものの、スケッチの線に揺らぎや歪み、線の交差等が見られる。このため、スケッチと 3D モデルの特徴線画像からの特徴抽出と、これら特徴の比較が困難となる。特に、特徴比較において、スケッチと特徴線画像から抽出された特徴を単純な L1 や Cosine 等の固定距離で比較するとうまくいかない可能性がある。

特徴間の距離比較を改善するため、特徴群の分布に適応した距離尺度で特徴比較を行う方法がある。He ら [6]、立間ら [16] は、それぞれ 2D 画像同士、3D モデル同士の特徴比較において、非線形な特徴の分布 (多様体) 上で拡散距離を計算し、検索の順位付けを行うことで、検索精度が改善することを示した。

本論文では、教師なしの距離尺度学習アルゴリズムの 1 つである Manifold Ranking (MR) [18] をスケッチによる 3D モデル検索に




図 1. 線画スケッチと特徴線画の例.

適用し、検索精度の改善を狙う。線画スケッチ画像の特徴群と、3Dモデルの多視点レンダリング画像から得た画像特徴群の双方を学習サンプルとし、特徴分布に適応した距離尺度を学習する。これにより、スケッチ線の揺らぎや種々のノイズに対して頑強な距離比較が期待できる。提案手法ではまず、 N_s 個の線画スケッチの各々から 1 つの特徴を、 N_m 個の 3D モデルの各々を N_v 個の視点でレンダリングして得た N_v 個の特徴を、それぞれ抽出する。次いで、これら $N_s + (N_m \times N_v)$ 個の特徴を特徴空間における距離の近傍で接続して多様体グラフを生成する。次いで MR 法を用い、多様体グラフ上の検索要求スケッチの特徴から、3D モデルの多視点画像特徴へ類似度を拡散させる。検索要求スケッチの特徴と、各多視点画像特徴との間の拡散距離に基づき、検索結果を順位付ける。

上述の通り、提案手法では、多様体グラフ生成時に、 $(N_m \times N_v)$ 個の 3D モデルの多視点画像に加え、 N_s 個のスケッチ画像を学習サンプル (コーパス) として利用する。これは現実的な仮定であり、例えば、実際の検索システムでは、データベースに蓄積された過去の検索要求スケッチ群を、コーパスとして利用可能である。本研究では、ベンチマークに含まれるスケッチ画像群をコーパスとして用い、多様体グラフに埋め込んで MR 法を適用する。

検索精度の評価実験では、2 つのベンチマーク SHREC 2012 Sketch-based 3D Shape Retrieval (SH12) [8] と SHREC 2013 Large-Scale Sketch-Based 3D Shape Retrieval (SH13) [9] を用いる。スケッチ画像と多視点レンダリング画像から抽出する特徴には、Eitz らの [2] に基づく BF-fGALIF と、我々の手法 BF-fDSIFT [8] を用いる。BF-fGALIF と BF-fDSIFT の各特徴に MR を適用した場合と、拡散距離の線形結合により 2 つの特徴を組み合わせた場合の検索精度を互いに比較する。さらに、スケッチコーパスの有無による検索精度への影響を評価する。

実験の結果、両ベンチマークとも、MR で得た適応的な距離の方が、固定距離よりも、有意に高い検索精度を示した。検索精度指標として Mean Average Precision (MAP) を用いると、例えば、SH12 の Hand-drawn クエリセットでは、BF-fGALIF 特徴を固定距離で比較すると 39.8 [%]、MR で比較すると 48.5 [%]、となり、精度が約 9 [%] 向上した。SH13 では、BF-fGALIF 特徴を固定距離で比較すると 10.3 [%] だが、MR で比較すると 12.0 [%] に改善した。さらに BF-fGALIF と BF-fDSIFT の 2 特徴の適応的な距離を線形結合すると 13.6 [%] となった。これは、比較した手法中、最も高い検索精度である。また、スケッチコーパスの利用により、ベンチマークとクエリセットの組み合わせによって検索精度が改善することが分かった。

本研究の貢献は、以下の通りである。

1. スケッチによる 3D モデル検索の特徴比較に、スケッチ画像の特徴と 3D モデルのレンダリング画像の特徴をまとめて多様体を生成し、これら間で適応的な距離を求めて順位付けする手法を初めて導入した。
2. 距離尺度の学習に際し、多数のスケッチ画像からなるスケッ

チ画のコーパスを上記の学習に利用することで、スケッチ線画の揺らぎやノイズ、変形に対する頑強性を得た

3. 提案手法により得られた特徴分布に適応した距離尺度による特徴比較が、L1, L2 等の固定距離よりも高い検索精度を与えることを実験的に示した。

2. 提案手法

本研究では、手書きの線画スケッチの揺らぎや種々のノイズに対して頑強な 3D モデル検索を狙い、距離尺度の学習を導入する。提案手法では、教師なし距離尺度学習アルゴリズムの 1 つである Zhou らの Manifold Ranking (MR) [18] を、2 つの特徴抽出手法 BF-fGALIF と BF-fDSIFT のいずれかを用いて生成した特徴の多様体グラフに適用する。検索要求スケッチの特徴から 3D モデルの視点画像の特徴への多様体グラフ上の拡散距離に基づいて、検索結果を順位付ける (図 2)。

さらに、特徴比較の頑強性をより高めるため、複数の特徴を組み合わせる。提案手法では、MR で求めた BF-fGALIF の拡散距離と BF-fDSIFT の拡散距離を、線形結合により組み合わせる。

