

## 学習により人の主観を反映する 3 次元モデルの形状類似検索\*

小田切 智<sup>1</sup>, 衣嶋 昌俊<sup>2</sup>, 大淵 竜太郎<sup>3</sup>

k6052@kki.yamanashi.ac.jp, zaq54940@cat.zero.ad.jp, f8058@kki.yamanashi.ac.jp, ohbuchi@acm.org

<sup>1</sup>山梨大学大学院工学研究科, <sup>2</sup>茨城計算センター株式会社, <sup>3</sup>山梨大学工学部コンピュータ・メディア工学科  
山梨県甲府市武田 4-3-11

### 1. はじめに

近年, コンピュータ技術の発展とともに 3 次元グラフィクスや 3 次元形状 CAD が広く普及し, 3 次元モデルの数は増加している(例: ゲーム, テレビ・映画での CG 合成, CAD 形状). それにともない, 3 次元モデルを対象とした類似検索が注目されつつある. 類似検索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. [Paquet97, 鈴木 97, Suzuki98, Keim99, Elad00, Suzuki00, Hilaga01, Novotni01, Osada01, Vranić01, 衣嶋 02, 小田切 02]. 形状そのものに基づく類似検索の代表的な手法は, (1) 3 次元モデルからコンパクトでかつ記述力のある形状特徴を抽出する, (2) その形状特徴に基づいてモデル間の相違度(あるいは距離)を計算する, (3) 相違度に基づいて 3 次元モデルの検索・取り出しを行う, の 3 つのステップからなる.

既存の形状特徴としては, モデルの幾何情報を主としたものが多い [Paquet97, 鈴木 97, Suzuki98, Elad00, Suzuki00, Novotni01, Osada01, Vranić01, 衣嶋 02, 小田切 02] が, 最近, 位相を形状特徴とした検索手法も発表された [Hilaga01]. モデル間の相違度を計算するのに用いる距離尺度としては Euclid 距離, Manhattan 距離, Hausdorff 距離, 等数多くの距離尺度がある [Veltkamp01].

相違度に基づき検索を行う際に問題となるのが, 人の主観的相違度の判断と, 「機械的に」計算したモデル間の相違度が一致しない場合が多いことである. つまり, 人が似ていると感じるモデル間でも, 相違度が高くなる場合がある. 形状類似検索において先駆的な研究の 1 つである鈴木らの研究 [鈴木 97, Suzuki98, Suzuki00] では, 多次元尺度法を用い, 人の主観と検索される形状の一致を試みた. また, 最近では, Elad らの研究 [Elad00] や衣嶋らの研究 [衣嶋 02] のように学習型の類似アルゴリズムを用い, 反復して正しい検索例と正しくない検索例とを教示することで, 漸的に求めるモ

デル(群)を検索しようとするものもある.

本論文では, 先行研究である [衣嶋 02, 小田切 02] を元に, 人の主観を反映する 3 次元モデルの形状類似検索手法を提案し, 評価を行う. 衣嶋ら [衣嶋 02] の研究では, Osada ら [Osada01] の特徴量を用い, 学習型の類似アルゴリズムを組み合わせることで漸的に求めるモデル(群)を検索しようとした. 小田切ら [小田切 02] の研究では, 慣性主軸方向に 1 次元にパラメタ化された 3 つの量の特徴量として類似検索を行った. そこで, 小田切ら [小田切 02] らの特徴量を用い, これを学習型の類似アルゴリズム [衣嶋 02] と組み合わせた類似検索手法を提案する.

### 2. 検索システムの概要

本論文の類似検索手法は, 頂点座標と頂点の接続性から形状が定義される 3 次元ポリゴンメッシュを対象とし, 例示された見本モデルと類似した形のモデルを取り出す. 本手法の特徴の 1 つは, 人の主観を検索結果に反映させるため, 学習型アルゴリズムであるサポートベクタマシン(SVM)を用いることである.

