

## 学習を用いた 3 次元形状類似検索

山本 明博<sup>1</sup>, 大淵 竜太郎<sup>2</sup>, 小林 準<sup>3</sup>, 清水 俊也<sup>4</sup>

<sup>1,2,3,4</sup>山梨大学 〒400-8511 山梨県甲府市武田 4-3-11

Mail: <sup>1</sup>g05mk039@ccn.yamanashi.ac.jp, <sup>2</sup>ohbuchi@yamanashi.ac.jp, <sup>3</sup>g05mk014@ccn.yamanashi.ac.jp,  
<sup>4</sup>g06mk009@ccn.yamanashi.ac.jp

**概要** 3次元モデルの形状に基づく類似検索において、形状特徴間の距離計算が性能を向上させるための重要な課題の 1 つである。形状特徴は数十を超える高次元のベクトルで定義されるため、形状特徴間の距離が正確に捉えられない可能性がある。そこで、学習用の 3 次元モデルデータベースを教師なし学習することで、距離計算を改善し検索性能を向上させる手法が提案されている。本論文では、複数の教師なし学習手法を複数の形状特徴と組み合わせ、検索性能と学習手法や形状特徴の関係を実験的に評価・検討する。実験から多様体学習を用いた特徴空間の学習は形状類似検索の性能を向上させるのに有効であることがわかった。

## Unsupervised-learning based approach 3D model retrieval

Akihiro Yamamoto<sup>1</sup>, Ryutarou Ohbuchi<sup>2</sup>, Jun Kobayashi<sup>3</sup>, Toshiya Shimizu<sup>4</sup>

<sup>1,2,3,4</sup>University of Yamanashi, 4-3-11 Takeda, Kofu-shi, Yamanashi-ken, Japan

Mail: <sup>1</sup>g05mk039@ccn.yamanashi.ac.jp, <sup>2</sup>ohbuchi@yamanashi.ac.jp, <sup>3</sup>g05mk014@ccn.yamanashi.ac.jp,  
<sup>4</sup>g06mk009@ccn.yamanashi.ac.jp

### Abstract

We have previously proposed a non-linear dimension reduction by using unsupervised learning for shape-based 3D model retrieval. The method learns, unsupervised, a mapping from the ambient (original) feature vector to the reduced dimensional “salient” feature vector. Retrieval performance improved significantly by computing the distance using the salient feature vectors. In this paper, we experimentally explore the interrelations of dimension reduction methods and shape descriptors. Specifically, we combine four dimension reduction methods, one linear and three non-linear, with eight shape descriptors for the experiments. The experiments showed that proximity based non-linear dimension reduction methods such as *Laplacian Eigenmaps* and *Locally Linear Embeddings* are more effective than the Principal Component Analysis, a globally linear dimension reduction method.

### 1. はじめに

3次元形状類似検索とは、ユーザが欲する「形状」を持つ 3次元モデルをデータベースから検索する手法である。これまでに多くの形状類似比較手法が提案されているが、検索性能は十分に満足できるものではない。この理由として、(1)計算された形状特徴が 3次元モデルの形状を正しく捉えられていない、(2)形状特徴の距離計算が正確に行われていない、という問題が挙げられる。特に(2)の問題に関して、例えば、既存の形状特徴として Absolute Angle Distance (AAD) [Ohbuchi05], Surflet Pair Relation Histogram (SPRH) [Wahl03]などが提案されているが、それぞれ 256, 625 次元と高次元なデータで表現される。このような高次元な形状特徴間で距離計算を行うと、いわゆる「次元の呪い」で正確な距離が測れない可能性がある。

この問題に対して、Ohbuchiらは教師なし多様体学習を用いて距離計算を改善させる手法を提案した[小林 06, Ohbuchi06]。この手法は、元々の高次元な特徴空間での距離ではなく、3次元モデルデータベースを教師なし学習することで推定される低次元多様体上の測地線距離を利用している。Ohbuchiらは、2次元画像の内容検索分野において Heらが提案した手法[He04]を 3次元モデルに適用した。Heらの方法は、形状特徴が  $n$  次元ベクトルで与えられたとき、非線形な多様体学習を用いて、特徴ベクトルが多様体を構成していると仮定する。学習によって多様体が推定されると、 $n$  次元ベクトルを  $m$  次元多様体 ( $m < n$ ) 上に射影し、多様体上の測地線距離によって、形状特徴間の距離が求められる。Ohbuchiらは教師なし学習手法として、Laplacian Eigenmaps (LE) [Belkin02]を、形状特徴として AAD, SPRH を用いている。Ohbuchiらの手法