2.1 節で MR による距離尺度の学習と距離の組み合わせ手法を、2.2 節でスケッチ画と 3D モデルからの特徴抽出手法を述べる。

2.1 Manifold Ranking による距離尺度の学習

提案手法では、まずスケッチ画の特徴群と、3D モデルの視点特徴群のそれぞれを頂点とした多様体グラフを生成する。多様体グラフは、サイズ $(N_s + N_m \cdot N_v) \times (N_s + N_m \cdot N_v)$ の疎行列 $\mathbf{W}$ として表現される。ここで、 N_s と N_m はそれぞれデータベースのスケッチと 3D モデルの数、 N_v はレンダリングの視点数を示す。 $\mathbf{W}$ の要素を式 (1) で求める。式 (1) の $d(\mathbf{x}_i, \mathbf{x}_j)$ は 2 つの頂点 (特徴ベクトル) $\mathbf{x}_i$ と $\mathbf{x}_j$ の距離、 $k\text{NN}(\mathbf{x}_i)$ は、頂点 $\mathbf{x}_i$ の k 近傍である頂点の集合を示す。 σ は、多様体における頂点間の類似度重みを制御するパラメータである。特徴ベクトル $\mathbf{x}$ 、及び、距離 d の計算については、2.2 節で述べる。

$$W_{ij} = \begin{cases} \exp(-d(\mathbf{x}_i, \mathbf{x}_j)^2 / \sigma) & \text{if } \mathbf{x}_j \in k\text{NN}(\mathbf{x}_i) \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

式 (2) により $\mathbf{W}$ を正規化する。 $\mathbf{D}$ は $\mathbf{W}$ と同サイズの対角行列であり、 $\mathbf{D}_{ii}$ は $\mathbf{W}$ の i 行目の和である。

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

次いで、式 (3) に示す漸化式を用い、ランキングスコア行列 $\mathbf{F}$ を得る。反復計算は収束するまで行う。 $\mathbf{Y}$ は $\mathbf{W}$ と同サイズの対角行列で、その対角成分は類似度の拡散源を定義する。頂点 $\mathbf{x}_i$ が拡散源であれば $\mathbf{Y}_{ii}$ を 1、そうでなければ 0 とする。本手法では、検索要求であるスケッチ特徴の頂点を、類似度の拡散源とした。 $\alpha = [0, 1]$ は、類似度の拡散時の正則化を制御するパラメータである。 $\mathbf{F}_i$ がスケッチ $\mathbf{x}_i$ から 3D モデルの視点特徴 $\mathbf{x}_j$ へ拡散した類似度を示す。ランキングスコアの符号を反転した $-\mathbf{F}_j$ を拡散距離とし、検索結果の順序付けに用いる。

$$\mathbf{F}_{t+1} = \alpha \mathbf{S} \mathbf{F}_t + (1 - \alpha) \mathbf{Y} \quad (3)$$

検索要求のスケッチ特徴と、3D モデルの各視点特徴との拡散距離 (N_v 個) の内、最小値をスケッチと 3D モデル間の距離とする。距離が小さな 3D モデルほど検索結果の上位に順位付けされる。

多様体グラフ $\mathbf{W}$ 生成の時間計算量は $O((N_s + N_m \cdot N_v)^2)$ 、式 (3) の反復計算 1 回あたりの時間計算量は $O((N_s + N_m \cdot N_v)^3)$ である。疎行列を利用するため、式 (3) の計算量はある程度緩和される。しかし、行列 $\mathbf{W}$ のサイズが $(N_s + N_m \cdot N_v) \times (N_s + N_m \cdot N_v)$ と大規模であるため、提案手法は時間計算量、空間計算量ともに大きい。

より検索精度を向上させるため、複数特徴の組み合わせを行う。

本研究では、BF-fGALIFとBF-fDSIFTの各々で多様体グラフを生成し、MRにより拡散距離を求める。次いで各特徴で求めたスケッチと3Dモデル間の距離を足し合わせ、これに基づいて検索結果の順位付けを行う。

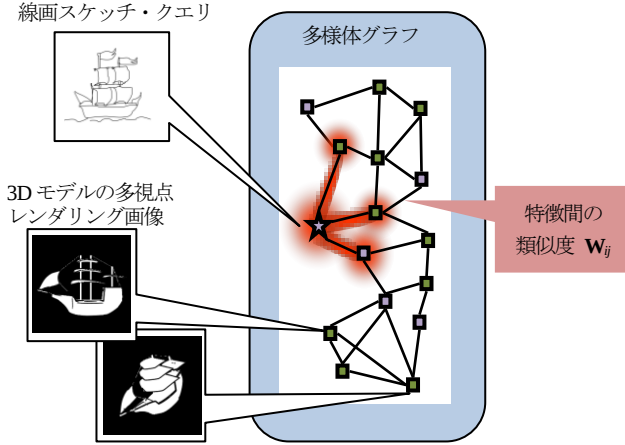


図2. Manifold Rankingによる距離比較. クエリの特徴を拡散源とし、多様体グラフの辺を介して類似度を拡散させる。拡散の収束後、クエリと各レンダリング画像間の拡散距離に基づいて、3Dモデルを順位付ける。

