TR - A - 0077スケルトンを用いた階層的形状記述 およびニューラルネットによる階層的形状識別 松下 博 森 吉弘 亁 敏郎 Hiroshi MATSUSHITA Yoshihiro MORI **Toshio INUI**

1990年3月29日

ATR視聴覚機構研究所

〒619-02 京都府相楽郡精華町乾谷 ☎07749-5-1411

ATR Auditory and Visual Perception Research Laboratories

Inuidani, Seika-cho, Soraku-gun, Kyoto 619-02 Japan

 Telephone:
 +81-7749-5-1411

 Facsimile:
 +81-7749-5-1408

 Telex:
 5452-516 ATR J

あらまし

3-D非剛体の形状認識は,観察者の視点の変化および形状自体の変化をいかに 記述し,効率のよい認識方式に結び付けるかが問題である.また,認識に際しては, モデルと実データをどのようにマッチングするかが重要である.本テクニカルレポ ートでは,対象として,3-D非剛体のシルエット画像を扱う.形状記述の表現素 としてスケルトン(骨格)を用い,多重解像度表現に基づく階層的形状記述アルゴリ ズムを提案する.さらに,ニューラルネットワークモデルを用いた階層的学習によ り,形状モデルの自動生成を行い,学習後のネットワークを用いた階層的形状識別 手法を提案する.その結果,非剛体形状は,そのスケルトンにより特徴がよく反映 され,柔軟で効率のよい形状識別が可能となった.

以下,次の順に詳述する(図表は,14頁以降にまとめる).

		貝
第1章	まえがき	1
第2章	スケルトンを用いた形状記述の自動生成	3
第3章	ニューラルネットワークモデルを用いた階層的	
	形状学習・認識アルゴリズム	8
第4章	シミュレーション	1 0
第5章	シルエットにおけるセグメンテーションについて	1 1
第6章	むすび	12

1. まえがき

L

最近,視覚情報処理の計算論的アプローチに基づいた研究が盛んに行なわれてい る.特に,初期視覚においては,さまざまな視覚モジュールに対して計算論的研究 がなされている.これらの視覚モジュールは,それぞれ異なった側面から,観察者 のまわりの3-D形状表面の物理的特性を抽出するために用いられる.視覚モジュ ールには,ステレオマッチング,運動・遮蔽輪郭からの構造復元,陰影からの形状 復元などがあるが,信頼性の高い形状認識のためには,これらの手がかりを何らか の形で統合すべきであろう.

本テクニカルレポートでは、上述のモジュールのうちの遮蔽輪郭からの構造抽出 ・形状認識であり、対象として非剛体のシルエット画像を扱う.

一般に,形状解析の方法は,大別すると次の2つになる.1つは,形状の輪郭線 に基づく記述である.これには,曲率・チェイン符号化・スプライン補間などによ る記述⁽¹⁾⁽²⁾⁽³⁾が含まれる。もう1つは,形状の領域に基づく記述である.これは, 形状の内的構造による記述であり,例えば中心軸変換(MAT)⁽⁴⁾や一般化円錐⁽⁵⁾など による表現が挙げられる.本研究では,後者のアプローチを採用する.その理由は, 動物などに代表される非剛体形状の認識を行なう場合,対象の動きにより,その輪 郭線が大きく変化してしまうからである.逆に,非剛体の形状変化は,その骨格や 関節によって拘束されるはずであり,認識を目的とした場合スケルトン(骨格線) は,非常に有効である.また,内的構造としてスケルトンを用いると情報圧縮の効 果もある.しかし,スケルトンを表現素とした場合のデメリットとして,過敏性が ある.これは,輪郭線の微妙な変化がスケルトンにおけるヒゲとして現われる現象 である.ただし,本研究においては,後述するように,輪郭線に沿ってスムージン グを施しているので,安定したスケルトンが得られている.

