

RI-001

学習を用いた3次元モデル検索手法における人工的教示例拡張の効果

Effectiveness of Training-Set Augmentation for Learning-Based 3D Model Retrieval Methods

手塚 将来¹, 大淵 竜太郎²
Masaki Tezuka¹, Ryutarou Ohbuchi²^{1,2}山梨大学 〒400-8511 山梨県甲府市武田 4-3-11^{1,2}University of Yamanashi, 4-3-11 Takeda, Kofu-shi, Yamanashi-ken, 400-8511, JapanMail: ¹g08mk022@yamanashi.ac.jp, ²ohbuchi@yamanashi.ac.jp

ABSTRACT

3次元モデルの形状類似検索の性能を向上させる手法の一つとして、検索対象の特徴群が成す部分空間を学習して次元削減を行うことで、特徴間の距離計算を改善する手法が注目されている。この種の手法で用いられる学習アルゴリズムは、多数の学習サンプルがあって初めて検索性能を向上させることができる。しかし、実際には十分な数の学習サンプルを得られないことが多い。本稿では、限られた数の教示例(学習サンプル)を暗黙の前提知識に基づいて増やすことで、部分空間の学習を助ける手法を提案し、複数種の3次元モデルデータベースおよび複数種の学習手法のもとで実験的性能評価を行った。その結果、教示例の拡張を用いて学習した際に、場合によって3次元モデルの検索性能の向上が実現されることがわかった。

1. はじめに

近年、機械設計や医療、ゲームや映画など様々な分野で3次元モデルが利用されるようになり、多くの3次元モデルが世の中に出回っている。このように3次元モデルが広まる中で、3次元モデルをその形状に基づいて比較、検索、分類するための研究がなされている。

形状に基づく類似検索を行う場合、モデルの3次元形状を直接比較するのは困難なため、モデルの形状特徴を捉えて数値化した特徴量を用いて比較する。しかし、3次元モデルの特徴量は次元が高い(数十次元～数千次元)ものも多く、いわゆる「次元の呪い」などにより効果的な距離比較が困難なことが多い。そこで、特徴空間における特徴量の分布からその部分空間を学習し、高次元の特徴を低次元の部分空間に写像、つまり次元削減することによって比較の際の距離計算を効果的に行う手法が提案されている。部分空間の推定を特徴量の分布のみから教師無しで行う手法を教師なし次元削減と呼ぶ。例として、非線形な多様体学習Locally Linear Embedding (LLE) [1]などを3次元形状類似検索に適応したOhbuchiらの手法[2]がある。

3次元モデルの比較には形に加えて、その形を持つ意味が重要な場合が多い。そこで、意味カテゴリを考慮した教師あり学習を用い、人間によって予め意味的なクラスに分類されたラベルを持つ形状特徴量を用い、形の情報と意味の情報を同時に考慮した学習と次元削減を行う手法(教師あり次元削減)がある。ただ、意味的なクラスに分類された教示例を多量に用意することは人的コストなどの点から大変困難であるため、教師なし学習と教師あり学習を組み合わせた半教師ありの手法で意味クラスの学習を効率化するOhbuchiらの半教師あり次元削減手法[3]も提案されている。

上記の教師なし、教師あり、半教師あり、いずれの学習手法も、学習による性能向上効果を得るには多くの学習サンプル

を必要とする。特に、入力となる特徴量の次元が高ければ高いほど、また捉えようとする特徴の分布が複雑なほど、多くのサンプルを要する。しかし、大量の学習サンプルを用意することは困難である。例えば、機械部品を検索する際、検索対象としたいような機械部品だけからなる3次元モデルについて、ラベルの振られていない、教師なし学習用のデータベースを入手するのは容易でないことが多い。さらに、前述のように、教師あり学習や半教師あり学習を行うのに必要な、クラス情報を持つ意味ラベルのついた多量の学習サンプルを用意するのは大変困難である。

本研究では、教示例の特徴数を人工的に増やす手法を提案し評価する。提案手法では、人間が先見的に知っている知識を利用して人工的に拡張した学習サンプルを用いて学習効果を高める。具体的には、比較的少数の学習用3次元モデルに対し、直交軸に沿う方向でランダムなスケールリングを3次元モデルの意味が変わらない程度に加え、学習サンプルを拡張する手法を提案する。そのような幾何変形は、3次元モデルの多くで許容されるからである。