は、距離計算を効率的に行うことができるが、実験に用いた学習手法や形状特徴が少ないことが問題である。

そこで、本手法は Ohbuchi らの手法を、複数の教師なし学習手法と形状特徴を用いて実験、評価することで、様々な学習手法による検索性能の違いを検討する。今回、形状特徴には AAD, SPRH, Exponential Euclidean Distance Transform (EDT) [Vranic04], Ray-based Spherical Harmonics (RSH) [Vranic04] の 4 つの手法を用い、さらに、各々の手法で多重解像度表現による形状比較手法も適応した。教師なし学習手法には、Principal Component Analysis (PCA), Kernel Principal Component Analysis (KPCA) [Haykin99], Locally Linear Embedding (LLE) [Roweis00], LE の 4 つの手法を用いて実験と評価を行った。実験の結果、非線形な特徴空間の学習手法を用いることは、いくつかの特徴量の比較性能を高める上で効果があることがわかった。その中でも、近傍に注目するような多様体学習は、特に効果が高いという結果が得られた。

## 2. 手法

3 次元データベース内の 3 次元形状モデルが成す多様体を推定し、これを用いて距離計算することで類似検索を行う手法の流れは以下の通りである。

学習の手順:

- (1) 形状特徴の抽出: 学習用データベース内の 3 次元モデルから形状特徴ベクトルを求める。
- (2) 特徴空間の学習:  $n$  次元特徴ベクトルが構成する  $m$  次元特徴空間を, PCA, KPCA, LE, LLE それぞれの手法から学習する。
- (3) 多様体の近似: LE, LLE のような多様体学習は学習サンプルのみの写像しか定義しない。学習サンプル以外の特徴ベクトルの写像を RBF network で近似する。RBF アルゴリズムは Matlab の Neural Network Toolkit に含まれる Chen らの RBF アルゴリズム [Chen91]を用いた。

検索の手順:

- (1) 形状特徴の抽出: 検索要求となる 3 次元モデルから形状特徴を求める。
- (2) 形状特徴の写像: 検索要求の  $n$  次元形状特徴ベクトルを近似された  $m$  次元特徴空間に写像する。
- (3) 測地線距離による検索:  $m$  次元特徴空間に写像された検索要求とデータベース内のモデルへの距離を計算し、距離の小さい順に検索結果を提示する。

### 2.1 形状特徴と教師なし学習手法

形状特徴には AAD, SPRH, EDT, RSH を用いた。

AAD と SPRH は共に剛体変換に不変なグローバルな形状特徴である。AAD は点対間の距離と法線ベクトルとの角度から成る 2 次元ヒストグラム, SPRH は 3 つの角度と距離から成る 4 次元ヒストグラムで定義される。EDT は形状の対称性を表す指標と、ボクセル化されたモデルから求められる指標との組み合わせから成る形状特徴である。RSH はモデルの重心から面に対して Ray を飛ばして得られる特徴である。また、AAD は 256 次元, SPRH は 625 次元, EDT は 544 次元, RSH は 136 次元で構成される特徴ベクトルである。AAD と SPRH は我々が実装したソフトウェアを用いて、EDT と RSH は [Vranic] に公開されたソフトウェアを用いて算出した。

教師なし次元削減手法には、線形な手法である PCA, 非線形な手法である KPCA, LE, LLE を利用した。PCA は線形な次元削減手法で、共分散構造を最もよく保存する特性を持つ。KPCA は非線形な次元削減手法で、入力データが非線形な変換で写像された新しい特徴空間において PCA を適応する手法である。KPCA による学習を 3 次元形状類似検索に用いる考えは、Leifman らの Relevance Feedback [Leifman05] にも利用されている。しかし、Leifman らの手法は学習を目的としていないため、KPCA が検索性能にどのような影響を与えたか詳細が不明である。そのため、本論文では KPCA を含めることとした。LLE は、元の特徴空間の局所的な線形構造を保持したまま、低次元空間へ写像する非線形多様体学習手法である。LE は、元の特徴空間の近傍を低次元空間でも保持するような写像方法である。