さらに、柔軟で効率のよい形状認識のためには、階層的な形状記述が有効である (⁶⁾. 階層的表現として多重解像度表現を適用し、それぞれの解像度で対象のスケル トンを抽出する.ここで、階層レベル間の関係記述を含むtree表現を提案する. このようにして得られた階層的形状記述は、ニューラルネットワークモデルにより、 階層的に学習され、認識が行なわれる.ここで言う階層的認識とは、各解像度毎に、 そのレベルに対応した識別を行なうネットワークを構築し、低解像度レベルから識 別とネットワーク選択を繰り返し、順次、詳細識別がなされてゆくというものであ

-1-

る.

以下,スケルトンを用いた階層的形状記述アルゴリズム,ニューラルネットによる階層的形状学習・認識手法,および大分類シミュレーション,シルエットにおける重なり部分のセグメンテーションについて述べる.

Ĩ

<u>2. スケルトンを用いた形状記述の自動生成</u>

ĥ

図1は、形状の階層的構造記述を得るための流れ図である.入力パターンとして、 3-D形状をある視点からながめたときに得られる2-Dシルエットを考える.こ のシルエットに対して輪郭線追跡を施し、抽出された輪郭線図形に対する階層的構 造記述を自動生成する. 階層的表現として輪郭線に沿ったマルチレベルの平滑化を 行なう. すなわち, 抽出された輪郭線の座標系列は, まず十分大きい標準偏差 σ1(レベル1)をもつガウス関数で平滑化される.次に、平滑化された輪郭線図形のスケ ルトンを連結線分の形で抽出する.ここで,その階層レベルにおける図形の特徴量 を記述するためにスケルトンの記号化を行なう、記号化としてスケルトンの折れ線 近似を行ない、近似スケルトンにおける各折れ線の長さ・方向などの数値をそのレ ベルの特徴量とする.いま、レベル1における近似スケルトンは、原図形の最も大 局的な特徴を表していることになる.さらに、そのレベルにおける特徴量の記述と ともに、そのレベルまでに求められた各レベル間の対応関係を記述するために、近 似スケルトンをtree表現し、このtreeの各節点および枝に対してラベリン グを行なう.このラベリングにより,各レベルの情報が次のレベルへと継承されて ゆく. 最後に, 上述の各レベルの特徴量を, 関係記述を表すtreeに付記するこ とにより、そのレベルの構造記述とする.

次のレベル2では、平滑化関数のσ2を小さくして同様の操作を行なう.以上の操作を繰り返すことにより、粗レベルから密レベルに至るマルチレベルのtree表現が求まり、階層的構造記述が得られる.

以下,図1の流れ図の各ステップについて詳細に説明する.

2.1 輪郭線のマルチレベル平滑化

多重解像度表現として、図形輪郭線のガウス関数によるマルチレベル平滑化を考える⁽¹⁾. すなわち,輪郭線に沿って1次元のガウシアンフィルタリングを行なう. 原図形輪郭線のx座標系列をx(t)とすると、平滑化された座標系列Xは、

-3-

 $X (t, \sigma) = x (t) * g (t, \sigma)$ (1)

g (t, σ) = (1/ $\sigma\sqrt{2\pi}$) exp (-t²/2 σ^{2}) (2)

となる. ここで、'*'は、たたみこみ積分を示す.

(1)式における σ は、ガウス関数 g の標準偏差であり、この値を変数として操作す ることによりマルチレベルの平滑化が行なえる.大きい値の σ によるたたみこみは、 大きな平滑化を意味し、逆に、小さい σ による平滑化は、もとの輪郭線をより忠実 に再現するため、 σ を解像度軸として扱える.なお、y 座標系列についても同様で ある.図2に入力パターンとして'ラクダ'のシルエット(a)が与えられた場合を示 す.同図(b)は、(a)の輪郭を抽出したものであり、(c)~(g)は、マルチレベル の平滑化を行なった結果である.図2(c)~(g)において、 σ は解像度を表してお り、 σ が大きいほど解像度が低い.ここで σ の値は、後述するが、スケルトンの構 造が変化するときの平滑化レベルとして決定される.