2.2 特徴抽出

本手法では、スケッチと3Dモデルからの特徴抽出手法として、EitzらのBF-GALIF [2]を元に改良を加えたBF-fGALIFと、我々のBF-fDSIFT [8]を用いる。図3に、BF-fGALIFとBF-fDSIFTの特徴比較の流れを示す。ここでの注意点として、距離尺度の学習を行う場合は、サイズ $(N_s+N_m:N_v) \times (N_s+N_m:N_v)$ の行列 $\mathbf{W}$ の生成のため、 $(N_s+N_m:N_v)$ 個の画像特徴の全対距離を計算する。つまり、スケッチ同士、視点画像同士、スケッチと視点画像間の全ての組み合わせで、距離計算を行う必要がある。一方で、固定距離で検索する場合は、スケッチ特徴と視点画像特徴を比較するため、スケッチ同士、視点画像同士の距離計算は必要ない。

2.2.1 BF-fGALIF

BF-GALIF [2]は、スケッチ線や特徴稜線の向きを特徴化し、比較する。我々はEitzらのBF-GALIFに対し、(1)輪郭線を抽出するためのレンダリング背景色の変更、(2)画像の回転不変性の付与、の改良を施す。本研究では改良を施したBF-GALIFをBF-fGALIFと呼ぶ。

まず、3Dモデルを N_v 視点(実験では42視点)から特徴稜線レンダリング [1]する。我々の予備実験では、レンダリング背景とモデルの面を白、特徴稜線を黒として3Dモデルをレンダリングすると、モデルの輪郭線が欠落する場合があった。SHREC2013 [9]の3Dモデルは、その多くがポリゴンスープ表現である。特徴稜線レンダリング [1]の入力は、多様体メッシュ表現を想定するため、モデルによっては輪郭の生成に失敗し、輪郭線が欠落する。そこで我々は、モデルの面を白、背景と特徴稜線を黒でレンダリングすることで、3Dモデルの輪郭を残したまま特徴稜線画像を生成する。レンダリングの解像度は 256×256 [pix]とした。

画像の回転に不変な特徴比較を行うため、画像を回転正規化する。画像に対して複数方向のGaborフィルタを適用し、複数の反応画像を生成する。反応画像の各画素で、反応ベクトル(向きはGaborフィルタの向き、長さは反応値の絶対値)を計算する。各反応ベクトルを18方向($0^\circ \sim 180^\circ$ を 10° ずつ分割)のビンに投票する。投票の結果、最大頻度となったビンの方向へ画像を回転させる。

次いで、回転正規化後の画像から、GALIF特徴 [2]を密に多数抽出する。格子点上に密に配置された特徴点から、画像あたり1,024個のGALIF特徴が抽出される。GALIFは、画像上の特徴点付近の局所領域における線や濃度勾配の向きを特徴化する。用いたGaborフィルタは4方向の線を検出するように設計しており、局所領域内の各向きのGaborフィルタの反応の強さをヒストグラム化する。バンド幅その他のGaborフィルタの各パラメータは、予備実験にて最も高い検索精度を示す値の組み合わせを用いた。

検索要求として与えられたスケッチ画についても、 256×256 [pix]にリサイズ後、特徴稜線画像と同様に1,024個のGALIF特徴を密に抽出する。

画像あたり1,024個のGALIF特徴群は、画像間比較の手間を減らすため、Bag-of-Features (BF) 法により画像あたり1個の特徴ベクトルに統合され、BF-fGALIF特徴となる。BF-fGALIF特徴は、多数のGALIF特徴のそれぞれを視覚単語にベクトル量子化し、視覚単語の頻度をヒストグラム化して得る。本論文の実験では、 k -meansクラスタリングを用いて2,500個の語彙を学習した。またベクトル量子化時の近傍探索は kd -treeを用いて高速化した。

画像ごとに抽出したBF-fGALIF特徴の距離 $d(\mathbf{x}, \mathbf{y})$ を、式(4)に示す対称化したKullback-Leibler Divergence (KLD)で求める。式(4)において n は特徴ベクトルの次元数(即ち語彙数)を示す。KLDは2つの確率分布間の距離尺度として用いられる。我々の予備実験では、L2, L1, CosineよりもKLDの検索精度が高くなった。

$$d(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^n (y_i - x_i) \ln \frac{y_i}{x_i} \quad (4)$$

固定距離で3Dモデルの順位付けを行う場合は、1個のスケッチのBF-fGALIF特徴と、 N_v 個の3DモデルのBF-fGALIF特徴を距離比較し、 N_v 個の距離の中での最小値を、スケッチと3Dモデル間の距離とする。

2.2.2 BF-fDSIFT

BF-DSIFT [3]は本来、3Dモデル同士の比較手法であるが、本論文では、BF-DSIFTをスケッチによる3Dモデル検索に応用する。以降は、スケッチ検索に応用したBF-DSIFTをBF-fDSIFTと呼ぶ。

BF-fDSIFT [8]は、スケッチと3Dモデルの見かけ形状(シルエット)を特徴比較する。まず、スケッチ画をシルエット化する。スケッチに対してclosing処理を行い、線の隙間を閉じる。次いで、スケッチ線の内部を塗りつぶすことで、シルエット画像を生成する。ただし、closing処理時に線の隙間が閉じず、シルエット画像の生成に失敗するスケッチも存在する。

3Dモデルについては、 N_v 視点(実験では42視点)からの2値レンダリングによりシルエット画像群を生成する。レンダリングの解像度は 256×256 [pix]とした。