評価実験の結果、複数のデータベースにおいて、形状特徴量、学習手法、形状変形比率に依存するものの、教示例を人工的に拡張することで、拡張する前の教示例を学習した場合に比べ検索性能が向上するところがあることがわかった。例えば、形状特徴量SPRH [4]に多重解像度表現[5]を用いた教示例サンプルを、形状変形比率10%で5,000個に拡張して学習した場合、SHREC2006 [6]の性能指標の一つであるMean Average Precisionが、学習を利用した拡張前の場合と比べ、約3%向上した。しかし、反対に、形状特徴量RSH [7]を用いて同様の条件で評価した場合、学習を利用した拡張前の場合と比べ、Mean Average Precisionが約1%低下した。

2. 関連研究

3次元モデルの形状類似検索において、検索要求の提示手法としてスケッチなど種々考えられる。本研究では、ユーザが検索要求である3次元モデルをシステムに与えるとする。システムは、この3次元モデルの形状に類似する3次元モデルをデータベースより検索し、検索結果(群)をユーザに提示する(図1)。まず、前処理として、検索対象となる3次元モデルから形状特徴量を抽出し、3次元モデルと共にデータベース内に保存しておく。ユーザから検索要求が与えられると、システムは検索要求から前処理と同様の手法で形状特徴量を抽出する。ついで、検索要求から求められた形状特徴量と、前処理時に計算しておいたデータベース内の全3次元モデルの形状特徴量との類似度計算を行い、モデル間の類似度を求める。最後に、求められた類似度を降順に並び替え、類似度の大きいモデルから検索結果としてユーザに提示する。

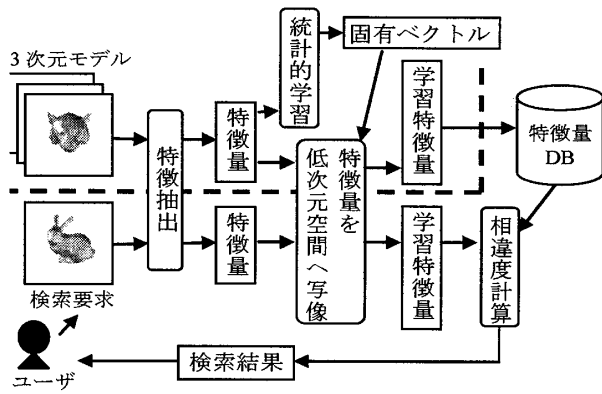


図1. 本検索手法の枠組み

モデル間の距離計算を行う上での課題のひとつに3次元形状特徴ベクトルの次元数がある。3次元形状特徴ベクトルは数十次元から数千次元という高次元のものが多い。さらに入力となる特徴ベクトルの次元が高ければ高いほど、学習の効果をj得るためには多くの学習サンプルが必要となる。そこで、Ohbuchiらの手法[2]では、コーパスを用いた多様体学習を利用して距離計算手法を改善することで、検索性能を向上させた。Ohbuchiらは多様体学習にLLEやLaplacian Eigenmaps (LE) [8], Isomap [9]を使用して実験を行っている。LLEやLE, Isomapは、学習した特徴点だけで写像が定義され、不連続な写像となる。そのため、検索要求が学習したデータベース外のモデルであるときに、その特徴量の写像を得ることができない。Ohbuchiらはこの問題を解決するために、Heらが提案した手法[10]を3次元形状類似検索に適応した。Heらは、2次元画像の類似検索において、Radial Basis Function (RBF)ネットワーク[11, 12]を用いることで、多様体を連続関数で近似し、LLEなどの多様体学習が不連続な写像を与える問題を解決した。