1

<u>2.2</u> スケルトン抽出

マルチレベル平滑化により得られた各々の線図形(図2(c)~(g))に対してス ケルトンを抽出する.スケルトン抽出のアルゴリズムに関しては,さまざまなもの が考案されているが⁽⁴⁾⁽⁷⁾⁽⁸⁾,一般にスケルトンは,輪郭線の変化に非常に敏感で ある.上述の輪郭線に対する平滑化は,ノイズ除去作用にも寄与していると考えら れる.本研究では,抽出結果の連結性を重視する.これは,得られたスケルトンの 記号化としてスケルトンの折れ線近似を行ない,その各折れ線の長さや方向などを 特徴量として記述するためである.このため,スケルトン抽出として,連結性の保 証された細線化のアルゴリズムを用いる.'ラクダ'についてスケルトンを抽出した 結果を図2(c)~(g)に示す.図2からわかるように大きな平滑化が施された図2 (c)のスケルトンは,原図形の大局的特徴を示し,逆に図2(g)は,もとの輪郭線 形状の詳細な部分の特徴まで表している.

2.3 スケルトンの記号化

連結線分の形で得られたスケルトンに対して,各セグメント(端点-交点および交 点-交点を結んでいる線分)毎に,k-曲率⁽⁹⁾に基づく折れ線近似を行ない,得られた 結果を近似スケルトンと名付ける.k-曲率とは,曲率を求めようとしている点と, その点の両側にそれぞれ距離kだけ離れた輪郭線上の点とを結んでできる2つの線 分の角度変化である.したがって,大きい値のkを用いると粗い曲率の調べ方をし ていることになり,小さいkでは細かな曲率変化まで見ていることになる.本研究 における折れ線近似の方法には,以下に示す3つのパラメータ(rate,thres,range) が存在する.

-4-

1) k-曲率のkの値を決定するための値:rate

2) k-曲率のしきい値:thres

3) k-曲率の局所極大値を求める範囲:range

1)については、細線化により得られたスケルトンの各セグメント長をs;(i=1, 2,…)とすると各セグメント毎のk-曲率のkの値k;は、

 $k_i = s_i / rate$

Ъ

(3)

となる. パラメータrateは、 s ; と k ; の比率を示す. このように,各セグメント毎 に k の値を変えるのは,短いセグメントと長いセグメントの折れ線近似の度合を変 えることにより,それぞれのセグメント形状を生かすためである.2)は,折れ線 の折れ曲がり点(ただし端点と交点は,起点および終点とする)の候補点を選ぶとき のk-曲率のしきい値である.実際のk-曲率の値が,このしきい値より大きいときそ の点は,折れ曲がり点の候補点となる.このしきい値は,実際には,比較的小さい 値を用い,いくつかの候補点を抽出し,次に述べるパラメータrangeにより最終の折 れ曲がり点を決定する.3)は,2)で得られた折れ曲がり候補点の中からk-曲率 の局所極大値,すなわち最終の折れ曲がり点を求めるための位置の近傍の範囲を示 す.したがって,この範囲を操作することにより,一本の枝当りの折れ曲がり点の 数を制御できる.

以上, 3つのパラメータを操作することにより,所望の近似スケルトンが得られる.図3に,'ラクダ'のスケルトンに対して折れ線近似を施した結果を示す.なお, これらパラメータの値は,後述のシミュレーション結果についても次の値で行なった.

(rate, thres, range) = (5, 0.1, 5)

これらの値は,各枝における折れ曲がり点の数を1にするために選ばれたものである.すなわち,これらのパラメータをうまく選択することにより,パターンに依存 することなく折れ曲がり点数を任意の1つの値に制御できる.

-5-

2.4 スケルトンのtree表現

2.4.1 階層レベル間の関係記述

スケルトンにおける交点およびセグメントを、それぞれtreeの節点および枝 と考えたtree表現を提案し、treeにおける各々の節点および枝にラベリン グを施すことにより各階層レベル間の関係記述を行なう. ₹.

