情報処理学会 グラフィクスとＣＡＤ研究会 2002 年 2 月 21 日
情報処理学会研究会報告 Vol. 2002, No. 16, pp.25-30 (2002-CG-106-5)

人間の感性に基づく3 次元モデルの形状類似検索

衣鳩 昌俊[1], 小田切 智[2], 大渕 竜太郎[3]
k7022@kki.yamanashi.ac.jp, k6052@kki.yamanashi.ac.jp, ohbuchi@acm.org
[1] 山梨大学電子情報工学科, [2] 山梨大学大学院工学研究科, [3] 山梨大学コンピュータ・メディア工学科
山梨県甲府市武田 4-3-11

要旨

近年, 様々な分野において3次元モデルが広く使用されるようになった. それに伴い, 3次元モデルを対象とした類似検索の必要性が高まっている. 形状類似検索の研究は幾つか行われているが, これまでの形状類似検索は形状の特徴のみが使用されているものが多く, 検索結果が人間の主観と一致しにくいという問題があった. 本論文では形状特徴に加え, 人間の主観も考慮した類似検索の手法を提案する. 本手法では, SVM(Support Vector Machine)を用いて人間の主観を数値化し, その結果を形状特徴量の比較に反映させることで人間の主観を考慮した検索を行った. 実験の結果, 一般化能力にはまだまだ改良の余地があるものの, 人間の主観をある程度反映させた結果が得られた.

Shape-Similarity Search of Three-Dimensional Models Based on Subjective Measures

[1]Masatoshi Ibato, [2]Tomo Otagiri, [3]Ryutarou Ohbuchi
[1]Department of Electrical Engineering, Yamanashi University, [2]Graduate School of Engineering, Yamanashi University
[3]Department of Computer Science and Media Engineering, Yamanashi University
4-3-11 Kofu, Yamanashi, Japan

Abstract

As popularity of three-dimensional (3D) models increase, interests in shape-similarity search of 3D models have increased. Except for a few, most of the methods for 3D shape similarity search published so far does not consider human subjective measures. In this paper, we propose a new shape-similarity search method that combines a 3D shape feature that is independent of the model pose and size with a learning classifier called Support Vector Machine (SVM). The system is a human-directed query-by-example system. By tagging similar and dissimilar models among the list of current retrieval results, the system learns the model the user desires by using the SVM. Preliminary experimental results shows that, despite its simplicity, the system works well in retrieving shape a user feels “similar” to the examples given.

1 はじめに

近年, コンピュータ技術の発展とともに, 様々な分野(例:ポリゴンゲーム, テレビ・映画でのCG合成, CAD形状)において3次元モデルが広く使用されるようになった. それに伴い, 3次元モデルを対象とした類似検索のための研究が数多くなされている.

3次元モデルを対象とした類似検索の手法にはモデルに付加された名前や注釈を対象としたキーワードによる検索もあるが, 形状そのものによる検索もある[3, 4, 5 ,7]. 形状そのものによる検索の代表的な手法は, 3次元モデルから形状特徴を取り出し, その形状特徴に基づいた検索を行う. 形状特徴にはモデルの幾何情報が使われていること[3, 4, 7]が多いが, 位相を形状特徴とした検索[5]もある.

しかし, 形状特徴のみから計算した類似度を用いた検索手法には2つの問題点があった. まず1つ目は, モデルの位置合わせ(向き, 位置, 大きさなどの幾何変換に対する正規化を行うこと)が必要な点である. 位置合わせは座標値へのノイズや幾何要素の縮退などによって結果が変わってしまうことが多い. そのような場合, 人間が位置を正しく合わせれば高い類似度を示すモデルが低い類似度を示してしまう. 2つ目の問題は人間の主観と検索結果が一致しにくいという点である. 鈴木らの多次元尺度構成法を用いた方法[9, 10, 11]や, EladらのSVM (Support Vector Machine)の分離超平面からの距離を用いる方法[2]など, 人間の主観を考慮した類似検索手法の研究[2, 9, 10, 11]も行われている. だが, これらの研究の幾つか[2, 9, 11]は位置合わせが必要だった. 鈴木らの手法[10]は回転不変な特徴量を用いているが, 形状の詳細まで記述しようとすると組み合わせ爆発が生じ, 限界があった.