シルエット画像からSIFT特徴 [12]を密に多数抽出する。シルエットの上部または周囲にランダムに配置された特徴点群から、画像あたり約1,200個のSIFT特徴が抽出される。SIFTはマルチスケール特徴であるため、形状の大域的特徴と局所的特徴の双方を捉える利点がある。またSIFTは画像の回転に対して不変である。よってBF-fDSIFTでは、画像の回転正規化を行わない。

画像あたり1,200個のSIFT特徴群は、BF-fGALIF同様、BF法により画像あたり1個の特徴ベクトルに統合され、BF-fDSIFT特徴となる。本論文の実験では、ERC-Tree [4]を用いて、約10,000個の語彙の学習と、ベクトル量子化時の近傍探索を高速化した。

BF-fGALIFと同様に、BF-fDSIFT特徴間の距離 $d(\mathbf{x}, \mathbf{y})$ を、式(4)に示す対称化KLDを用いて求める。固定距離で3Dモデルの順位付けを行う場合は、1個のスケッチのBF-fDSIFT特徴と、 N_v 個の3DモデルのBF-fDSIFT特徴を距離比較し、 N_v 個の距離の中での最小値を、スケッチと3Dモデル間の距離とする。




図 3. 特徴比較の流れ.

3. 実験と結果

3.1 実験条件

実験では、評価用ベンチマークとして SHREC 2012 Sketch-based 3D Shape Retrieval (SH12) [8]と、SHREC 2013 Large Scale Sketch-based 3D Shape Retrieval (SH13) [9]を用いる。図 4 に、SH12 と SH13 の検索要求スケッチと検索対象モデルの例を示す。

SH12 の検索要求は、Hand-drawn と Standard line の 2 つのクエリセットから成る。Hand-drawn クエリセットは、素人が描いた線画スケッチ群 (250 個) から成る。Standard line クエリセットは、“プロが描いたような”線画スケッチ群 (12 個) から成る。検索対象は、飛行機、メガネ、蟻など 13 個の意味カテゴリに分類された 3D モデル群 (260 個) から成る。SH12 のスケッチ画像は、画像サイズと、画像中のスケッチの位置、大きさが不揃いであるため、これらに対し予め正規化を施しておく。

SH13 のスケッチは、人間が描いたスケッチ群 (7,200 個) から成る。これらのスケッチ群は、検索要求用の Testing スケッチ群 (2,700 個) と、学習用の Training スケッチ群 (4,500 個) に分けられる。検索対象は、ヒトや机やワイングラスなど 90 個の意味カテゴリに分類された 3D モデル群 (1,258 個) から成る。

検索精度の評価実験では、(1) 固定距離 (KLD) による特徴比較 (BF-fGALIF, BF-fDSIFT), (2) 適応的距離による特徴比較 (MR-BF-fGALIF, MR-BF-fDSIFT), (3) 固定距離の組み合わせ (BF-fGALIF + BF-fDSIFT), (4) 適応的距離の組み合わせ (MR-BF-fGALIF + MR-BF-fDSIFT), を互いに比較する。

スケッチのコーパスの有無による検索精度を比較するため、(2) 適応的距離による特徴比較では、検索要求を含む全てのデータ

ベースのスケッチ群を多様体グラフに埋め込む場合 (スケッチコーパス有り) と、検索要求スケッチのみを多様体グラフに埋め込む場合 (スケッチコーパス無し) に分けて評価する。

MR のパラメータ (k, σ, α) は、予備実験により、最も検索精度が高くなる値の組み合わせを用いた。表 1 に、実験に用いた MR のパラメータを示す。

検索精度の評価指標には、First Tier (FT), Second Tier (ST), Mean Average Precision (MAP) を用いる。いずれも値が大きいほど検索精度が高いことを示す。FT [%] は検索要求スケッチの正解カテゴリに属する 3D モデル数を n とした時、検索結果上位 n 件における再現率、ST [%] は検索結果上位 $2n$ 件における再現率である。MAP [%] は、検索結果を上位から走査し、正解モデルが検索された時点における適合率の平均である。




図 4. 検索要求スケッチと検索対象モデルの例.

表 1. MR のパラメータ.

ベンチマーク	手法	スケッチコーパス	k	σ	α
SH12	MR-BF-fGALIF	有	30	0.0001	0.9
		無	140	0.0050	0.9
	MR-BF-fDSIFT	有	160	0.0010	0.9
		無	160	0.5000	0.9
SH13	MR-BF-fGALIF	有	100	0.0025	0.9
		無	160	0.0050	0.9
	MR-BF-fDSIFT	有	140	0.0010	0.9
		無	160	0.0050	0.9

3.2 実験結果

3.2.1 Manifold Ranking の効果

図 5, 図 6 にそれぞれ、SH12 と SH13 における BF-fGALIF と BF-fDSIFT に Manifold Ranking を適用した際の検索精度を示す。

図 5, 図 6 より、SH12 と SH13 の双方において、距離尺度の学習によって BF-fGALIF と BF-fDSIFT の検索精度が向上した。例えば SH12 の Hand-drawn クエリセットでは、スケッチコーパス有りの MR-BF-fGALIF は MAP = 48.5 [%], MR-BF-fDSIFT は MAP = 35.3 [%] と、元の BF-fGALIF と BF-fDSIFT に比べて、それぞれ約 9 [%], 約 3 [%] の検索精度向上を示した。