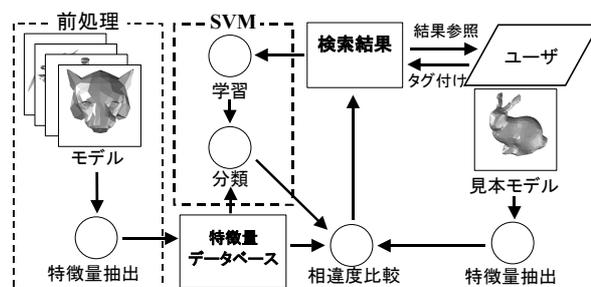


図 1: 検索システムの概要

まず, システムに見本モデルを提示すると, システムはそのモデルの特徴量を計算し, データベース内のモデルの特徴量(あらかじめ特徴量を計算しモデルと共に格納)と相違度比較を行い, 相違度の最も低い k 個のモデルを第 1 次候補として選出する. 特徴量は (1) モデルの面上に質量が分布すると仮定した慣性モーメント, (2) 主軸からの距離の平均, (3) 主軸からの距離の分散, の 3 つの数値をモデルの 3 つの主軸にそった距離でパラメタ化したものである.

人の主観を検索結果に反映させるために, ユーザがシステムに対し反復して「欲しいモデル・欲しくないモデル」を教示し, 学習型類似アルゴリズムに学習させる.

\*A Learning-Based Approach to Shape-Similarity Search of 3D Models

<sup>1</sup>Tomo Otagiri, <sup>1</sup>Tsuyoshi Takei, <sup>2</sup>Masatoshi Ibatto,

<sup>3</sup>Ryutarou Ohbuchi

<sup>1</sup>Graduate School of Engineering, Yamanashi University.

<sup>2</sup>Ibaraki Computing Center, Incorporated.

<sup>3</sup>Department of Computer Science and Media Engineering, Yamanashi University.

システムはまず, 主観を反映しない(つまり, 「機械的に」に求められた)第 1 回目の検索結果を第 1 次候補群としてユーザに提示する. ユーザはその候補の中で見本モデルに似たモデルに“+1”の, 似ていないモデルに“-1”のタグをつける. SVM はこれらのタグを元に学習を行い, 1 回目の学習を反映した第 2 次の候補を提示する. この操作を数回繰り返すことで, 提示された候補群は徐々にユーザの主観を反映するようになる.

## 2.1. 特徴量の抽出

本手法で用いる特徴量は, (1) モデルの位置と向きの正規化, (2) 数値包絡線の計算, の 2 ステップで求める. 位置と向きの正規化は, モデル面上に一樣に分布する質量をモンテカルロ法的に近似し, その慣性主軸を計算して行う. 具体的には, ポリゴンを 3 角形分割し, 各 3 角形ごとにその面積に比例した数の同一質量の質点を一樣に生成し, これから慣性主軸を求める. 点の生成には準乱数 Sobol [William92]を用い, 結果の分散が小さくなるようにした. 頂点を質点として慣性主軸を計算する Gottschalk らの向き合わせ手法 [Gottschalk96]と比べ, 形状の多面体分割に影響されにくい.

次に, 向き合わせに用いられた各主軸回りで, 主軸に沿ってパラメタ化された数値の包絡線を求める. 前述のように, 慣性モーメント, 主軸からの距離の平均, 主軸からの距離の分散, の 3 つを数値として用いた.

### 2.1.1. 主軸計算

3 次元モデルから特徴量を抽出する前処理として慣性主軸を計算し, モデルの位置と向きの正規化を行う. モデルの頂点を質点と考え慣性主軸を求めると, 頂点に偏りのあるモデルや, 頂点数の少ないモデルでは主軸の向きが上手く決まらない. そこで, 我々は(頂点に質点があると考えてだけでなく)面に質量があると考えて慣性主軸を求め, モデルの向きを決める. 具体的には, モデルの各面上に一樣に点を生成し, 生成した点群から共分散行列  $C$  を求める.

$$C = (c_{pq}) = \frac{1}{n} \sum_{i=1}^n (p_i - p_M)(q_i - q_M) \quad (1)$$

ただし,  $p, q \in \{x, y, z\}$  である.