ここで我々が着目したのがOsadaらが考案した形状特徴[4]とEladらの手法[2]である. Osadaらの形状特徴は位置合わせを必要とせず, 剛体変換や鏡像変換, 座標値へのノイズ, 幾何要素の縮退に対して頑強である. だが, Osadaらの検索手法では人間の主観は考慮されていなかった. EladらはSVMを用いて形状特徴である慣性モーメントに重み付けを行い, 人間の主観を反映させた. だが, Eladらの手法は位置合わせが必要だった.

そこで本論文では, Osadaらの形状特徴ベクトルと, Eladらの用いたSVMとを組み合わせることで, 位置合わせを必要とせず, 類似検索結果に人間の主観を反映させる手法を提案する. 本手法ではモデルの表面に点を撒き, その中の任意の2点間のユークリッ

ド距離を測定する. この距離の測定を表面上の点全ての組み合わせに対して行い, 距離ヒストグラムを作成し, この距離ヒストグラムを特徴ベクトルとする. この特徴ベクトルはモデルの向きや位置に影響されず, 等方スケーリングの影響も殆ど無い. 類似検索は特徴ベクトルのマンハッタン距離をモデル間で比較することで行う. 検索はマンハッタン距離による初回の検索結果から出発し, ユーザが繰り返し教示例を与えることで行われる. SVMは与えられた教示例を基にマンハッタン距離を修正し, 人間の主観を反映させる.

2 検索システム

本論文の類似検索は, 頂点座標と頂点の接続性から形状が定義される3次元モデルを対象としている. 本手法の概要を図1に示す.

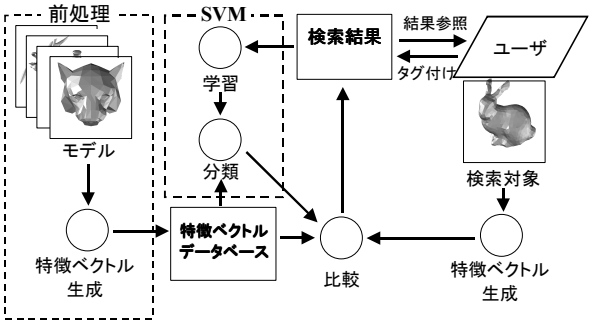

図1.検索手法の概要図

本手法は, 例示された検索対象をもとに検索を行う. まず, ユーザは検索キーとなる検索対象モデルをシステムに例示する. システムは例示された検索モデルから特徴ベクトルを自動的に抽出し, データベース内のモデルの特徴ベクトル(あらかじめ計算され, モデルと共に格納されている)との類似比較を行う. 類似比較の際, SVMで比較結果を修正する. この修正の結果, 類似度の高い幾つかのモデルを似ているモデルとしてユーザに提示する. ユーザは検索結果に対して自らの主観を反映させたタグを付与し, SVMに与える. SVMは与えられたデータを基に学習を行い, 以降の検索に学習結果を反映させる. このようにSVMに繰り返し学習させることで, 求める形状の3次元モデルを検索する.

2.1 特徴ベクトルの作成

今回, 我々が使用した形状特徴はOsadaらがD2と呼んだものである. D2は3次元モデルの面上に(準)ランダムに点を生成し, その点の中からランダムに選ばれた2点間の距離のヒストグラムを特徴ベクトルとする[4]. ある三角形上に点 $\mathbf{P}$ を生成するにはモデルの頂点の接続性より構成される三角形の頂点座標 $\mathbf{A}$, $\mathbf{B}$, $\mathbf{C}$ から式(1)を用いて行う(図2).

$$\mathbf{P} = (1-\sqrt{r_1})\mathbf{A} + \sqrt{r_1}(1-r_2)\mathbf{B} + \sqrt{r_1}(r_2\mathbf{C}) \quad (1)$$

(r_1, r_2 :0から1までの値をとりうる準乱数)

生成された点の中から任意に2点 $\mathbf{P}_1, \mathbf{P}_2$ を選び式(2)により距離を求める.