SH13 においては、スケッチコーパス有りの MR-BF-fGALIF は MAP = 12.0 [%], MR-BF-fDSIFT は MAP = 12.1 [%] と、元の BF-fGALIF と BF-fDSIFT と比べて、どちらも約 2 [%] の検索精度向上を示した。

以上の実験結果より、固定距離による特徴比較よりも、適応的距離による特徴比較の方が、高い検索精度を示すことが分かった。

スケッチコーパスの有無を比較すると、SH13 ではスケッチコーパスの利用により検索精度がやや向上した。SH12 においては、スケッチコーパスの利用により MR-BF-fGALIF の検索精度がやや向

上したが、MR-BF-fDSIFT ではやや低下した。スケッチコーパスの有無により、生成される多様体グラフの構造が異なる。検索精度が向上した MR-BF-fGALIF では、スケッチコーパスの利用により、スケッチ線の揺らぎや歪みに対して頑強な距離尺度が学習された。一方で、検索精度が低下した MR-BF-fDSIFT では、スケッチコーパスの特徴が多様体に追加されることで、不適切な拡散が起きた可能性がある。

ここで BF-fGALIF と BF-fDSIFT を比較すると、SH12 の Hand-drawn クエリセットでは、BF-fGALIF の方が高い検索精度を示した。一方で Standard line クエリセットでは、BF-fDSIFT の方が高い検索精度を示した。Standard line のスケッチは、例えば熊の毛のような詳細な線を含むが、これらの線は特徴線とは異なる。よって、シルエットで詳細な線を見逃して比較する BF-fDSIFT が高い検索精度を示した。SH13 では、BF-fGALIF と BF-fDSIFT は同等の検索精度を示した。




図 5. SH12 における MR の効果。




図 6. SH13 (Testing セット)における MR の効果。

図7, 図8にそれぞれSH12の Hand-drawn クエリセットと Standard line クエリセットの Recall-Precision 曲線を示す。MAP での比較と同様、SH12 の Hand-drawn と Standard line の双方において、距離尺度の学習によって BF-fGALIF と BF-fDSIFT の検索精度が向上した。

図9にSH13の Testing クエリセットの Recall-Precision 曲線を示す。MR を用いた距離尺度の学習によって、BF-fGALIF と BF-fDSIFT の検索精度が僅かに改善した。

図7, 図8, 図9において、MR による距離尺度の学習によって、Recall 値が 0.4 以上における Precision 値が改善したのが見て取れる。特徴群の分布に適応した拡散距離で特徴比較をすることで、正解カテゴリの 3D モデルが検索結果のより上位に現われたためである。一方で、図8, 図9において、MR による距離尺度の学習を行うと Recall 値が 0.05 における Precision 値がやや低下した。これは検索結果上位の精度が低下したことを指す。提案手法では、スケッチ特徴と、モデルあたり複数の視点画像特徴を互いに接続した多様体グラフを生成する。このような多様体では、拡散処理の早い段階で、検索要求スケッチと類似した不正解 3D モデルの視点画像へ類似

度が拡散した場合、検索結果上位の検索精度が低下する。この問題は、例えば、検索結果上位のみを固定距離で順位付け、それ以外を MR による適応的距離で順位付けることにより解決可能である。




図7. SH12 Hand-drawn の Recall-Precision 曲線。




図8. SH12 Standard line の Recall-Precision 曲線。




図9. SH13 Testing の Recall-Precision 曲線。

3.2.2 既存手法との検索精度比較

表 2, 表 3, 表 4 に SH12 と SH13 における既存手法との検索精度の比較を示す。比較対象は, 3D 形状類似検索コンテスト SHREC2012 と SHREC2013 のスケッチ検索部門へ参加した手法群である。比較対象の手法群および BF-fGALIF, BF-fDSIFT は, いずれも 3D モデルを多視点レンダリングしてシルエット画像や輪郭画像, 特徴稜線画像を生成し, スケッチ画像と特徴比較する手法である。表 2, 表 3, 表 4 の手法の中で, MR-BF-fGALIF, MR-BF-fDSIFT, およびこれらを組み合わせた MR-BF-fGALIF+MR-BF-fDSIFT が, 特徴分布に適応した距離尺度を用いてスケッチの特徴と 3D モデルの多視点画像特徴を比較する手法である。表の中で(有), (無)は, それぞれ, スケッチコーパスの利用有り, スケッチコーパスの利用無し, を示す。また, MR-BF-fGALIF+MR-BF-fDSIFT はスケッチコーパスを用いて学習して得た拡散距離を 2 つ, それぞれの重み 1.0 で線形に足し合わせたものである。

SH12 において, FT, ST の 2 つの性能指標を用いた場合, 提案手法は最も高い検索精度を示した。提案手法の 1 つである MR-BF-fGALIF+MR-BF-fDSIFT の検索精度は, Hand-drawn クエリセットにおいて FT = 45.8 [%], ST = 61.9 [%]を示し, Standard line クエリセットでは FT = 54.6 [%]を示した。ST ではスケッチコーパス有りの MR-BF-fDSIFT が 73.3 [%]を示した。これらはいずれも, 比較したその他の手法と比較して現状で最も高い検索精度を示す。提案手法の FT と ST が高い理由は, 距離尺度の学習を行うことで再現率が改善したためである。MAP では, Hand-drawn クエリセットにおいて MR-BF-fGALIF+ MR-BF-fDSIFT, Standard line クエリセットではスケッチコーパス無しの MR-BF-fDSIFT が Li らの SBR-2D-3D [10]に次ぐ高い検索精度を示した。