### 2.2 多重解像度特徴量の多様体学習

本論文では、多重解像度表現として、武井らの  $\alpha$  多重解像度表現による形状比較手法 [武井 05] を用いた。以下の手順で多重解像度特徴量を多様体学習し、3 次元モデルの形状を比較する。

- (1) 多重解像度表現の計算: 面の集合で構成される入力モデルを、点群モデルに変換し、 $1-1$  個のスケール値  $\alpha$  を用いて  $1-1$  個の 3D alpha shapes [Edelsbrunner94] を計算する。もっとも詳細な形状特徴をもつレベル  $l$  のモデルとしては、元の 3 次元モデルをそのまま用いる。
- (2) 多重解像度形状特徴の計算: 上で計算した  $l$  個のモデルそれぞれに対し単一解像度の形状比較手法を適用し、 $l$  個の形状特徴を得る。図 1 に多重解像度形状特徴の計算例を示す。
- (3) 多重解像度特徴量の学習: 上で計算した  $l$  個の形状特徴それぞれに対し、2.1 節の多様体学習を適用す

る。学習に用いる多様体の次元数  $m$  はすべての解像度レベルで共通とする。

- (4) 学習した多重解像度形状特徴の距離計算：上で計算、学習した 1 個の形状特徴から、解像度レベルごとに特徴間の距離を計算する。計算した解像度ごとの距離を重み 1.0 で線形結合し、学習した多重解像度形状特徴の間の距離を得る。

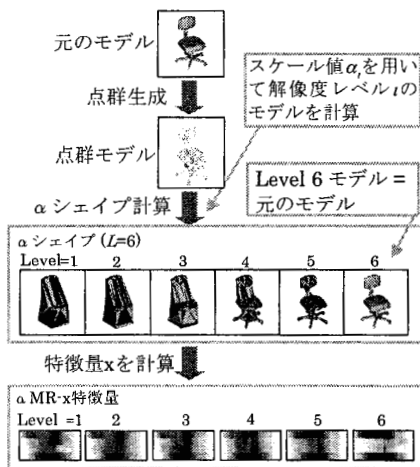


図 1. 多重解像度特徴量の計算例

### 3. 実験と結果

我々は、学習手法を Matlab で、形状特徴の抽出、距離計算、検索結果の評価は C++ で実装した。実験は、教師なし学習手法による検索性能の変化を調べる(3.1 節)。また、実際の検索結果例も示す(3.2 節)。

実験に利用したデータベースは、National Taiwan University 3D Model Database (NTU) ver.1 [NTU] と SHREC 2006 [Veltkamp06] ベンチマークである。NTU は、10,911 個のモデルを含んでおり、カテゴリには分類されていない。SHREC 2006 には、検索対象となる 1,814 個の予めカテゴリに分類されたモデルと、検索対象に含まれない 30 個の検索要求モデルが含まれている。検索要求モデルには、それぞれ正解カテゴリ(Highly Relevant, 以下 HR)とほぼ正解カテゴリ(Relevant, 以下 R)が割り付けられている。本手法では、実験に学習用と評価用の 2 種類のデータベースが必要である。学習用のデータベースには、NTU と SHREC2006 の検索対象モデルを組み合わせた 12,725 個のモデルの中から、Ohbuchi らの手法 [Ohbuchi06] で性能が最も良いとされた準乱数 Niederreiter 系列 [Bratley] を用いて、 $L$  個の学習用モデルを抽出し

用いた。評価は SHREC2006 ベンチマークにしたがって行い、性能指標も SHREC 2006 で公開されている評価ツールで計算した [Veltkamp06]。