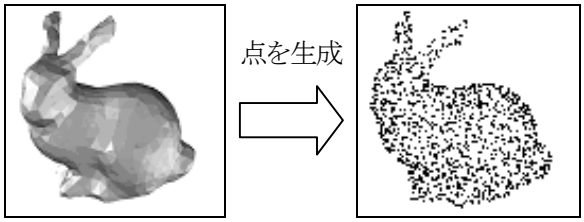

図2. モデルの表面上に点を生成

$$D2(\mathbf{P}_1, \mathbf{P}_2) = \sqrt{|\mathbf{P}_1 - \mathbf{P}_2|^2} \quad (2)$$

生成された点全ての組み合わせ(点の総数が N のとき, 組み合わせの総数は $N(N-1)/2$ となる)に対してD2を適用することで, 1次元の数値群を生成する.

生成された数値群を基にして距離ヒストグラムを生成するには, まず, 数値群の最小値, 最大値, 及び平均値を測定する. 次にヒストグラムの区間数Nを決定し, 平均値から最小値, 平均値から最大値の区間をそれぞれ $N/2$ に分割する. 最後に数値群が各区間において占める割合を各区間の値とすることで, N 本からなるヒストグラムを生成できる(図3).

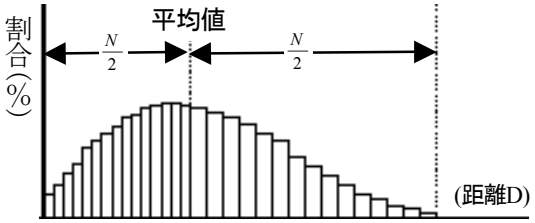

図3. 距離ヒストグラムのイメージ図

各モデルを同一区間数のヒストグラムで表すことにより, 剛体変換に対して頑強性をもたせることができる. 区間数512のヒストグラムの例を図4に示す.

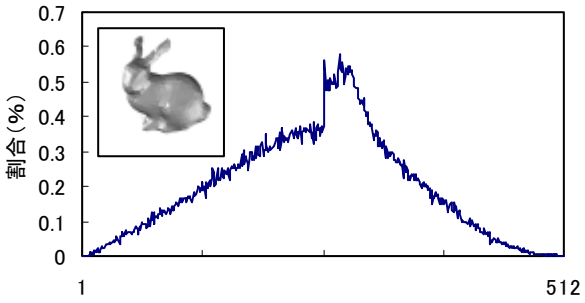

図4. Bunnyのヒストグラム(区間数512)

2.2 SVM による分類

2.2.1 SVM(Support Vector Machine)

SVM(Support Vector Machine)はパターン認識のための学習型アルゴリズムである[12, 13, 14, 15, 16, 17]. 学習パターンとして n 個のベクトル $\mathbf{x}_i (i = 1,...,n)$ が与えられたとき, それらを正例と負例に分け, 正負例間の距離 $\boldsymbol{\omega}$ が最大になるような超平

面を最適解として求める．この距離 $\boldsymbol{\omega}$ の最大化がSVMの大きな特徴である．学習パターンが線形分離可能な場合，正負例間の距離 $\boldsymbol{\omega}$ が最大になる識別関数は式(3)を用いて表せる．

$$f(\mathbf{x}) \equiv sign(g(\mathbf{x})) = sign(\boldsymbol{\omega} \cdot \mathbf{x} + \mathrm{b}) \tag{3}$$

ここで n 個の学習パターン $\mathbf{x}_i$ が満たすべき条件を式(4)とする．これは平面 $g(\mathbf{x}) = \pm 1$ の間に学習パターンが存在しないことを示している．

$$\forall i, g(\mathbf{x}) = \boldsymbol{\omega}\mathbf{x}_i + b \begin{cases} \geq +1 & \mathbf{x}_i \in \text{正例} \\ \leq -1 & \mathbf{x}_i \in \text{負例} \end{cases} \tag{4}$$

$\mathbf{x}_i$ が正例と負例のどちらに属すかを変数 y_i (式(5))を用いて示すと式(4)は式(6)のように表せる．

$$y_i = \begin{cases} +1 & \mathbf{x}_i \in \text{正例} \\ -1 & \mathbf{x}_i \in \text{負例} \end{cases} \tag{5}$$

$$\forall i, y_i \cdot (\boldsymbol{\omega} \cdot \mathbf{x}_i + b) - 1 \geq 0, i = 1, ..., n \tag{6}$$