」以下,'ラクダ'に関するtree表現を示す図4を例にあげて,treeの構成 法を説明する. 図4において N1,N2,… は節点名を, 数字は枝名を示す. 図4(a) は、最も粗な階層(レベル1)におけるスケルトンのtreeである. この階層レベ ルからラベリングを始め,順次,密レベルヘとラベリングを進めてゆき,各レベル の構造的特徴情報を継承させ関係記述が得られる.レベル1においては,節点N1, 枝1,2,3 とする. ラベリングの方法は, 新たな節点が1つ出現するレベル(図4(b))において,前レベルを参照して枝3 に節点N2が出現したことから,枝3 を3つの 枝31.32.33に分割する.同様にして,次レベル(図4(c))においては,前レベルの 枝31に節点N3が出現するため,枝31が枝311,312,313 に分割される.以下,最も密 なレベル (図4(e))まで同様の操作を繰り返すことにより関係記述が得られる.こ のラベリング手法からわかるように、節点については添え字の若いものが、枝につ いては桁数の小さいものが,より粗なレベルにおいてラベリングされたものである. また,節点数は,階層レベルを表している.ここで注意すべきことは,最終の密レ ベルのtreeには、すべてのレベルの関係が記述されていることである、すなわ ち、このレベルのtreeにおいて桁数の大きい枝から順次,統合を行なうことに より、任意のレベルのtreeが再構成できる. したがって、この最終レベルのt r e e は,形状の解像度軸に沿った構造的特徴の変化を反映している.なお,各解 像度レベルを表すσ1,σ2,…の値は,パターン毎に,節点数が1つずつ増すよう な σ を サーチして決定している.したがって、パターンによっては、同じ節点数の レベルでも異なるσの解像度となることがあるが、本研究における形状記述手法の 特徴は,形状の構造記述であり, σの値そのものは,それほど意味はなく,スケル トンの構造(節点数など)が重要となる. さらに,形状マッチングの段階では,本記 述手法で得られたすべての階層レベルを用いるのではなく,いくつかのレベル(例 えば2番目に粗いレベルと2番目に密なレベルの2つ)を選択して階層的に形状識 別を行なうため,形状変化の過敏性は,かなり吸収されると考えられる.

-6-

2.4.2 近似スケルトンの特徴量

1

各階層レベルにおいて、折れ線近似の結果得られた近似スケルトンの特徴量を抽 出する.特徴量として、各折れ線の長さと方向および各節点の位置を考える. 図5を例として、それぞれの特徴量について説明する.これは、各節点の位置座標、 およびそこからのびる枝に関して、その枝を構成している折れ線の長さと方向を示 している.この図においては、各枝を構成する折れ線数は、すべて2になっている. この折れ線数は、上述の3つの折れ線近似パラメータのうちの'range'を操作するこ とにより制御できる.図5において、各枝 i (i=1,2,3)の折れ線の節点からみた第 j 成分(j=1,2)の長さおよび方向(水平右向きを基準として反時計回り方向)をそれぞれ 1 i-j,およびθ i-j(rad)とすると、正規化された長さLi-jおよび方向Θi-jは次の ようになる.

$$L_{i-j} = 1_{i-j} / \sum \sum 1_{i-j}$$

i j

(4)

(5)

 $\Theta_{i-j} = \theta_{i-j} / 2\pi$

また,節点の位置座標を(x1, y1)とすると正規化座標(X1, Y1)は次のようになる.

 $X 1 = (x 1 - x_{min}) / (x_{max} - x_{min})$ (6) $Y 1 = (y 1 - y_{min}) / (y_{max} - y_{min})$ (7)

ただし、 x min, y min, x max, y maxはそれぞれ近似スケルトンにおけるx, y 座 標の最小値および最大値である.以上のように [0, 1] の範囲に正規化された各折 れ線の長さ・方向,および節点の正規化された位置座標が,各解像度レベルの特徴 量として抽出される.

同様にして,さらに階層の密なレベルの特徴量も正規化された形で抽出される. 正規化の目的は,後述する形状学習・認識のためのニューラルネットワークへの入 力データとするためである.

-7-

以上に述べた近似スケルトンの特徴量を, 階層レベル間の関係記述を示すtre eに付記することにより, 階層的形状記述が得られる.

ĵ

..

図6,7に階層的形状記述の例を示す.図6,7は,それぞれ'ウシ','キリン'の階層的記述である.図4,6,7のtree表現からわかるように,いずれの動物も階層の粗いレベルでは,treeの構造(各枝の接続関係)は同じになっている.