共分散行列  $C$  の固有ベクトルをモデルの主軸とする. このとき固有値の大きい順に  $\alpha$  軸,  $\beta$  軸,  $\gamma$  軸とする. 主軸だけでは鏡像の区別が出来ないので,  $\alpha$  軸,  $\beta$  軸,  $\gamma$  軸についての重心からの点の距離により右手系に定める.

面上に一樣な点  $P$  を生成させるには, モデルの頂点の接続性より構成される三角形の 3 頂点の座標  $t_1, t_2, t_3$  より次式で求める[Osada01].

$$P = (1 - \sqrt{r_1})t_1 + \sqrt{r_1}(1 - r_2)t_2 + \sqrt{r_1}(r_2 \cdot t_3) \quad (2)$$

Osadaらは(2)式の2つの数  $r_1, r_2$  には疑似乱数を使用しているが, 我々は準乱数を使用した. 疑似乱数を使ってみたところ, 図 2 の示すように主軸計算に若干の誤差が見られた(ここで言う誤差とは, 主軸計算後の 3 つの主軸( $\alpha$  軸,  $\beta$  軸,  $\gamma$  軸)の角度差(単位は度)を平均したものである. 実験は 10 回行い, その平均を結果として示す). そこで, モンテカルロ法で用いられる準乱数のひとつである Sobol [William92]を用いることにした. これにより 3 次元モデルの面上に一樣に点を生成でき, かつ安定した計算結果が得られる.

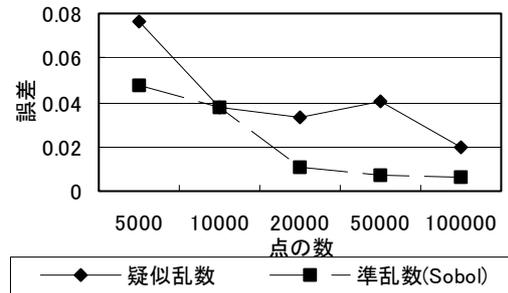


図 2: 主軸計算の誤差の平均値

### 2.1.2. 特徴ベクトルの抽出

位置と向き合わせを行ったのちにモデルの特徴量を求める. 本手法で用いる特徴量は, 小田切らを用いた包絡線ベクトル[小田切 02]である. 包絡線ベクトルは (1)モデルの表面に質量が分布していると仮定した慣性モーメント, (2)主軸からの距離の平均, (3)主軸からの距離の分散, の 3 つの数値をモデルの 3 つの主軸にそった距離でパラメタ化したものである.

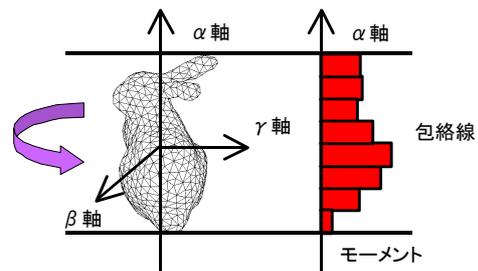


図 3:  $\alpha$  軸周りでの包絡線ベクトルのイメージ

包絡線ベクトルは以下のステップで求める.

- 1) モデルを, 主軸に対して垂直な平面で  $l$  個の小区間に分割し, 隣り合う 2 つの小区間を 1 つの区間とする. このとき, 隣り合う区間は, 1 小区間分オーバーラップする(したがって区間数は  $l-1$  となる).
- 2) 2.1.1 節の主軸計算で生成した各点を質点とし, 各区間ごとに各数値(慣性モーメントの合計, 距離の平均, 距離の分散)を計算する.
- 3) 包絡線ベクトルの大きさが 1 になるように正規化を

行う。

1)~3)の処理を $\alpha, \beta, \gamma$ の各主軸について行い, それぞれの主軸にそった包絡線ベクトルを求める. 各包絡線を抽出する際, 各区間をオーバーラップさせる. 各包絡線ベクトルの例を図4, 図5に示す.