この式(6)を満たす $\boldsymbol{\omega}, b$ のうちで，

$$\phi(\boldsymbol{\omega}) = \left\| \boldsymbol{\omega}^2 \right\| \tag{7}$$

を最小にするものが分離超平面と呼ばれる最適解である．この最小化問題には様々な解法(Lagrange未定乗数法，共役勾配法など)が存在する．

学習パターンの線形分離が不可能な場合には、スカラーを出力する非線形関数 $\phi_i(\mathbf{x})(i = 1, ..., d)$ を

$$\phi(\mathbf{x}) = (\phi_1(\mathbf{x}), \phi_2(\mathbf{x}), ..., \phi_i(\mathbf{x}))' \tag{8}$$

と定義する．この $\phi(\mathbf{x})$ を用いて $\mathbf{x}$ 入力ベクトルを変換し，変換後の空間で線形識別をする．$\phi(\mathbf{x})$ 空間で得られた分離超平面は変換前の $\mathbf{x}$ 空間において非線形な分離面をなす．そのため，線形分離不可能な学習パターンを非線形分離することが可能となる．

しかし $\mathbf{x}$ はベクトルであるため，ϕ によって表される空間の次数が大きくなり，計算が複雑になりがちである．この問題はカーネル関数を用いてベクトルの内積を置換することで解決することができる．カーネル関数には多くの種類があるが，本手法では $p = 2$ 多項式型カーネル(式(9))を使用した．

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j + 1)^p \tag{9}$$

また，SVMはsoft margin hyper planeを用いて汎化能力を得ている．Soft margin hyper planeはパラメータを操作することで，その汎化能力を操作することができる(詳しくは[13]を参照)．

2.2.2 SVM の適用

本手法では，SVMに与える特徴ベクトルとして2.1節で作成した距離ヒストグラムを使用している．教示例には，各モデルに人間が主観に基づいて検索対象との類似度を判定した結果のタグ(+1：似ている，-1：似ていない)を付与する．

SVMを類似度の順序付けに使用する場合，分離超平面からの距離により分類をする方法が一般的である．分離超平面からの距離による分類はEladらが行っている[2]が，本手法ではモデル比較の際，SVMでモデルを分類した結果を用いてマンハッタン距離の修正を行った．このSVMの使用法は本手法独自のものである．

モデルの比較は，各モデルごとに作成した距離ヒストグラムを比較することで行う．比較にはマンハッタン距離を使用し，更にSVMの分類結果を用い距離の修正を行った．$\mathbf{x}$，$\mathbf{y}$ を任意のモデルの距離ヒストグラムとすると，その距離は式(10)により求められる．

今回の実験ではSVMの分類結果が似ている(+1)場合は $\alpha = 0.5$，似ていない(-1)場合は $\alpha = 2.5$ となるようにした．この距離Dの値が小さいほど類似度が高いモデル，すなわち似ているモデルである．

$$D(\mathbf{x}, \mathbf{y}) = \alpha \cdot \sum_{i=1}^{N} |x_i - y_i| \tag{10}$$

(N :ヒストグラム区間数)

3 実験と評価

SVMは Joachims らのアルゴリズムSVM$^{\text{Light}}$ [6]をRupingらがC++で実装したmySVM(http://www-ai.cs.uni-dortmund.de/SOFTWARE/MYSVM/) [16] を用いて実装した．検索システムは3次元三角メッシュモデルを対象としており，gmtoolsを基盤としてC++で実装した．実験には，VRML (Virtual Reality Modeling Language)モデル269個からなるデータベースを用いた．

3.1 最適な組み合わせ

SVMを用いた実験を行う前に，距離ヒストグラムのマンハッタン距離のみを用いたときの性能比較を行った．条件は9通り(区間数128，256，512，表面上に生成する点の総数256，512，1024)である．各条件での識別能力は以下のようにして求めた[4]．