しかし、3次元モデルの形状特徴でだけでは検索が不十分という問題が教師なし学習にはある。そこで、意味カテゴリを利用した教師あり学習がある。教師あり学習ではクラスの分類情報のラベルを持つ学習用データが少ないため、学習の効果が得にくいことがあるが、Ohbuchiらは教師なし学習と教師あり学習を組み合わせる半教師あり学習を行うことでこの問題を解決した[3]。Ohbuchiらの半教師あり学習では、まず、ラベルを持たない多量な3次元モデル群を非線形な教師なし学習により高次元な(元々の形状特徴の次元よりは低い)特徴空間を精製する。次に、精製した特徴空間において、ラベルを持つ少量な3次元モデル群に教師あり学習を行うことで低次元特徴量を得る。この2段階の学習により、ラベルを持つ少量な学習サンプルでも効率的に意味を学ばせることを可能とする。

一般的な学習手法は統計的であり、学習の効果をj得るには、大量な学習サンプルが必要とされる。Ohbuchiらの研究[2]によると、対象とするデータベースや形状特徴に依存するものの、元の特徴と比較して、教師無し次元削減の学習サンプル数1,000程度以下では逆に検索性能が低下した。サンプル数が1,000程度を超えると検索性能が元の特徴を上回り、5,000個程度でほぼ頭打ちになった。しかし、検索したい3次元モデルと同種の学習サンプルを5,000個も用意するのは難しい。例えば、SHREC2006で使用するデータベースは1,814モデル、SHREC2007 [13] CAD models trackで使用するデータベースは867モデル、SHREC2007 3D face models trackで使用するデータベースは1,516モデルしか存在しない。Ohbuchiらの半教師あり学習[3]では、少量なラベル付き学習サンプルの学習

を、その前段階に多量のラベル無しサンプルによる教師無し次元削減をはさむことで効率化した。しかし、教師無し次元削減の学習は、検索対象と相似と推定される多数のモデルを収集して行っており、検索対象にもっとも効果的な学習がなされたとは限らない。

本研究では、我々は、教師無し次元削減、教師あり次元削減を学習するための学習サンプルを人工的に拡張することでこの問題を解決することを試みる。学習サンプル(教示例)の人工的な拡張は、2次元画像の文字認識、物体認識の分野で少数が提案されている。例えば、Canoらは手書き文字認識における教示例の拡張を提案した[14]。Canoらは、傾けたり、膨張、侵食、縮小したりできるという2次元画像の暗黙の前提知識を利用して、データベースの人工的な拡張を行った。その結果、拡張前に比べ性能が改善したが、拡張を行わず、実際に(本物の)教示例を増やした場合の方がより好ましい結果となった。他に、Sappらは物体認識における教示例の拡張を提案した[15]。Sappらは2次元画像の前景と背景を合成することで、新たに教示画像を作り出してデータベース拡張を行い、物体認識性能を向上させた。

本研究では、3次元モデルで許容されるようなデータの変化を利用して、教示例の拡張を行い、その効果を3次元モデル検索の性能比較により実験的に評価する。評価に当たっては、複数の検索対象データベース(機械部品、多様な一般モデル、顔、など)と複数の学習手法(教師なし、教師あり、など)を組み合わせて比較した。3次元モデルの検索において教示例を拡張した例は、我々の知る限り、本研究が初めてである。

3. 提案手法

2章で述べたように、学習を用いた3次元モデルの形状類似検索を行う場合、5,000個程度の学習サンプルを必要とする。また、2次元画像の分野では学習サンプルの人工的な拡張を行うことで学習効果を高める手法が提案されている。そこで、本稿では、小数の3次元モデルの学習サンプルを人工的に拡張して、部分空間の学習を助ける手法を提案する。

提案手法では、少量な学習サンプルをある条件で幾何変形することで新たな3次元モデルを作成し、学習サンプルを増やす。こうして数を多様性を増やした3次元モデルのデータベースから特徴量群を抽出し学習に用いる。3次元モデルの幾何変形には、種々の軸に対する大域的あるいは局所的な伸縮やねじれ、あるいは間接を持つモデルにおける姿勢変化などがある。これらのうち、本稿では、モデルごとに求めた軸に対する大域的な伸縮を利用して学習サンプルを拡張する。

これに対し、ねじれによる変形は、ねじれの軸や範囲などの指定が必要で、実験が困難である。姿勢変化の指定も、対象となる3次元モデルとその利用法に依存し、実験が困難である。したがって、本研究では、ねじれや姿勢変化は対象としない。