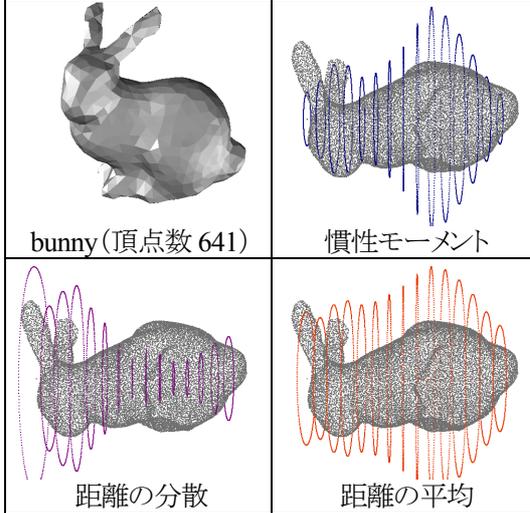


図4: bunny モデルの包絡線ベクトル( $\alpha$  軸周りに, 区間数 15)

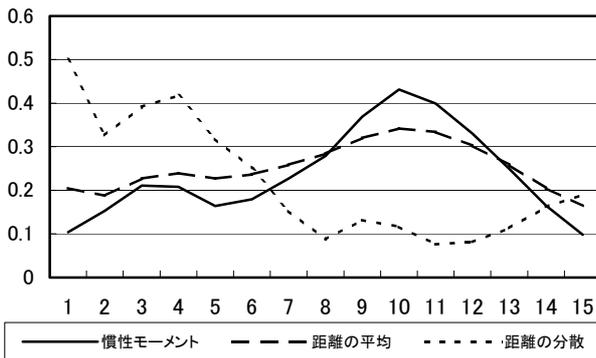


図5: bunny の包絡線ベクトル( $\alpha$  軸周りに, 区間数 15)

慣性モーメントの包絡線ベクトルを $\mathbf{m}_\alpha, \mathbf{m}_\beta, \mathbf{m}_\gamma$  ( $\alpha, \beta, \gamma$  は直交する慣性主軸( $\alpha$  軸,  $\beta$  軸,  $\gamma$  軸)を示す), 平均距離の包絡線ベクトルを $\mathbf{a}_\alpha, \mathbf{a}_\beta, \mathbf{a}_\gamma$  とし, 分散の包絡線ベクトルを $\mathbf{d}_\alpha, \mathbf{d}_\beta, \mathbf{d}_\gamma$  とする. 3次元モデル  $M$  の形状特徴を $\mathbf{F}$  とすると, 式(3)となる.

$$\mathbf{F} = \begin{pmatrix} \mathbf{F}_p \end{pmatrix} = \begin{pmatrix} \mathbf{m}_p \\ \mathbf{a}_p \\ \mathbf{d}_p \end{pmatrix} = \begin{pmatrix} m_{p,1}, m_{p,2}, \dots, m_{p,n} \\ a_{p,1}, a_{p,2}, \dots, a_{p,n} \\ d_{p,1}, d_{p,2}, \dots, d_{p,n} \end{pmatrix} \quad (3)$$

ただし,  $p \in \{\alpha, \beta, \gamma\}$ ,  $m_{p,i}$  はベクトル  $\mathbf{m}_p$  の  $i$  番目の要素である. また,

$$\mathbf{F}_{p,q} = \begin{pmatrix} m_{p,q} \\ a_{p,q} \\ d_{p,q} \end{pmatrix} \quad (4)$$