3. ニューラルネットワークモデルを用いた階層的形状学習・認識アルゴリズム 3次元形状の認識問題を扱う場合,まず,モデルと実データをどのようにマッチ ングするかが問題となる。例えば,実データの視点方向をある種の仮説を用いて決 定し,その方向から3次元モデルを見たときのモデルの見え方を計算することによ り両者を比較することが考えられる。ただし,モデルの自動生成は,非常にむずか しい問題である。単純な形状の3次元モデルの自動生成を,ニューラルネットを用 いて行なった研究⁽¹¹⁾がある。この研究では,ある対象を複数の異なる視点からな がめたときの投影像が,学習サンプルとして与えられる。出力では,標準方向から ながめたときの投影像が教師信号として与えられ,ネットワークは実際の視点方向 から標準方向への変換規則を学習する。ただし,対象は剛体であり,1つのネット ワークは,1つの対象を学習する。

我々は,対象として非剛体を取り上げ,対象の運動による形状変化と観察者の視 点方向の変化に伴う形状変化の両面を扱おうとしている.

スケルトンを用いた多重解像度表現に基づく階層的形状認識アルゴリズムは,次の3つのステップからなる.

1)スケルトンを用いた階層的形状記述

2)3層のニューラルネットによる形状学習

3) 学習後のネットワークによる形状認識

1)は、前章で提案した形状記述のステップである、入力パターンは、まずこの 段階で、スケルトンを用いて階層的に記述される、図8(a)は、その概念図であり、 解像度ピラミッドを表している、各ピラミッドの上部ほど、低解像度、すなわちそ の形状の大局的特徴を表現している、また、1つのピラミッドの各階層(レベル1、 レベル2、…、レベルN)には、近似スケルトンの特徴量と階層間の関係が記述され ている.

2)では、3層のニューラルネットワークモデルを用いて、形状学習がなされる. ここで、学習に先立ち形状の階層的カテゴリー化を考える.図8(b)は、1)で求 まった階層的記述に基づいて、ある形状の集合を階層的にカテゴリー化した様子を 示している.例えば,4つ足動物をカテゴリー化する場合,一番上の階層レベルに は、4つ足動物すべてが属する、次の階層レベルでは、4つ足動物が2つのグルー プに大分類される(ただし、分類は2分木に限らない). そして、いくつかの分類を 経て、個々の動物がカテゴリー化される、本研究では、対象として4つ足動物を取 り上げ, 階層的カテゴリー化がすでになされたものと仮定する. 階層的形状(近似ス ケルトン)は、カテゴリー化により決定された各階層レベルのグループ名を教師信号 として、ある階層レベルからその1つ下のレベルへの分類を行なうネットワークに より学習される、ネットワークは、入力層、出力層、中間層の3層からなり、入力 層には、各階層レベルにおける近似スケルトンの各セグメントの長さ・方向などが 入力される.また,学習則として,誤差逆伝搬アルゴリズム(10)を用いる.誤差逆 伝搬アルゴリズムは、最急降下法による誤り訂正過程であり、(8)式に示す出力誤 差を極小化するように、ネットワークの各ユニット間の結合係数を変化させるもの である.

2

$$E = (1 / 2) \Sigma (t_{j} - o_{j})^{2}$$
(8)

ここで、 t」, o」はそれぞれユニットjの教師信号と実際の出力信号である. ユニ ットiからユニットjへの結合係数w」;は、次式(9)により推移してゆく.

また、中間層の各ユニットの入出力関数は、シグモイド関数を用いる.

3)は、認識のステップであり、各階層レベルで構築されたネットワークに未知 パターンあるいは既知パターンを入力し、その出力結果を次のレベルのネットワー ク選択に用い、順次、詳細識別へと進んでゆくことにより、階層的認識が得られる.