1) 検索対象となるモデルを決定．
2) 検索対象と269個のモデルそれぞれを比較．
3) 検索結果から類似度が高い順に(k-1)個のモデルを抜き出す．ここでkとは検索対象が属するカテゴリ内のモデル数をあらわす．
4) 検索対象と同じカテゴリに属するモデルが3)で抜き出したモデル中に存在する割合を測定．この割合を識別能力とする．

検索対象として，ウサギ(10モデル)，飛行機(11モデル)の計21モデルを使用し，それぞれのモデルに対する識別能力の平均値を総合的な識別能力とした．各条件下の識別能力を表1に示す．

表 1．各条件下の識別能力

区間＼点	256	512	1024
128	40.6%	51.1%	45.6%
256	39.4%	51.7%	45.6%
512	42.2%	**52.8%**	46.7%

表1の結果から，区間数512，生成する点の総数512の場合に識別能力が最も高い．これは生成する点の数が256ではモデルの幾何形状を捉えるためには不足しており，1024では微細な部分まで捉えてしまい，微細な相違までも結果に反映されてしまうからだと推測できる．これ以後の実験では区間数512，生成する点の総数512でヒストグラムを作成する．

3.2 学習の効果

この実験では，図5のモデルを使用して「いわゆる」飛行機に似た形状のモデルを検索する．SVMを使用した場合と使用しなかった場合，及びSVMの学習過程における検索結果の相違を測定した．実験の手順は以下に示す．

1) 検索対象となるモデルを決定．
2) 検索対象と269個のモデルそれぞれを比較．
3) 類似度が高い上位15モデル(検索対象モデルを含む)を選出．
4) 3)のモデルからSVMの学習データを作成．
5) 2),3),4)の作業を2度繰り返す．

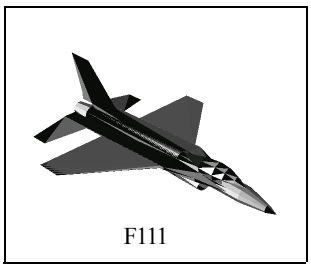

図5．検索対象モデル

まず，SVMを使用せずに図5のモデルと各モデル間の距離ヒストグラムの比較のみを行った．その結果が図8である．モデル左下側の数字は各順位を示し，各順位の右の「( )」はそのモデルにあたえられているインデックスを示している．以後，各モデルはインデックスを用いて表される．また，各モデル右上の「＋」「－」はそのモデルを学習データとしてSVMにあたえる際に付与されたタグを示しており，「( )」の付いているものは既にSVMの学習データとして選出されていることを示している．

図8の中で検索対象と{54，197，198，241，189，254}を似ているモデル(+1)，{200，265，175，46，220，131，177，178}を似ていない(-1)として学習モデルを生成し，SVMに学習を行わせた．その結果をマンハッタン距離に反映させたものが図9である．

その後，図9の中でも学習モデルとして使用されていないモデルを対象として，新たに学習モデルを生成した．今回は{52，224}を似ているモデル，{151，150，95，204，85，97}を似ていないモデルとした．これで，先ほどの学習モデルと合わせて23個の学習モデルを使用して学習したことになる．その結果をマンハッタン距離に反映させると図10のようになった．

実験で使用したデータベース中には，検索対象モデル以外に飛行機のモデルが10個存在する．そのうちの8個が類似度が高いモデル(1位～8位)として選出された．ここで，{52，224}が最終的には15位以内にまで上昇したのが注目すべき点である．これらのモデルはマンハッタン距離のみによる検索時(図7)には15位以内に存在しなかった．だが，1度学習データを作成し，SVMによってマンハッタン距離に修正を加えた結果，15位以内に順位が上昇した．また，最終的な結果として，人間が見て検索対象と似ているモデル(タグとして+1を付与したモデル)が1位から8位を占めている．このことから，SVMによる学習及び，SVMの分類結果による距離の修正が有効に働いており，人間の主観を反映できたと言える．

だが，「いわゆる」飛行機のカテゴリに属している図6の2つのモデルが15位以内に無かった．これは，上位15モデルから学習データを選出する方法に原因がある．本来は似ているはずなのに似ていないと分類され，低い類似度を示したモデルを似ているモデル(+1)としてSVMにあたえるのは難しいためだと考えられる．