以下に本稿で行った教示例の人工的拡張の流れを説明する。また、図2に教示例の人工的拡張を行ったモデルの例を示す。ただし、図2では変化がわかりやすいように変化の割合を本実験で使用した割合よりも大きくしてある。




図2. 教示例の人工的拡張の例 (分かりやすいように変化の割合を誇張してある)

教示例の人工的拡張の流れ

- (1) 拡張前のモデル数 p 個から拡張後のモデル数 q 個の分だけ乱数を用いてサンプリングする。このとき、少量な教示例からの学習を想定しているため、 $p < q$ となり、サンプリングしたモデルは重複することがある。
- (2) サンプリングした各モデルに対し以下を実行する。
 - (2-1) 乱数を用いて、 x, y, z 軸から1つ、または複数の軸の組み合わせを選択する。
 - (2-2) (2-1)で決められた座標軸に対し、指定した範囲内で乱数を用いて形状変形比率をそれぞれ定め、3次元モデルの対応する座標値に掛ける。

4. 実験と結果

提案手法の有用性を調べるため、以下の実験を行った。

- 実験 1) 特徴量における教示例の拡張の効果 (4.1 節)
- 実験 2) 学習手法における教示例の拡張の効果 (4.2 節)
- 実験 3) 形状変形比率における教示例の拡張の効果 (4.3 節)
- 実験 4) 教示例の拡張を用いた学習とコーパスを用いた学習の比較 (4.4 節)

各実験の検索性能評価のために、SHREC2006 benchmark, SHREC2007 CAD models track benchmark, SHREC2007 3D face models track benchmark の3つの benchmark を用いた。

SHREC2006 benchmark は、2006年に行われた3次元形状類似検索コンテスト SHREC (SHape REtrieval Contest) 2006 で用いられた benchmark である。検索対象は、3次元形状類似検索において最もよく利用されるデータベースの一つである Princeton Shape Benchmark (PSB) [16] の test set (907models), train set (907models)を合わせた1,814個のモデルである。また、検索要求はPSBに含まれない30個のモデルである。検索対象のモデル群は、161個のクラスに分けられており、検索要求モデルには複数の正解クラス(HR)とほぼ正解クラス(R)が割り当てられている。ほぼ正解とは、形状は似ているが、意味的には異なるクラス群に属するモデルである。

SHREC2007 CAD models track benchmark は、Engineering Shape Benchmark (ESB) [17] 867個を検索対象として使用する。また、検索要求はESBに含まれない45個のモデルである。検索対象のモデル群は45個のクラスに分けられており、検索要求モデルには正解クラスが割り当てられている。ESBは前述の2つのデータベースとは異なり、ほぼ正解クラスは割り当てられていない。そのため、ESBでは検索性能指標のMAPやMFTにおいてHRしかない。

SHREC2007 3D face models track benchmark は、検索要求データベースに64個、検索対象データベースに1,516個のモデルがある。検索対象モデルには、それぞれ検索要求モデルに対する複数の正解クラス(HR)とほぼ正解クラス(R)がある。また、検索対象モデルの中には、検索対象モデルと形は同じだが、向きや大きさが違うモデルが含まれている。

図3に各データベースのモデル例を示す。

検索性能の数値による評価については、SHREC2006 benchmark で用いられている以下の2つの性能指標を用いた。

- ・ Mean Average Precision (MAP)
- ・ Mean Normalized Discounted Cumulated Gain (MNDCG)

MAPは検索結果にHighly Relevant (HR)が出現したときの

適合率の平均値を各検索要求で平均した指標である。MAPでは、HRのみで性能を測定した場合、Relevant (R)も含めて性能を測定した場合のそれぞれがある(以下MAP-HR, MAP-R)。MNDCGは検索結果上位@件の検索スコアを示す。スコアは、上位@件にHR, Rが多く検索されるほど高い値を示す。




図3. 各データベースのモデル例. (a)一般モデル PSB, (b)CADモデル ESB, (c)顔モデル

4.1. 特徴量における教示例の拡張の効果

特徴量に以下の4つの特徴量を用いた。

- ・ AAD [18] (256次元)
- ・ SPRH [4] (625次元)
- ・ EDEDT [7] (544次元)
- ・ RSH [7] (136次元)