SH13 において, 提案手法は, 比較した手法中最も高い検索精度を示した。提案手法 MR-BF-fGALIF + MR-BF-fDSIFT の検索精度は MAP = 13.6 [%]であり, SHREC2013 のスケッチ検索部門に参加した手法群の中で最も検索精度が高い VC+SC_NUM_100 法の MAP = 11.4 [%]を約 2 [%]上回った。MAP 以外の検索精度指標 (FT, ST)においても MR-BF-fGALIF + MR-BF-fDSIFT は最も高い検索精度を示した。提案手法である MR-BF-fGALIF+MR-BF-fDSIFT は, SH13 ベンチマークにおいて, 現状で最も高い検索精度を示す。

表2. SHREC2012 Hand-drawnクエリセットの検索精度 [%].

手法	FT	ST	MAP
BOF-SBR [8]	33.9	49.7	45.0
SBR-2D-3D [8][10]	41.5	58.1	*55.6
HKO-KASD [8]	15.0	25.8	25.4
Orig_DG1SIFT [8]	15.2	25.3	29.0
Dilated_DG1SIFT [8]	16.8	27.6	30.2
HOG-DTF [8]	16.7	28.6	29.2
HOG-SC [8]	21.5	33.5	33.1
BF-fGALIF	36.7	51.3	39.8
BF-fDSIFT	29.5	45.4	32.7
MR-BF-fGALIF (有)	*45.2	*58.9	48.5
MR-BF-fGALIF (無)	42.7	58.2	46.3
MR-BF-fDSIFT (有)	30.3	49.3	35.3
MR-BF-fDSIFT (無)	32.8	47.1	37.6
BF-fGALIF+BF-fDSIFT	36.9	52.9	40.5
MR-BF-fGALIF+MR-BF-fDSIFT	*45.8	*61.9	*49.3

表3. SHREC2012 Standard lineクエリセットの検索精度 [%].

手法	FT	ST	MAP
SBR-2D-3D [8] [10]	*54.2	70.0	*67.5
HKO-KASD [8]	14.6	26.3	24.3
Orig_DG1SIFT [8]	19.2	32.1	32.8
Dilated_DG1SIFT [8]	22.5	36.3	37.3
HOG-DTF [8]	19.2	31.3	33.5
HOG-SC [8]	18.3	24.2	30.7
BF-fGALIF	42.1	61.2	44.9
BF-fDSIFT	44.2	65.8	48.4
MR-BF-fGALIF (有)	48.7	61.7	52.4
MR-BF-fGALIF (無)	50.0	68.3	51.1
MR-BF-fDSIFT (有)	52.5	*73.3	57.5
MR-BF-fDSIFT (無)	52.5	*72.9	*60.5
BF-fGALIF+ BF-fDSIFT	47.1	71.7	50.5
MR-BF-fGALIF+MR-BF-fDSIFT	*54.6	69.2	57.6

表4. SHREC2013 Testingクエリセットの検索精度 [%].

手法	FT	ST	MAP
EFSD [9]	1.9	3.6	3.1
FDC [9]	3.8	6.8	5.1
SBR-2D-3D_NUM_50 [9][10]	7.7	12.4	9.5
SBR-VC_NUM_50 [9][11]	8.2	13.1	9.8
SBR-VC_NUM_100 [9][11]	9.7	14.9	11.4
BF-fGALIF	10.1	15.6	10.3
BF-fDSIFT	9.9	15.4	10.4
MR-BF-fGALIF (有)	11.9	17.9	12.0
MR-BF-fGALIF (無)	10.9	16.5	11.5
MR-BF-fDSIFT (有)	11.3	17.8	12.1
MR-BF-fDSIFT (無)	11.1	17.7	12.0
BF-fGALIF + BF-fDSIFT	*12.3	*18.6	*12.8
MR-BF-fGALIF+MR-BF-fDSIFT	*13.1	*19.5	*13.6

3.2.3 Manifold Ranking の計算時間

表 5 に SH12 と SH13 における検索要求スケッチ 1 個の検索に要する MR の計算時間を示す。MR は全てスコッチコーパス無しの場合の計算時間である。

SH12, SH13 共に, 固定距離よりも適応的距離 (MR) の計算時間が大幅に大きいことが分かる。MR の処理の中では, 類似度を拡散させる際の反復計算が時間の大部分を占める。

SH12 より SH13 の方が時間がかかるが, これは, 後者の方が多様体グラフが大きいためである。SH13 の多様体グラフを表現する行列 $\mathbf{W}$ の大きさは 17,062×17,062 だが, SH13 の多様体グラフを表現する行列 $\mathbf{W}$ の大きさは 60,036×60,036 である。

表 5. SH12 と SH13 における 1 クエリを処理する為の Manifold Ranking の計算時間 [s].