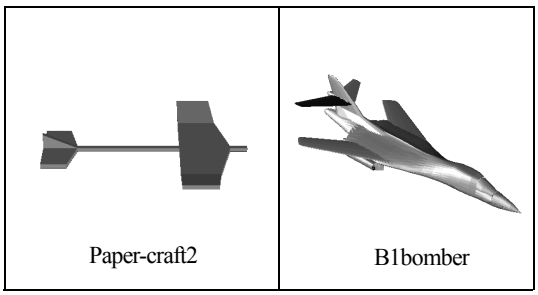

図6．上位15位に無かったモデル

3.3 検索システムの一般化能力

このようなシステムでは，教示例だけを正しく認識しても意味が無く，教示例には含まれず且つ似ているモデルを取り出す「一般化」の能力が求められる．

ここでは，SVMにあらかじめ学習データを与え，学習データの基になったモデルを含まないデータベース内の検索を行うことで，本手法の一般化能力の測定を行った．まず，「いわゆる」ウサギに似た形状のモデルを検索するための学習データをあらかじめ15個作成した(図12)．次に図7を検索対象モデルとして検索を行った．その結果が図12である．

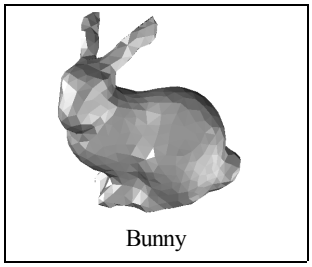

図7．検索対象モデル

実験で使用したデータベース中には，検索対象

モデル以外にウサギのモデルが5個存在する. そのうちの4個が類似度が高いモデル(15位以内)として選出されている. 残る1つのモデルが15位以内に存在しなかった理由としては, ウサギ以外のモデルをウサギとして分類してしまったことが挙げられる.

これにはいくつかの原因が考えられる. 1つ目は不適当なカーネルやパラメタ値を使用してしまっている可能性である. 旧来のニューラルネットワークではその構成により識別能力が大きく影響される. SVMは旧来のニューラルネットワークに比べ, 構成を意識しなくて良いなどはるかに使いやすいが, カーネルの種類やそのパラメタ(例えば多項式カーネルの次元), 誤認識と一般化能力のトレードオフをするパラメタ, など, いくつか調整すべき点がある. 最適なカーネルやパラメタ値を見つけると能力が向上する可能性がある. 2つ目はD2関数の特性である. D2関数, 及びD2関数から作成される距離ヒストグラムは, 3次元モデルを素早く大まかに分類することを目的としている[4]. そのため, 3次元モデルの形状特徴を細部まで捉えることは難しく, それが検索結果やSVMの学習に影響を及ぼしたと推測される. これはD2に基づく特徴ベクトル以外の特徴ベクトルを考案することで改善が可能である.

4 まとめと今後の課題

本論文では, 人間の感性に基づく3次元モデルの類似検索手法を提案した. モデルの面上に生成した点から, 2点間のユークリッド距離を計測し, それを元にヒストグラムを生成する. 次に各モデルの距離ヒストグラム間でマンハッタン距離を計測する. その距離にSVMを用いた修正を加え比較することで人間の主観に基づく類似検索を行った. 実験結果からSVMに適切な学習データを与えることで, 人間の主観に近い検索結果が得られることが分かった.

また, 本論文の実験では類似度の高い上位15モデル内から学習データを選出している. この方法では類似度の低いモデルを学習モデルとしないため, SVMの学習効率を低下させている可能性がある. これは学習データの選出法を変えることにより, 改善が可能であると考えられる.

今後の課題としては, 学習データのより良い選出方法の考案, より一般的な手法を用いたSVMの使用(例:分離超平面からの距離に基づく検索)の実現などが挙げられる. また, D2に基づく特徴ベクトル以外の特徴ベクトルを考案し, 類似検索の識別能力の向上とSVMの学習効率の向上を検討していく.

5 謝辞

本論文の実験を行う上で, 類似検索システムの基盤となったgmtoolsを提供していただいた東京大学の高橋 成雄 助教授に感謝する.

6 参考文献

[1] C. Burges, A Tutorial on Support Vector Machines for Pattern Recognision, *Data Mining and Knowledge Discovery*, **2**, pp. 1-47, 1998.