ただし,  $q=1,2,\dots,n$  で,  $n$  は包絡線の区間数である. 各包絡線の要素である慣性モーメント  $m_{p,i}$ , 距離の

平均  $a_{p,i}$ , 距離の分散  $d_{p,i}$  は以下の式で計算される.

$$m_{p,i} = \sum_{j=1}^n m r_j^2 \quad (5)$$

$$a_{p,i} = \frac{1}{n} \sum_{j=1}^n r_j \quad (6)$$

$$d_{p,i} = \frac{1}{n-1} \sum_{j=1}^n (r_j - a_{p,i})^2 \quad (7)$$

ただし,  $m$  は点の質量,  $r$  は主軸から点までの距離である.

## 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の類別アルゴリズムである [Vanik98, Vapnik99, Ruping00, 前田 01]. 学習パターンとして  $n$  個のベクトル  $\mathbf{x}_i (i=1,2,\dots,n)$  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  $\omega$  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  $\omega$  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  $\omega$  が最大になる識別関数は式(8)を用いて表せる.

$$f(\mathbf{x}) = \text{sign}(g(\mathbf{x})) = \text{sign}(\omega \cdot \mathbf{x} + b) \quad (8)$$

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(9)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.

$$\forall i, g(\mathbf{x}) = \omega \mathbf{x}_i + b \begin{cases} \geq +1 & \mathbf{x}_i \in \text{正例} \\ \leq -1 & \mathbf{x}_i \in \text{負例} \end{cases} \quad (9)$$

$\mathbf{x}_i$  が正例と負例のどちらに属するかを変数  $y_i$  (式(10))を用いて示すと式(9)は式(11)のように表せる.

$$y_i = \begin{cases} +1 & \mathbf{x}_i \in \text{正例} \\ -1 & \mathbf{x}_i \in \text{負例} \end{cases} \quad (10)$$

$$\forall i, y_i \cdot (\omega \cdot \mathbf{x}_i + b) - 1 \geq 0, \quad i=1,2,\dots,n \quad (11)$$

この式(11)を満たす  $\omega, b$  のうちで,

$$\phi(\omega) = \|\omega\|^2 \quad (12)$$

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  $\phi_i(\mathbf{x}) (i=1,2,\dots,d)$  を

$$\phi(\mathbf{x}) = (\phi_1(\mathbf{x}), \phi_2(\mathbf{x}), \dots, \phi_i(\mathbf{x}))^i \quad (13)$$

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,  $\phi$  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(14))を使用した.

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j + 1)^p \quad (14)$$

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[Vapnik99]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小田切らの包絡線ベクトル[小田切02]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[Elad00]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相違度の修正を行う.

モデル間の相違度は, 各モデルごとに作成した包絡線ベクトルを比較することで求める. 比較には Euclid 距離を使用し, 更に SVM の分類結果をもとに相違度に修正を加える.  $\mathbf{x}, \mathbf{y}$  を任意のモデルの包絡線ベクトルとすると, その距離は式(15)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  $D$  の値が小さいほど相違度が低いモデル, すなわち似ているモデルである.

$$D(\mathbf{x}, \mathbf{y}) = \alpha \cdot \sum_{i=1}^N |x_i - y_i| \quad (15)$$

ただし,  $i$  はベクトルの  $i$  番目の要素を示す.

## 3. 実験と評価

SVM は Joachims らのアルゴリズム SVM<sup>Light</sup>[Joachims99]を Ruping らが C++ で実装した mySVM(<http://www-ai.cs.uni-dortmund.de/SOFTWARE/MYSVM/>) [Puping00]を用いて実装した. 検索システムは 3 次元ポリゴンメッシュを対象としており, gmtools を基板として C++ で実装した. 実験には, VRML(Virtual Reality Modeling Language)モデル 302 個からなるデータベースを用いた. 実験 1 で類似検索に使用する包絡線ベクトルの区間数を決定するための実験を行った. 実験 2 では, 実験 1 の結果をもとに検索を行った結果である.