形状特徴には、上記の 4 種類を用い、武井らの多重解像度表現による形状特徴と区別するため、特徴量  $x$  の単一解像度版を SR- $x$ 、多重解像度版を MR- $x$  と表記する。各学習手法には、いくつかのパラメータと削減後の次元数を指定する必要がある(PCA は寄与率, KPCA はカーネルの種類, LE と LLE は近傍点数, RBF network の広がりなど)。また、特徴ベクトル間の距離計算手法にも、L1 距離, L2 距離, Cosine 距離, Kullback-Leibler divergence (KLD) [Wah03] などさまざまな定義がある。これらの設定は、各形状特徴、学習手法でパラメータを変化させて実験を行い、その中で最も良い性能値になるように実験的に設定した。

#### 3.1 教師なし学習手法と検索性能

表 1 に PCA, KPCA, LE, LLE をそれぞれ用いて 4 つの特徴量を学習した結果を示す。また、参考として表 1 に SHREC2006 で高い性能を示した Makadia ら、Dars らの検索性能も記載する。

まず、PCA を用いた学習では、SR, MR 共にごの特徴量に対しても性能の向上は見られなかった。MR-SPRH においては、主軸をうまく計算することができず、特徴ベクトルが潰れてしまい、検索性能がかなり低下してしまった。KPCA もほとんどの特徴量で PCA と同様に性能は向上しなかった。ここでも、MR-SPRH は、うまく主軸を計算できずに性能が低下してしまう結果が得られた。しかし、RSH, MR-AAD では少しではあるが KPCA による学習で性能の向上が見られた。対して、LE, LLE は、多くの特徴量で性能の向上が見られた。特に、MR 特徴量において効果が高く、最も性能が高かった LLE で学習した MR-SPRH は、SHREC 2006 で首位の Makadia らの手法とほぼ同等の検索性能を示した。

#### 3.2 検索結果例

図 2 に実際の検索結果例を示す。図 2 の結果は、本実験中で最も性能が向上した、LLE を用いて 10,000 個のモデルを学習した MR-SPRH の結果である。検索要求のモデルには、QUERY 18 を用いた。QUERY 18 に割り付けられた正解(HR)カテゴリのモデル数は 15、ほぼ正解(R)カテゴリのモデル数は 27 モデルである。また、検索結果は上位 15 の結果を示す。検索結果中、太枠で囲ったモデルは正解(HR)、破線枠で囲ったモデルがほぼ正解(HR)、それ以外が不正解(Non Relevant)であることを示す。

結果は、学習がうまくいった例で、学習によって結果が良くなっているのがわかる。学習無し MR-SPRH では、HR のモデルが 15 件中 7 件だったのに対し、学習を用いることで 11 件の HR のモデルが検索されている。さらに、R のモデルも 1 件検索されている。

#### 4. まとめと今後の課題

本研究では、複数の教師なし学習手法と形状特徴を用いて実験を行い、その検索性能の違いを検討した。結果として、PCA のような線形な次元削減手法による特徴空間の学習は、我々が用いたような特徴量の性能を向上させるのに有効でないようである。また、KPCA のように、大域に注目するような非線形な次元削減手法は、検索性能向上にわずかに効果がある可能性がある。対して、LE, LLE のような近傍の関係のみに注目して非線形写像を行うような写像は、今回用いたいくつかの特徴量に関して、検索性能を向上させる上で有効であることがわかった。

今後の課題として、計算にかかるコスト(計算時間、消費メモリ等)を削ることがある。KPCA ではカーネル空間への写像が、LE, LLE では固有値分解、RBF network による多様体の近似が、多くの計算コストを要する。例えば、よりよいサブサンプリングを用いて、少ないモデル数で特徴空間を学習するなどが必要である。また、Isomap [Tanenbaum00] や Locality Preserving Projections (LPP) [He03] 等さらに多くの特徴空間の学習手法を用いて実験を進めることも挙げられる。