AAD, SPRHは双方ともモデルを点群表現にして全体形状を解析する特徴量である。EDEDTは、2値ボクセル化したモデルから得る特徴と形状の対称性測度から得る特徴を融合して得る特徴量である。RSHは、モデルの重心から面へRayを飛ばして形状特徴を得る。AAD, SPRHには我々が実装したプログラムを利用した。また、EDEDT, RSHは[19]に公開されたソフトウェアを用いて算出した。

また、形状特徴抽出にあたり、一般モデルとCADモデルの形状特徴抽出では、3次元モデルの多重解像度表現を用いた(以下、MR_AADのように記す)。一般モデルとCADモデルについては、多重解像度表現を利用すると性能が向上することが先行研究によりわかっている。一方、顔モデルの形状特徴量の抽出にあたっては、ある1つの元々の3次元モデルのみを利用する単一解像度表現を用いた(以下、SR_AADのように記す)。顔モデルに多重解像度表現を使用しなかった理由は、顔モデルが目や耳、鼻といった細かな部分によって判断される必要があるので、粗い形状を利用する多重解像度表現は不向きと考えたためである。本研究では、多重解像度表現として、武井らによって提案された α 多重解像度表現による形状比較手法[5]を用いた。 α 多重解像度表現は、点群表現のモデルに対し複数のスケール値をもとに有限個の3D alpha shapes [20]を生成する。武井らの手法では、複数のスケール値のモデル群から複数の特徴を抽出し、これを統合して比較する。統合には特徴量のベクトルを接続する方法なども考えられるが、ここでは、解像度ごとに距離を求め、これら距離の線形和を全体の距離とする[20, 2,3]を利用した。学習を適用する場合には、解像度ごとに学習次元削減を施したのち、解像度ごとに距離計算し、その結果の距離群を統合する。

学習手法として教師なし学習(Unsupervised Dimensionality Reduction, 以下UDR)のLLEを利用した。また、さしあたり拡張モデル数を5,000個に、形状変形比率を10%に設定した。

特徴量ごとの教示例の拡張の効果を図4に示す。図4(a)(b)から、MR_SPRH を用いたときに、教示例の拡張を利用した学習手法が教示例の拡張を利用しない学習手法より一般モデルで約3%、CADモデルで約2%高い性能を示すことがわかる。他の特徴量では教示例の拡張による検索性能の向上はみられなかった。また、CADモデルのMR_RSH以外の特徴量について、教示例の拡張を利用した学習手法は学習なし手法より高い性能を示した。

図4(c)によると、顔モデルの場合、4つの特徴量のいずれについても教示例の拡張の効果がない。顔モデルで教示例拡張の効果が得られなかった理由として、モデルの性質がある。一般のモデルやCADモデルなどでは全体形状の差異が大きい。しかし、顔モデルは鼻や目などの細かな部分に重要な差異がある。したがって、全体を伸縮する提案手法の変形で顔モデルの教示例を拡張しても効果がなかったと考えられる。




図4. 特徴量と手法の性能比較. (a)一般モデル, (b)CADモデル, (c)顔モデル

顔モデルを対象とした場合には提案手法の効果はないといえるので、学習手法における教示例の拡張の効果(実験2)と形状変形比率における教示例の拡張の効果(実験3)は顔モデルについて検証しなかった。

4.2. 学習手法における教示例の拡張の効果

学習手法に教師なし学習(UDR)、教師あり学習(Supervised Dimensionality Reduction, 以下 SDR)、半教師あり学習(Semi-Supervised Dimensionality Reduction, 以下 SDDR)の3つを用いた。