4. シミュレーション

実際のネットワークの構成について、少し詳しく述べる、本研究では、階層レベ ル2における3種類の動物の形状分類を行なった.ネットワークの構成を図9に示 す.入力層は、25個のユニットから構成され、対象の階層レベル2における近似 スケルトンの特徴量が正規化されて入力される.また,出力層は,3つのユニット からなり, それぞれ'ラクダ', 'キリン', 'イヌ'の3種類の動物に対応している. さらに、中間層は、8つのユニットで構成する、シミュレーションは、3種類それ ぞれの動物について、51個の学習パターンと50個の未知パターンを生成し、学 習パターンについては、1000回の繰り返し学習を行なわせた。図10に学習パ ターンの一例を示す、学習および未知パターンの生成については、本来なら実際に さまざまに変化する3D形状のシルエットから得られるべきであるが,本テクニカ ルレポートでは、その動物の典型的なシルエットから得られる近似スケルトンを基 に. その各セグメントの長さや方向をランダムに変化させることにより生成した. ここで、シミュレーションの妥当性について考えてみると、次の2点が問題となる. 1つは,スケルトン抽出が実データを対象とした場合,安定して行えるかどうかで ある.この点については,2章で述べたように,スケルトン抽出の前に輪郭線の平 滑化を施しているので,実データに対しても安定して得られると考えられる.もう 1点は、生成パターンのランダム性である、パターンの生成は、まず、それぞれの 動物らしさが保たれるように、近似スケルトンの各枝の第1成分と第2成分の長さ の和を一定に保ったまま,各セグメントの長さおよび方向をランダムに変化させる. その後、すべての節点、端点、折れ曲がり点の位置をランダムに振動させる、この ときも同様に、その動物の動物らしさが保たれるように、振幅に制限を設ける、こ の振動により、各セグメントの長さ・方向が影響を受け、前述の成分和が一定とい う条件が崩れる.そこで,このときの最終の長さ・方向,節点の位置座標を計算す る. この方法により, ネットワークは, 意味のないパターン生成規則などの学習を 行なわず,近似スケルトンの形状のみを学習していると考えられる.

認識結果は、学習パターンについては100%、未知パターンについては97. 3%の認識率が得られた、すなわち、階層レベル2における大分類を行なうネット ワークがうまく構成されたことになる、このことから、動物等の非剛体形状は、ス ケルトンによりその特徴がよく反映され、効率の良い認識がなされることがわかっ た. また,ネットワークに入力するデータが,入力対象から抽出したスケルトンの 長さ・方向といった簡略化された数値であるため,ネットワークの構成に必要なユ ニット数が少なくて済んでいる.

5. シルエットにおけるセグメンテーションについて

3 D非剛体形状は,その対象の運動や観察者の視点の変化に伴い,大きく変化し 得る.特に,対象のシルエットを入力として形状記述および認識を考える場合,対 象の交差部分のセグメンテーションが必要かつ重要となる.前章までに扱ったシル エット形状は,すべてこのような部分間の重なりのないものだけであった.しかし, より一般性をもたせるためには,重なり部分が生じるような対象の姿勢も考慮すべ きである.スケルトンに基づく形状記述においては,部分間の交差は,ループ状の スケルトンとして現われる(図11参照).そこで,ループ状になったスケルトン のセグメンテーションを行い,その結果得られたスケルトンをもとに,前述の形状 記述・認識を適用することを考える.

図12は、ある動物の近似スケルトンを模式的に表したものである. 各セグメン トの交点は、nodeを表している. 近似スケルトンの中央付近にループ状の部分がで きているが、ループの原因は、ある2つのセグメントの交差である. すなわち、 図13(a)に示すように、ループ付近の隣接する2つのnodeの組のうち、どれか 1組は、nodeではなく分離すべき2つのセグメントの交差によって生じたものであ ると考えられる. したがって、すべての隣接する2つのnodeの組(図14参照)の うち、最も直線の連続性の高いものを選択し、その部分を交差部分と考える. 例え ば、図15に示したような×印の部分が、交差部分であったと判定された場合は、 同図右側のようにセグメンテーションが実行される. ただし、図13(b)のよう なセグメンテーションは、非剛体のスケルトンとしては除外する.