ベンチマーク	手法	特徴抽出	距離計算	合計
SH12	BF-fGALIF	0.14	0.14	0.28
	MR-BF-fGALIF	0.14	4.48	4.62
	BF-fDSIFT	0.09	0.54	0.63
	MR-BF-fDSIFT	0.09	5.36	5.47
SH13	BF-fGALIF	0.18	0.31	0.49
	MR-BF-fGALIF	0.18	36.83	37.01
	BF-fDSIFT	0.09	1.18	1.27
	MR-BF-fDSIFT	0.09	37.40	37.49

3.2.4 検索結果の例

図 10 は, SH12 と SH13 ベンチマークにおいて BF-fGALIF, MR-BF-fGALIF, MR-BF-fGALIF+MR-BF-fDSIFT の 3 つの手法を用い, 3 種のクエリを検索した結果の例である. 図の左端は検索要求である. その右側には検索結果上位 10 個を, 左が最上位, 右が最下位, の順で示す.

これらの例では, 距離尺度の学習によって検索精度が改善したことが分かる. 例えば, (a)のメガネカテゴリでは, 検索結果上位 10 件の正解数は BF-fGALIF が 3 件, MR-BF-fGALIF が 5 件, 検索結果が改善した. (b), (c)においても同様で, 距離尺度の学習により, 全体としては検索精度が改善した.

2 つの特徴の距離尺度を各々学習し, 個別に距離を計算した結果を足し合わせた MR-BF-fGALIF+MR-BF-fDSIFT も検索結果を改善している. 特に, 図 10 (c)の鉢植え植物カテゴリの正解数は, MR-BF-fGALIF の 6 件に比べ MR-BF-fGALIF+MR-BF-fDSIFT が 9 件と, 特徴の組み合わせにより頑強性が増したことがうかがわれる.

4. まとめと今後の課題

本論文では, 距離尺度の学習を用いたスケッチによる 3D モデルの検索手法を提案した. スケッチで 3D モデルを検索する従来の手法の殆どでは, 線画スケッチの画像と 3D モデルをレンダリングした特徴線画のそれぞれから抽出した特徴ペアを比較するが, 十分な検索精度が得られていなかった. そのひとつの原因として, 特徴間の比較に L1, L2, Cosine 等の固定距離を用いることが考えられる. スケッチ画に特有の抽象化, 多様な描画スタイル, 線の揺らぎや歪み, 不要な線, 線の交差等が特徴に影響を与えるため, 単純な距離計算では 3D モデルの特徴線画との比較がうまくいかない可能性がある.

提案手法では, 教師なし距離尺度学習手法の 1 つである Manifold Ranking (MR) [18]を用いて, 線画スケッチの特徴と 3D モデルをレンダリングした画像の特徴を合わせた特徴群の分布に適応した距離尺度で特徴比較を行った. 提案手法ではまず, スケッチ画像の特徴と, 全 3D モデルの各視点の特徴を頂点とした多様体グラフを生成する. 次にこの多様体グラフ上で, 検索要求となるスケッチの特徴から 3D モデルの各視点の特徴へと類似度を拡散させて得た, 多様体グラフ上の拡散距離に基づいて検索の順位付けを行う.

また, スケッチ画像と 3D モデルの視点画像の比較をより頑強にするため, 距離尺度の学習時に多数のスケッチからなるスケッチコーパスの利用を試みた. また, 複数特徴の各々で計算した適応的距離の線形結合による組み合わせも試みた.

評価実験の結果, 実験に用いた全てのベンチマークにおいて, MR で学習した適応的な距離による特徴比較の方が, 固定距離による特徴比較よりも, 有意に高い検索精度を示した. 特に, 2 つの特徴の適応的距離を線形結合で組み合わせた MR-BF-fGALIF+MR-BF-fDSIFT は, SH13 ベンチマークにおいて, 比較した複数の既存手法よりも高い検索精度を示した. また, スケッチコーパスの利用は, クエリセットとベンチマークの組み合わせによっては検索精度を改善することが分かった.

今後の課題は, 提案手法の高速化である. 提案手法は, スケッチ特徴と, 3D モデルの視点特徴の各々を頂点とした多様体グラフを生成するため, 多様体グラフの行列サイズが大きく, グラフ生成と MR の時間計算量と空間計算量が多い. そのため, 提案手法は, 大規模なスケッチコーパスや, 多数の 3D モデルから成る大規模データベースにスケールしない問題がある. 計算量でいう一つの問題は, MR では, データベース外 (Out-of-Sample) の検索要

求が与えられる毎に (前処理ではなく) 多様体グラフ生成と拡散を行う必要があり, すなわち, 検索要求ごとにその手間がかかることである. 今後は, MR 法の計算量の大幅な削減により効率的に 3D モデルの順位付けを行う手法を検討する.