### 3.1. 実験 1

この実験では, 類似検索に用いる特徴量の包絡線ベクトルの区間数についての実験を行った. これにより, 検索に最適な区間数を調べる. 今回は, モデルの概形, 詳細をある程度反映しているであろう区間数を最適なものとする. 区間数の少ない包絡線はモデルの概形, 区間数の多い包絡線はモデルの詳細を捉えていると考えられる. そこで, 他の区間数の包絡線との距離が全体的に小さいものを最適な区間数とする. 実験は, 同一モデルから区間数の異なる 8 つの包絡線を求め, 区間数の異なる包絡線同士を比較した. 10 種類のモデルに対して比較を行い, その平均を結果として図 6 に示す. 相違度計算には動的計画法を適応した弾性マッチングを使用した. 図 6 の結果より, 区間数 63, 127(実線で示す)の 2 つの区間数が他の区間数と距離が小さく最適な区間であると言える.

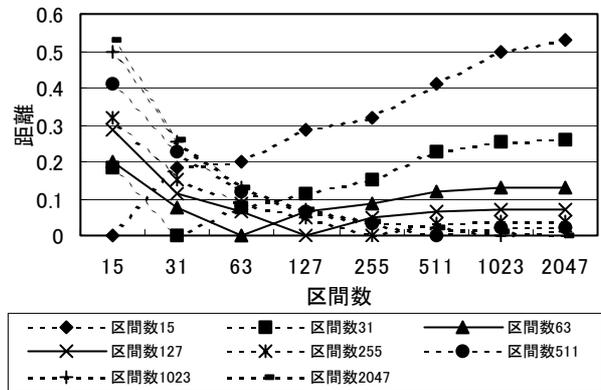


図 6: 同一モデル間の相違度

### 3.2. 実験 2

この実験では, SVM を使用した場合と使用しなかった場合での検索結果の相違を比較した.

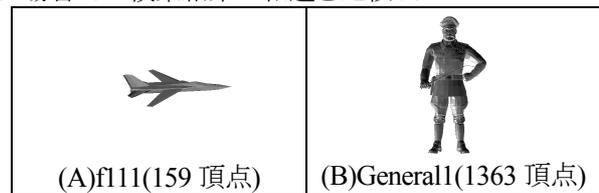


図 7: 類似検索でを使用した検索モデル

図 7 のモデルを検索モデルとして検索を行った. 包絡線ベクトルの区間数は実験 1 の結果から 63 区間を使用した. SVM を使用せずに検索を行った結果が図 8(a), 図 9(a), SVM を使用した結果が図 8(b), 図 8(c), 図 9(b) である. SVM で使用する学習データは検索結果の上位 15 モデルを基に作成した. (図 8(a), 図 8(c), 図 9(a) の各順位の右の +1, -1 がタグである). 学習データは, (A) のモデルを検索モデルとした検索では「飛行機」のモデル, (B) モデルを検索モデルとした検索では「人型」のモデルに対して +1 のタグを付与し, それ以外の

モデルには-1 のタグを付与することで作成した。

(A)のモデルを検索した場合には, 1 回目の学習で +1 のタグを付与したモデルが上位を占め, 10, 11 位に新たな「飛行機」のモデルが選出されている。さらに, 2 回目の学習で上位 10 位までが「飛行機」のモデルとなった。これは, SVM によりモデル間の距離を修正することで, 人の主観をある程度反映出来た結果といえる。

(B)のモデルを検索した場合には, +1 のタグが付与されたモデルが上位に浮上し順位に変化が見られたが, 選出されたモデルの集合には変化は見られなかった。また, データベース中には図 10 のような「人型」のモデルが 2 種類存在しているが, これらを上位 15 位以内に検索することは出来なかった。これは, SVM がユーザの欲しいモデルを判別しきれなかったためである。そのため, 教示方法や, SVM に使い方の改善が必要と考えられる。