#### 参考文献

[Belkin02] Mikhail Belkin, Partha Niyogi: Laplacian eigenmaps for dimensionality reduction and data representation, *Technical Report TR 2002-01*, Univ. Chicago, Dept. Comp. Sci. and Statistics, (2002).  
[Bratley] P. Bratley, B. L. Fox, H. Niederreiter, Algorithm 738: Programs to Generate Niederreiter's Low-discrepancy Sequences, *ACM TOMS Algorithm 738*.  
[Chen91] Chen, S., C.F.N. Cowan, P. M. Grant: Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks, *IEEE Transactions on Neural Networks*, **2**(2), pp. 302-309, (1991).  
[Edelsbrunner94] H. Edelsbrunner, E. P. Mücke: Three-dimensional Alpha Shapes, *ACM TOG*, **13**(1), pp. 43-72, (1994).  
[Haykin99] S. Haykin, *Neural network a comprehensive foundation*, Second Edition, Prentice Hall, 842pages, (1999).  
[He03] Xiaofei He, and Partha Niyogi, Locality Preserving

Projections, *Advances in Neural Information Processing Systems 16*, Vancouver, Canada, 2003.

[He04] Xiaofei He, Wei-Ying Ma, Hong-jiang Zhang: Learning an Image Manifold for Retrieval, *Proc. ACM Multimedia 2004*, pp. 17-23 (2004).

[Leifman05] G. Leifman, R. Meir, A. Tal, Semantic-oriented 3d shape retrieval using relevance feedback, *The Visual Computer (Pacific Graphics)*, **21**(8-10), pp. 865-875, (2005).

[NTU] NTU 3D Model Database ver.1

<http://3d.csie.ntu.edu.tw/>

[Ohbuchi05] R. Ohbuchi, T. Minamitani, T. Takei: Shape Similarity Search of 3D Models by using Enhanced Shape Functions, *International Journal of Computer Applications in Technology (IJCAT)*, **23**(3/4/5), pp. 70-85, (2005).

[Ohbuchi06] R. Ohbuchi, Jun Kobayashi, Unsupervised Learning from a Corpus for Shape-Based 3D Model Retrieval, *poster paper*, *Proc. ACM MIR 2006*, Santa Barbara, CA, U.S.A., Oct.26-27, (2006).

[Roweis00] S.T. Roweis, L.K. Saul, Nonlinear Dimensionality Reduction by Locally Linear Embedding, *Science*, **290**(5500), pp. 2323-2326, (2000).

[Tanenbaum00] J. B. Tanenbaum, V. de Silva, J.C. Langford, A Global Geometric Framework for Nonlinear Dimensionality Reduction, *Science*, **290**(5500), pp. 2319-2323, (2000).

[Vranic04] D. V. Vranic, *3D Model Retrieval*, Ph.D Thesis, University of Konstanz, Germany (2004).

[Vranic] Tools for 3D model retrieval

<http://merkur01.inf.uni-konstanz.de/3Dtools/>

[Veltkamp06] R. C. Veltkamp, R. Ruijsenaars, Michela Spagnuolo, R. Van Zwol, F. ter Haar, SHREC2006 3D Shape Retrieval Contest, Utrecht University Dept. Information and Computing Sciences Technical Report UU-CS-2006-030 (ISSN: 0924-3275)

<http://give-lab.cs.uu.nl/shrec/shrec2006/index.html>

[Wahl03] E. Wahl, U. Hillenbrand, G. Hirzinger, Surflet-Pair-Relation Histograms: A Statistical 3D-Shape Representation for Rapid Classification, *Proc. 3DIM 2003*, pp. 474-481, (2003).

[武井 05] 武井 毅, 大淵 竜太郎, 多重解像度表現を用いたポリゴンスープ 3 次元モデルの形状類似比較, 画像電子学会誌, 第 34 巻, 第 4 号, pp. 256-269, 2005 年.

[小林 06] 小林 準, 大淵 竜太郎, コーバスの多様体学習を用いた 3 次元形状モデルの検索, *Visual Computing グラフィックスと CAD 合同シンポジウム 2006*, pp.113-118.