[2] M. Elad, A. Tal, S. Ar. Directed Search in A 3D Objects Database Using SVM, *HP Laboratories Israel Technical Report*, HPL-2000-20(R.1), August, 2000.

[3] M. Novotni, R. Klein. A Geometric Approach to 3D Object Comparison. Proc. *Int'l Conf. on Shape Modeling and Applications 2001*, pp. 167-175, Genova, Italy, May, 2001.

[4] R. Osada, T. Funkhouser, B. Chazelle, D. Dobkin. Matching 3D Models with Shape Distributions. Proc. *Int'l Conf. on Shape Modeling and Applications 2001*, pp. 154-166, Genova, Italy, May, 2001.

[5] M. Hilaga, Y. Shinagawa, T. Kohmura, and T. Kunii. Topology Matching for Fully Automatic Similarity Estimation of 3D Shapes. *Proc. SIGGRAPH 2001*, pp. 203-212, Los Angeles, USA. 2001.

[6] T. Joachims, Making Large Scale SVM Learning Practical, in *Advances in Kernel Methods - Support Vector Learning*, B. Schölkopf, et al. Eds., MIT Press, 1999.

[7] E. Paquet and M. Rioux, "Nefertiti: a Query by Content Software for Three-Dimensional Databases Management", Proc. *Int'l Conf. on Recent Advances in 3-D Digital Imaging and Modeling*, pp. 345-352, Ottawa, Canada, May 12-15, 1997.

[8] E. Paquet, A. Murching, T. Naveen, A. Tabatabai, M. Roux. Description of shape information for 2-D and 3-D objects. *Signal Processing: Image Communication*, 16:103-122, 2000.

[9] M. T. Suzuki, T. Kato, H. Tsukune. 3D Object Retrieval based on subject measures, Proc. *9th Int'l Conf. and Workshop on Database and Expert Systems Applications (DEXA98)*, pp. 850-856, IEEE-PR08353, Vienna, Austria, Aug. 1998.

[10] M. T. Suzuki, T. Kato, N. Otsu. A similarity retrieval of 3D polygonal models using rotation invariant shape descriptors. *IEEE Int. Conf. on Systems, Man, and Cybernetics (SMC2000)*, Nashville, Tennessee, pp. 2946-2952, 2000.

[11] 鈴木一史, 加藤俊一, 築根秀男. 主観的類似度を反映した 3 次元多面体の検索. 第 3 回知能情報メディアシンポジュウム, pp.9-16, Dec. 1997.

[12] V. N. Vapnik. *Statistical Learning Theory*. Wiley, 1998.

[13] V. N. Vapnik. *The Nature of Statistical Learning Theory, Second Edition*. Springer, 1999.

[14] R. C. Veltkamp. Shape Matching: Similarity Measures and Algorithms, invited talk, Proc. *Int'l Conf. on Shape Modeling and Applications 2001*, pp. 188-197, Genova, Italy, May, 2001.

[15] D. V. Vranić, D. Saupe, and J. Richter. Tools for 3D-object retrieval: Karhunen-Loeve Transform and spherical harmonics. Proc. of the *IEEE 2001 Workshop Multimedia Signal Processing*, Cannes, France, pp. 293-298, October 2001.

[16] S.Ruping. mySVM-Manual. http://www-ai.cs.uni-dortmund.de/SOFTWARE/MYSVM/. October 2000.

[17] 前田英作, 痛快！サポートベクトルマシン, 情報処理 2001 年 7 月号 pp.676-683, 2001 年 7 月.