図 10:「人型」のモデル

#### 4. まとめと今後の課題

本論文では, 学習により人間の主観を反映する 3 次元モデルの類似検索手法を提案した。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。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た。そのため, 相違度の高いモデルを学習することができず, SVM の学習効率を低下させている可能性がある。本手法の特徴量は向きの正規化が必要で, まれではあるが向きの正規化に失敗したために検索に失敗することがあった。

今後, 衣嶋ら[衣嶋 02]で用いたような向きの正規化を要しない特徴量と本論文で用いた特徴量や新たな特徴量との比較, また, これらを組み合わせた手法の検討を行いたい。また, 繰り返し学習の候補となるデータの選出法の改善, SVM の適用手法の変更(例えば, 分離超平面からの距離に基づく検索), 等も考慮する予定である。

**謝辞:**本研究は文部科学省科学研究費補助金(課題番号 14580369)からの助成による。

#### 参考文献

[Burges98] C. Burges, A Tutorial on Support Vector Machines for Pattern Recognition, *Data Mining and Knowledge Discovery*, 2, pp. 1-47, 1998.  
[Elad00] M. Elad, A. Tal, S. Directed Search in A 3D Objects Database Using SVM, *HP Laboratories Israel Technical Report*,

HPL-2000-20 (R.1), August, 2000.

[Gottschalk96] S. Gottschalk, M.C. Lin, D. Manocha, OBBTree: A Hierarchical Structure for Rapid Interference Detection, *Proc. SIGGRAPH '96*, pp. 171-180, 1996.

[Hilaga01] 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.

[Igarashi99] Takeo Igarashi, Hidehiko Tanaka, Satoshi Matusoka, Teddy: A Sketching Interface for 3D Freeform Design, *Proc. SIGGRAPH '99*, pp. 409-416, 1999.

[Joachims99] T. Joachims, Making Large Scale SVM Learning Practical, in *Advances in Kernel Methods - Support Vector Learning*, B. Schölkopf, et al. Eds., MIT Press, 1999.

[Keim99] D. Keim, Efficient Geometry-based Similarity Search of 3D Spatial Databases, *Proc. ACM SIGMOD Int. Conf. On Management of Data*, pp. 419-430, Philadelphia, PA., 1999.

[Mortensen97] M. E. Mortensen, *Geometric Modeling, Second Edition*, John Wiley & Sons, Inc., 1997.

[Novotni01] M. Novotni, R. Kleim. A Geometric to Approach to 3D Object Comparison. *Proc. Int'l Conf. on Shape Modeling and Applications 2001*, pp. 165-175, Genova, Italy, May, 2001.

[Osada01] 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.

[Paquet97] 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.

[Ruping00] S. Ruping. mySVM-Manual. <http://www-ai.cs.uni-dortmund.de/SOFTWARE/MYSVM/>. October 2000.

[Suzuki98] 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.

[Suzuki00] 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.

[Vapnik98] V. N. Vapnik. *Statistical Learning Theory*. Wiley, 1998.

[Vapnik99] V. N. Vapnik. *The Nature of Statistical Learning Theory, Second Edition*. Springer, 1999.

[Veltkamp01] R. C. Veltkamp. Shape Matching: Similarity Measures and Algorithms, invited talk, *Proc. Int'l Cong. on Shape Modeling and Applications 2001 Workshop Multimedia Signal Processing*, Cannes, France, pp. 293-298, October 2001.

[Vranić01] 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.

[William92] William H. Press et al., *Numerical Recipes in C-The Art of Scientific Computing*, Second Edition, Chapter 7.7: Quasi-(that is, Sub-)Random Sequences, Cambridge Universe Press, Cambridge, UK, 1992, pp. 309-315.