表 1. PCA, KPCA, LE, LLE で特徴空間を学習した結果

形状特徴	解像度	学習手法	学習モデル数	距離計算	FT-HR	FT-R	DAR	MNCG @25	MNDCG @25
AAD	SR	No	-	cos	24.55	26.48	0.3364	0.3405	0.3771
		PCA	5,000	cos	24.03	27.23	0.3396	0.3553	0.3851
		KPCA	4,000	cos	24.22	27.01	0.3401	0.3511	0.3850
		LE	10,000	cos	28.04	30.12	0.3795	0.4022	0.4382
		LLE	10,000	cos	28.31	28.54	0.3636	0.3994	0.4180
	MR	No	-	cos	31.02	31.38	0.4320	0.4386	0.4793
		PCA	10,000	cos	31.08	32.98	0.4429	0.3556	0.3853
		KPCA	4,000	cos	32.22	33.52	0.4312	0.4375	0.4737
		LE	10,000	cos	35.76	35.95	0.4763	0.4824	0.5311
		LLE	10,000	cos	36.84	36.82	0.4780	0.4918	0.5336
SPRH	SR	No	-	KLD	26.68	31.77	0.3990	0.3920	0.4384
		PCA	5,000	cos	27.20	28.66	0.3722	0.3560	0.4035
		KPCA	3,500	cos	26.49	28.07	0.3679	0.3590	0.4104
		LE	10,000	cos	30.27	31.59	0.4116	0.4275	0.4647
		LLE	10,000	cos	30.32	31.03	0.4047	0.4294	0.4658
	MR	No	-	KLD	34.93	32.84	0.4631	0.4519	0.5101
		PCA	5,000	cos	27.20	28.66	0.3722	0.3560	0.4035
		KPCA	3,500	cos	26.49	28.20	0.3697	0.3610	0.4170
		LE	10,000	cos	42.24	40.65	0.5250	0.5421	0.5867
		LLE	10,000	cos	44.44	41.93	0.5382	0.5584	0.6013
RSH	SR	No	-	L1	27.46	26.84	0.3782	0.3641	0.4296
		PCA	10,000	L1	26.50	24.71	0.3538	0.3609	0.4118
		KPCA	4,000	L1	29.31	27.22	0.3837	0.3826	0.4425
		LE	10,000	cos	29.20	25.82	0.3561	0.3837	0.4154
		LLE	10,000	cos	25.47	23.22	0.3307	0.3323	0.3849
	MR	No	-	L1	36.45	31.06	0.4359	0.4596	0.5006
		PCA	5,000	L1	37.08	31.66	0.4438	0.4673	0.5124
		KPCA	4,000	L1	37.77	32.56	0.4564	0.4672	0.5176
		LE	10,000	cos	38.60	35.18	0.4728	0.4909	0.5333
		LLE	10,000	cos	37.52	33.89	0.4563	0.4883	0.5238
EDT	SR	No	-	L1	31.46	29.08	0.4027	0.3862	0.4377
		PCA	10,000	L1	28.55	26.76	0.3755	0.3739	0.4198
		KPCA	3,500	L1	29.06	26.62	0.3786	0.3498	0.4142
		LE	10,000	cos	28.42	27.66	0.3817	0.3948	0.4437
		LLE	5,000	cos	29.54	28.72	0.3891	0.4083	0.4573
	MR	No	-	L1	34.68	35.34	0.4604	0.4692	0.5135
		PCA	10,000	L1	35.64	34.29	0.4529	0.4627	0.5022
		KPCA	3,500	L1	36.13	32.93	0.4520	0.3613	0.4979
		LE	5,000	cos	38.55	37.34	0.4768	0.4955	0.5350
		LLE	5,000	cos	38.49	38.86	0.4861	0.5043	0.5442
SHREC 2006	Makadia, (run 2)				44.77	40.55	0.5499	0.5498	0.5906
	Dars, (run 1)				42.75	37.03	0.5242	0.5246	0.5791

FT-HR: Mean First Tier (Highly Relevant)

FT-R: Mean First Tier (Relevant)

DAR: Mean Dynamic Average Recall

MNCG @25: Mean Normalized Discounted Cumulated Gain @25

MNDCG @25: Mean Normalized Discounted Cumulated Gain @25



QUERY 18

Orig. MR-SPRH(学習無し) 検索結果 HR=7, R=0				
1.	2.	3.	4.	5.
6.	7.	8.	9.	10.
11.	12.	13.	14.	15.
MR-SPRH LLE-10,000L 検索結果 HR=11, R=1				
1.	2.	3.	4.	5.
6.	7.	8.	9.	10.
11.	12.	13.	14.	15.

図2. SHRECの検索結果例(検索結果上位15件).