UDRにはLLEを使用した。LLEは非線形な次元削減手法で、入力データ群の高次元空間での局所的な線形構造を保持するような低次元多様体への写像を与える。LLEでは、近傍の数、削減後の次元数、RBFネットワークのスプレッドの3つをパラメータとして変化させて最も性能の良いパラメータを求めた。また、SDRにはSLPPを使用した。SLPPは線形な次元削減手法であり、空間的に近くないとしても同じクラスに属するサンプルをつなげる手法である。SLPPでは、削減後の次元数をパラメータとして変化させ、最も性能の良いパラメータを求めた。さらに、UDRとSDRを組み合わせた手法であるSSDRにはUDRのLLEとSDRのSLPPを使用した。SSDRでは、多量な一般モデルのデータベースから5,000個をLLEにより学習し、その後、拡張した教示例をSLPPにより学習した。このとき、多量な一般モデルのデータベースとしてNational Taiwan University 3D Model Database (NTU) [21]を使用した。

パラメータを変化させたときの検索性能の例として、時限削減後の次元数と検索性能の変化を図5に示す。図5は一般モデルについて特徴量MR_SPRHを用いて、拡張モデル数5,000個、形状変形比率10%で教示例を拡張したときの各学習手法の検索性能である。SLPPは削減後の次元数のパラメータに敏感であるため、LLEよりも小さな間隔で次元をとった。LLEのようにパラメータが複数ある場合には、ある1つのパラメータを変化させるときには他のパラメータ群は固定した。

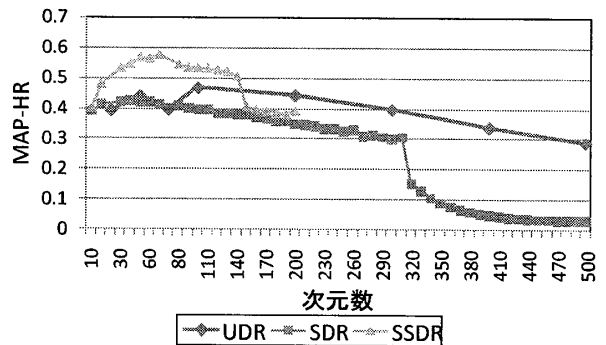


図5. 次元数の変化による検索性能のグラフ例

実験2では、拡張モデル数を変化させて検索性能を比較した。また、さしあたり形状変形比率を10%に設定した。

図6に一般モデルを対象とした場合、図7にCADモデルを対象とした場合の学習手法における教示例の拡張の効果を示す。このとき、特徴量は図4(a)(b)より教示例の拡張の効果がみられたMR_SPRHを用いた。

図6, 7の評価指標MNDCG@5に注目する。一般モデルでは、5,000個に拡張した3次元モデルをUDRで学習した場合に約5%、7,000個に拡張してSDRで学習した場合に約11%、5,000個に拡張してSSDRで学習した場合に約7%の性能が向上したとわかる。CADモデルでは、3,500個に拡張してUDRで学習した場合に約1%、5,000個に拡張してSDRで学習した場合に約8%の性能が向上し、SSDRで学習した場合には教示例拡張の効果が得られなかったとわかる。また、一般モデルでは全ての学習手法において、CADモデルではSDRにおいて、検索結果上位@件数が小さいと教示例の拡張の効果が大きいといえる。つまり、提案手法によって検索結果の上位に正解モデルが与えられやすくなったといえる。さらに、CADモデルのUDRやSSDRで提案手法の効果があまり見られなかった理由として、ESB 867個の学習で十分な傾向を捉えられ

ていた可能性がある。CADモデルは一般モデルと比べて3次元モデルの範囲が狭く傾向が偏っているモデル群であるため、拡張した教示例の特徴量が3次元モデルの範囲を広げてしまった可能性がある。

4.3. 形状変形比率における教示例の拡張の効果

拡張後のモデル数を5,000個に設定し、計算量が少ないSDRのSLPPを学習手法に用いたうえで、形状変形比率を変化させて検索性能を求めた。

一般モデルとCADモデルを対象とした場合の形状変形比率における教示例の拡張の効果を図8に示す。

図8より、一般モデルでは、形状変形比率が10%のときに最も良い性能を示すことがわかる。この結果から、一般モデルは教示例の拡張の際にある程度の変形を行うと性能は向上するが、変化を大きく過ぎると性能は低下するといえる。形状変形比率を30%とした場合に、0%とした場合よりも検索性能が低下した理由として、3次元モデルを変形しすぎて、形が崩れたことが考えられる。一方、CADモデルでは、形状変形比率が0.5%のときに最も良い性能を示すことがわかる。この結果から、CADモデルは教示例の拡張の際になるべく小さな変形を行うと性能が向上するといえる。CADモデルに含まれるナットやねじなどのモデルは丸い形状が重要な特徴であると考えられ、教示例の拡張により形状を変形し過ぎると楕円の形状になってしまう、重要な特徴が失われると推測できる。