参考文献














- [1] D. DeCarlo, A. Finkelstein, S. Rusinkiewicz, A. Santella, Suggestive Contours for Conveying Shape, *ACM TOG*, **22**(3), pp. 848-855, (2003).
- [2] M. Eitz, R. Richter, T. Boubekeur, K. Hildebrand, and M. Alexa, Sketch-Based Shape Retrieval, *ACM TOG*, **31**(4) pp.1-10, (2012).
- [3] T. Furuya, R. Ohbuchi, Dense sampling and fast encoding for 3D model retrieval using bag-of-visual features, *ACM CIVR 2009*, Article No. 26, (2009).
- [4] P. Geurts, D. Ernst, and L. Wehenkel, Extremely randomized trees, *Machine Learning Journal*, **63**(1), pp. 3-42 (2006).
- [5] C. Goldfeder, P. Allen, Autotagging to Improve Text Search for 3D Models, *Proc. 8th ACM/IEEE-CS Joint Conference on Digital Libraries 2008 (JCDL'08)*, pp. 355-358, (2008).
- [6] J. He, M. Li, H.-j. Zhang, H. Tong, C. Zhang, Manifold-ranking based image retrieval, *The 12th annual ACM international conference on Multimedia*, pp. 9-16, (2004).
- [7] Kanai S, Content-based 3D mesh model retrieval from hand-written sketch, *International Journal on Interactive Design and Manufacturing (IJIDeM)*, **2**(2), pp. 87-98, (2008).
- [8] B. Li, T. Schreck, A. Godil, M. Alexa, T. Boubekeur, B. Bustos, J. Chen, M. Eitz, T. Furuya, K. Hildebrand, S. Huang, H. Johan, A. Kuijper, R. Ohbuchi, R. Richter, J. M. Saavedra, M. Scherer, T. Yanagimachi, G. Yoon, S. M. Yoon, SHREC'12 track: Sketch-based 3D shape retrieval, *EG 3DOR 2012*, pp. 109-118 (2012).
- [9] B. Li, Y. Lu, A. Godil, T. Schreck, M. Aono, H. Johan, J. M. Saavedra, S. Tashiro, SHREC'13 Track: Large Scale Sketch-Based 3D Shape Retrieval, *EG 3DOR 2013*, pp. 1-9, (2013).
- [10] B. Li, H. Johan, Sketch-based 3D model retrieval by incorporating 2D-3D alignment, *Multimedia Tools and Applications*, **65**(3), pp.363-385, (2013).
- [11] B. Li, Y. Lu, H. Johan, Sketch-based 3D model retrieval by viewpoint entropy-based adaptive view clustering, *In Proc. Eurographics Workshop on 3D Object Retrieval 2013 (3DOR 2013)*, pp. 49-56, (2013).
- [12] D. G. Lowe, Distinctive Image Features from Scale-Invariant Keypoints, *Int'l Journal of Computer Vision*, **60**(2), November 2004.
- [13] J. M. Saavedra, B. Bustos, M. Scherer, and T. Schreck, STELA: sketch-based 3D model retrieval using a structure-based local approach, *ACM Int'l Conf. on Multimedia Retrieval (ICMR'11)*, **26** pp. 1-8, (2011).
- [14] T. Shao, W. Xu, K. Yin, J. Wang, K. Zhou, B. Guo, Discriminative sketch-based 3D model retrieval via robust shape matching, *Computer Graphics Forum*, **30** (7), (also at *Proc. Pacific Graphics 2011*), (2011).
- [15] H. Shin and T. Igarashi. Magic canvas: interactive design of a 3-D scene prototype from freehand sketches. In *GI '07: Proceedings of Graphics Interface 2007*, pages 63-70, 2007.
- [16] 立間淳司, 青野雅樹: 多様体ランキングを用いた 3 次元物体の形状類似検索, 情報処理学会論文誌 Vol.49 No.10 2008
- [17] S. M. Yoon, M. Scherer, T. Schreck, and A. Kuijper, Sketch-based 3D model retrieval using diffusion tensor fields of suggestive contours, *ACM Multimedia 2010*, pp. 193-200, (2010).
- [18] D. Zhou, J. Weston, A. Gretton, O. Busquet and B. Scholkopf, Ranking on Data Manifolds, In *Proceedings of NIPS 2003*, 2003.

 検索要求	BF-fGALIF									
	✓ 	✗ 	✗ 	✗ 	✗ 	✗ 	✗ 	✓ 	✗ 	✓ 
	MR-BF-fGALIF (コーパス有)									
	✓ 	✓ 	✗ 	✗ 	✗ 	✗ 	✓ 	✓ 	✓ 	✗ 
MR-BF-fGALIF+MR-BF-fDSIFT (コーパス有)										
	✓ 	✓ 	✓ 	✓ 	✗ 	✗ 	✗ 	✓ 	✓ 	✓ 

(a) SHREC2012 Hand-drawn メガネカテゴリの検索結果例.

 検索要求	BF-fGALIF									
	✗ 	✓ 	✓ 	✓ 	✓ 	✗ 	✗ 	✗ 	✗ 	✗ 
	MR-BF-fGALIF (コーパス有)									
	✗ 	✓ 	✓ 	✗ 	✓ 	✓ 	✗ 	✓ 	✗ 	✓ 
MR-BF-fGALIF+MR-BF-fDSIFT (コーパス有)										
	✓ 	✓ 	✗ 	✗ 	✓ 	✓ 	✗ 	✓ 	✗ 	✓ 

(b) SHREC2012 Standard line 蟻カテゴリの検索結果例.

 検索要求	BF-fGALIF									
	✓ 	✗ 	✓ 	✗ 	✗ 	✗ 	✗ 	✓ 	✗ 	✗ 
	MR-BF-fGALIF (コーパス有)									
	✗ 	✓ 	✗ 	✓ 	✓ 	✓ 	✗ 	✓ 	✓ 	✗ 
MR-BF-fGALIF+MR-BF-fDSIFT (コーパス有)										
	✓ 	✓ 	✓ 	✓ 	✓ 	✓ 	✓ 	✓ 	✓ 	✗ 

(c) SHREC2013 Testing 鉢植え植物カテゴリの検索結果例.

図 10. SHREC2012 Hand-drawn, Standard line, SHREC13 Testing における上位 10 件の検索結果例 .