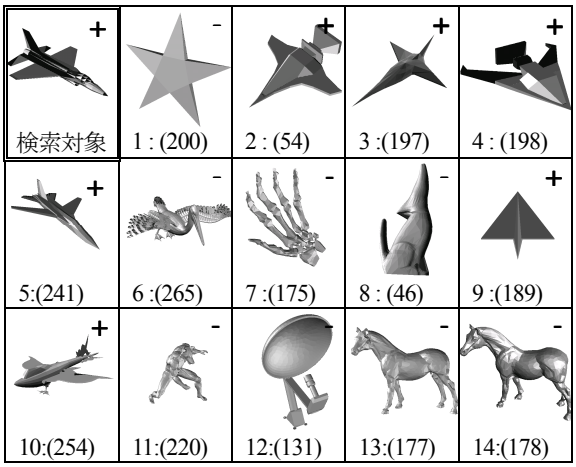

図8. マンハッタン距離のみによる比較結果

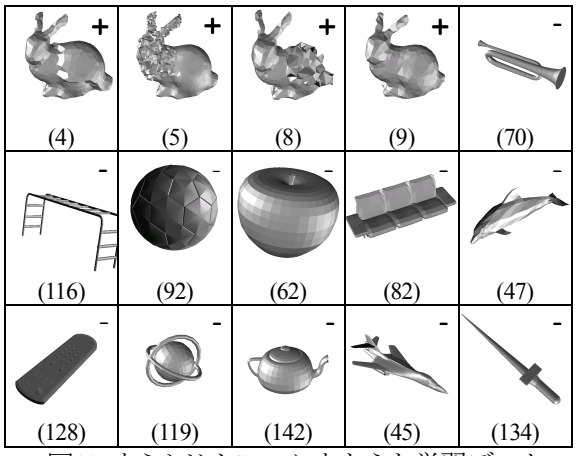

図11. あらかじめSVMにあたえた学習データ

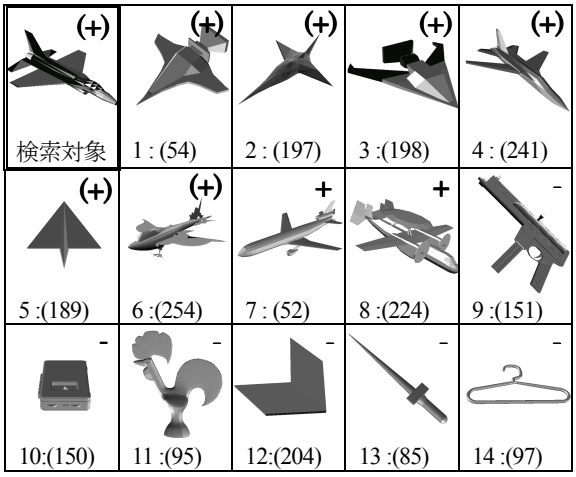

図9. SVMによる学習を反映させた結果1

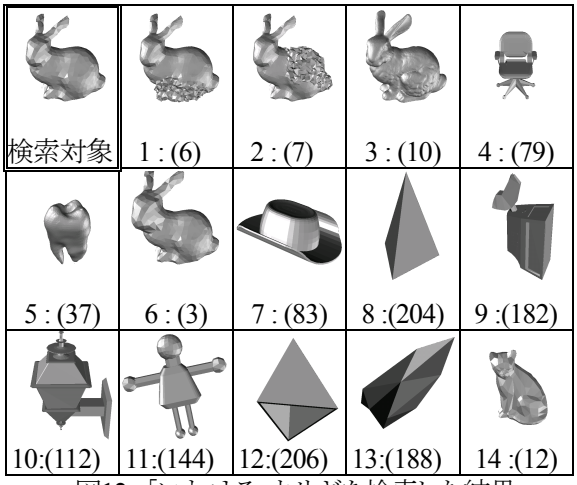

図12.「いわゆる」ウサギを検索した結果

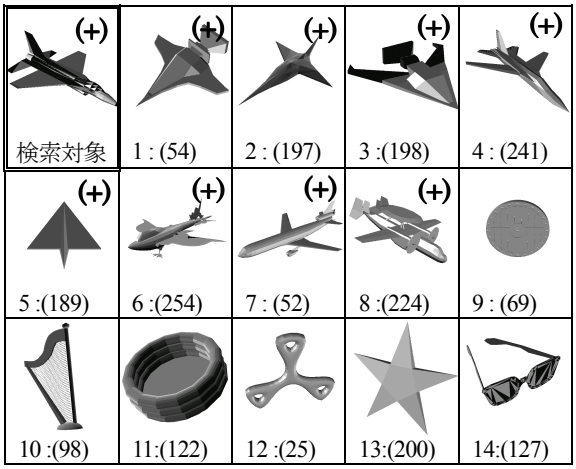

図10. SVMによる学習を反映させた結果2