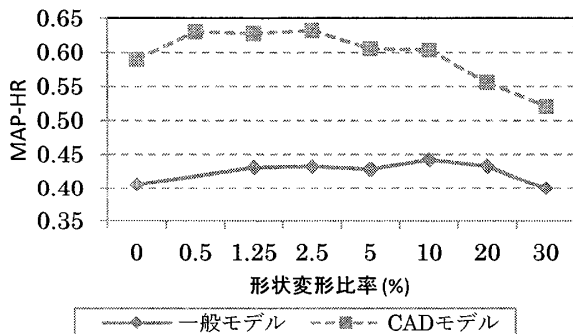


図8. 形状変形比率による検索性能

4.4. 教示例の拡張を用いた学習とコーパスを用いた学習の比較

一般モデルのデータベースには、多量のモデルからなるNTU [21]がある。そこで、本手法により教示例を拡張した場合と実際に多量の教示例(コーパス)を用意して拡張を行わない場合で教師なし学習を行い、検索性能を比較することで提案手法の効果を検証した。コーパスを用いた学習手法として、Ohbuchiらの手法[2]を使用した。なお、Ohbuchiらの手法[2]はSHREC2007 CAD Model Trackで検索性能一位を獲得した。Ohbuchiらの研究によると一般モデルを学習するには5,000個程度が良いということがわかっているため、学習サンプル数を5,000個に設定した。また、実験3の結果を考慮し、教示例の拡張の形状変形比率を10%とした。ちなみに、CADモデルと顔モデルに関しては、データベースが少量でかつ加えることのできるデータベースもないため、コーパスを用いた学習手法を用いることはできない。

実験結果を表1に示す。表1より、教示例の拡張を用いた場合とコーパスを用いた場合の検索性能はほぼ同じであるが、性能指標によっては教示例の拡張を用いた場合の方が約1%高い性能を得た。この理由として、教示例に用いたデータベースの種類の違いが考えられる。実験で用いたコーパスは検

索モデルと少し異なるモデル群であるのに対し、教示例を拡張して得たモデル群は検索モデルと同じ種類のモデル群であるといえそうである。したがって、提案手法のように人工的な教示例拡張を簡単に行うだけでも、コーパスを用意する場合と同等な性能を得ることがわかった。

表1. 教示例の拡張を用いた場合とコーパスを用いた場合の検索性能比較

学習手法	MAP -HR	MAP -R	MNDCG@				
			5	10	25	50	100
コーパスを使用	0.4653	0.4228	0.7026	0.6512	0.6048	0.5846	0.5871
提案手法を使用	0.4713	0.4474	0.6980	0.6666	0.6074	0.5946	0.5999

5. まとめと今後の課題

本論文では、学習サンプルが少ない場合でも学習できるように、学習サンプルを人工的に拡張する手法を提案した。提案手法では、学習サンプルの3次元モデルをわざわざ変形することで学習サンプルを増やす。

3種類の学習データベースについて、教示例の拡張手法を適用した実験の結果、提案手法の有効性は、データベースおよび特徴量に依存することがわかった。

例えば、一般モデルとCADモデルについては、形状特徴量MR_SPRHを用いたときに最も効果が高かった。一方、顔モデルでは、提案手法を適用しても効果はみられなかった。また、一般モデルでは3種類の学習手法すべてについて提案手法の効果があるが、CADモデルでは教師なし(UDR)および教師付き(SDR)の2つの学習手法について提案手法の効果があった。さらに、形状変形比率については、一般モデルはある程度の変形(形状変形比率10%)を行うと良く、CADモデルは小さな変形(形状変形比率0.5%)を行うと良いことがわかった。実験結果より、教示例の拡張の効果は教示例に用いるデータベースの種類によるところが大きいと推測できる。