[衣嶋 02] 衣嶋 昌俊, 小田切 智, 大淵 竜太郎, 人間の感性に基づく 3 次元モデルの形状類似検索, 情報処理学会 グラフィクスと CAD 研究会, Vol. 2002, No. 16 (2001-CG-106), pp. 25-30, 2001 年 2 月 21 日。

[小田切 02] 小田切 智, 衣嶋 昌俊, 武井 毅, 大淵 竜太郎, 慣性モーメントの包絡線を用いた 3 次元モデルの形状類似検索, 情報処理学会 第 64 回全国大会 講演予稿集, pp. 757-762, 2002 年 3 月 14 日。

[前田 01] 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

[鈴木 97] 鈴木一史, 加藤俊一, 築根秀男. 主観的相違度を反映した 3 次元多面体の検索. 第 3 回知能情報メディアシンポジウム, pp. 9-16, Dec. 1997.

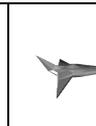
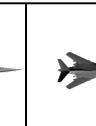
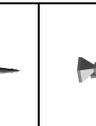
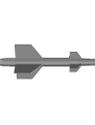
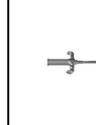
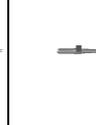
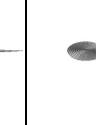
				
検索モデル	1:(+1)	2:(+1)	3:(+1)	4:(+1)
				
5:(+1)	6:(+1)	7:(-1)	8:(-1)	9:(+1)
				
10:(-1)	11:(-1)	12:(-1)	13:(-1)	14:(+1)

図 8(a): 検索結果, SVMなし

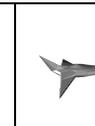
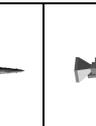
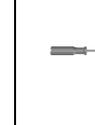
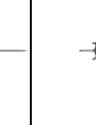
				
検索モデル	1:(+1)	2:(+1)	3:(+1)	4:(+1)
				
5:(+1)	6:(+1)	7:(+1)	8:(+1)	9:(-1)
				
10:(+1)	11:(+1)	12:(-1)	13:(-1)	14:(-1)

図 8(b): 検索結果, SVMあり(学習回数1回)

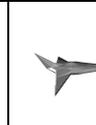
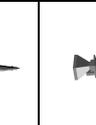
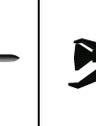
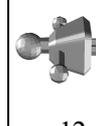
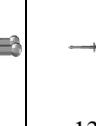
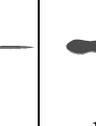
				
検索モデル	1:(+1)	2:(+1)	3:(+1)	4:(+1)
				
5:(+1)	6:(+1)	7:(+1)	8:(+1)	9:(+1)
				
10:(+1)	11	12	13	14

図 8(c): 検索結果, SVMあり(学習回数2回)

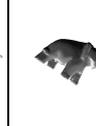
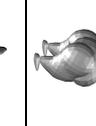
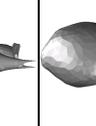
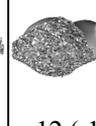
				
検索モデル	1:(+1)	2:(-1)	3:(-1)	4:(-1)
				
5:(+1)	6:(-1)	7:(-1)	8:(-1)	9:(-1)
				
10:(-1)	11:(+1)	12:(-1)	13:(-1)	14:(-1)

図 9(a): 検索結果, SVMなし

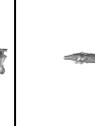
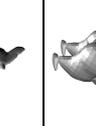
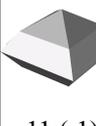
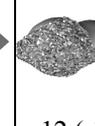
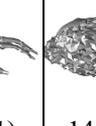
				
検索モデル	1:(+1)	2:(+1)	3:(+1)	4:(-1)
				
5:(-1)	6:(-1)	7:(-1)	8:(-1)	9:(-1)
				
10:(-1)	11:(-1)	12:(-1)	13:(-1)	14:(-1)

図 9(b): 検索結果, SVMあり