今後の課題として、形状の変形方法をさらに工夫することが挙げられる。例えば、形状変形法を行う軸を選択する際に重みをつけることや、CADモデルの性質を利用して穴の数を増やしたり直径を変えたりすることが挙げられる。

参考文献

- [1] S.T. Roweis, L.K. Saul, Nonlinear Dimensionality Reduction by Locally Linear Embedding, *Science*, **290**(5500), pp. 2323-2326, (2000).
- [2] Ryutarou Ohbuchi, Jun Kobayashi, Unsupervised Learning from a Corpus for Shape-Based 3D Model Retrieval, *Proc. ACM Multimedia Information Retrieval (MIR) 2006*, Santa Barbara, CA, U.S.A., Oct. 2006.
- [3] Ryutarou Ohbuchi, Jun Kobayashi, Akihiro Yamamoto, and Toshiya Shimizu, Comparison of dimension reduction method for database-adaptive 3D model retrieval, *Proc. Adaptive Multimedia Retrieval (AMR) 2007*, Paris, France, July 2007.
- [4] 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).
- [5] 武井 毅, 大淵 竜太郎, 多重解像度表現を用いたポリゴンスプ3次元モデルの形状類似比較, *画像電子学会誌*, **34**(4), pp. 256-269, 2005年.
- [6] R. C. Velkamp, R. Ruijsenaars, M. Spagnuolo, R. Van Zwol, F. ter Harr, SHREC2006 3D Shape Retrieval Contest, Utrecht University Dept. Information and

Computing Sciences Technical Report UU-CS-2006-030 (ISSN: 0924-3275), 2006.
<http://give-lab.cs.uu.nl/shrec/shrec2006/index.html>

[7] 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).

[8] 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).

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

[10] X. He, W-Y. Ma, H-J. Zhang, Learning an Image Manifold for Retrieval, *Proc. ACM Multimedia 2004*, pp. 17-23 (2004).

[11] 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).

[12] S. Haykin, *Neural network a comprehensive foundation*, Second Edition, Prentice Hall, 842pages, (1999).

[13] R. C. Veltkamp, Frank B. ter Harr, SHREC2007 3D Shape Retrieval Contest, Department of Information and Computing Sciences, Utrecht University, *Technical*

Report UU-CS-2007-015 (ISSN: 0924-3275)
<https://engineering.purdue.edu/PRECISE/shrec/>

[14] Cano, J., Perez-Cortes, J. Arlandis, and R. Llobet. Training Set Expansion in Handwritten Character Recognition. *Proc. 9th SSPR / 4th SPR*, pp. 548-556. (2002)

[15] Benjamin Sapp, Ashutosh Saxena, and Andrew Y. Ng, A Fast Data Collection and Augmentation Procedure for Object Recognition, *AAAI*, (2008).

[16] P. Shilane, P. Min, M. Kazhdan, T. Funkhouser, The Princeton Shape Benchmark, *Proc. SMI '04*, pp. 167-178, 2004.
<http://shpa.cs.Princeton.edu/search.html>

[17] S. Jayanti, Y. Kalyanaraman, N. Iyer and K. Ramani, Developing An Engineering Shape Benchmark For Cad Models, *Computer-Aided Design*, **38**(9) September 2006, pp. 939-953, 2006.
<http://purdue.edu/shapelab>

[18] D. V. Vranic, 3D Model Retrieval, *Ph.D. Thesis*, University of Leipzig, (2004).

[19] D. V. Vranić, 3D Tools,
<http://merkur01.inf.uni-konstanz.de/CCCC/>

[20] H. Edelsbrunner, E. P. Mücke, Three-dimensional Alpha Shapes, *ACM TOG*, **13**(1), pp.43-72, (1994).

[21] NTU 3D Model Database ver.1
<http://3d.csie.ntu.edu.tw/>




図 6. 各学習手法を用いたときの一般モデルにおける各拡張モデル数の検索性能。(a) UDR, (b) SDR, (c) SDDR




図 7. 各学習手法を用いたときの CAD モデルにおける各拡張モデル数の検索性能。(a) UDR, (b) SDR, (c) SDDR