そこで、以下に述べるような連続性の度合を示す評価関数を定義する. 図12では、模式的に表していたが、実際の近似スケルトンにおける各セグメント は、図16に示すようにすべて2つの折れ線の要素から成っている.図16のよう に各セグメントの折れ線の長さと方向(11,12,a1~a6)を決め、直線連 続度C」を次のように定義する. $1 / C_{L} = \alpha (11 + 12) + \beta (|a1 - a4| + |a2 - a3|) + \gamma (|a1 - a5| + |a2 - a5| + |a3 - a6| + |a4 - a6|)$ (10)

(10)式は、3つの項から成っている.第1項は、交差部分の長さの拘束条件で ある.第2項、第3項は、方向変化の拘束条件である.それぞれ値が、小さいほど 連続度が大きく、 α 、 β 、 γ は、それぞれの項の寄与度を示すパラメータである. 以上に定義した直線連続度CLを隣接する2つのnodeの組に対してすべて計算し、そ のうち最大のものを求め、セグメンテーションを行なう.図17にシミュレーショ ン結果を示す.ここで、3つのパラメータα、 β 、 γ の決め方については、それぞ れの項の寄与度を考慮してヒューリスティックに決定することになるが、実際にい ろいろな値でセグメンテーションを試みてみると、かなりの値の範囲で安定して同 ーの所望の結果が得られた.図17に対しては、パラメータ値は、 $\alpha = \beta = \gamma = 1$ である.もちろん、異なる対象(図17(a),(b)参照)に対して同一のパラ メータ値でセグメンテーションが可能であった.

6. むすび

÷

非剛体形状のシルエット図形に対して,スケルトンを表現素とした多重解像度表 現,およびその認識方式を提案し,その有効性を確認した.この多重解像度表現は, スケルトンを階層的にtree表現したものであり,各解像度レベルにおける対象 の特徴量に加えて,解像度レベル間の対応関係の記述も含まれている.また,認識 方式として,3層のニューラルネットを用いた形状学習・認識を提案した.ここで は形状は,スケルトンのtree表現に基づいて階層的にカテゴリー化され,それ ぞれの解像度で学習される.認識時は,学習後のネットワークを解像度毎に階層的 に選択することにより,大分類・詳細分類といった階層的認識が可能となる.シミ ュレーションとして,3種類の4つ足動物の大分類用ネットワークを構成し,良好 な識別結果が得られた.さらに,一般化の目的で,シルエットにおける部分間の重 なりを検出してそれを分離するアルゴリズムを提案した.今後は,さらに詳細な階 層レベルの認識性能を評価してゆきたい.また,複数の異なる視点から対象を見た 場合に得られるシルエット群の記述を統合することにより, 3D形状の記述および 認識へ拡張してゆきたい.

<u>文献</u>

- F. Mokhtarian, A. Mackworth: "Scale-Based Description and Recognition of Planar Curves and Two-Dimensional Shapes", IEEE P.A.M.I., 8, pp. 34-43(1986).
- (2) H. Freeman: "On the Encoding of Arbitrary Geometric Configurations", IRE Trans., EC-10, pp. 260-268(1961).
- (3) T. Pavlidis: "Structural Pattern Recognition", Springer-Verlag, Berlin-Heidelberg-New York(1977).
- (4) H. Blum: "Biological Shape and Visual Science (Part 1)", J. Theoretical Biol., 38, pp. 205-287 (1973).
- (5) G. J. Agin, T. O. Binford: "Computer Description of Curved Objects", IEEE Trans., C-25(4), pp. 439-449(1976).
- (6) D. Marr:"Vision", W. H. Freeman and Company(乾,安藤訳. 産業図書. 1987).
- (7) A. Rosenfeld, J.L. Pfaltz: "Sequential Operations in Digital Picture Processing", J. ACM., 13, pp. 471-494 (1966).
- (8) C. J. Hilditch: "Linear Skeleton from Square cupboards", Machine Intelligence, 6, Edinburgh Univ. Press, pp. 403-420 (1969).
- (9) A. Rosenfeld, A. C. Kak: "Digital Picture Processing", Academic Press, pp. 371-375(1976).
- (10) D.E.Rumelhart, J.L.McClelland, and the PDP Research Group:"Parallel Distributed Processing", 1, pp. 318-362(1986).
- (11) T.Poggio, S.Edelman:"A network that learns to recognize threedimensional objects", NATURE, VOL. 343, pp. 263-266(1990).



図1 形状の階層的構造記述アルゴリズム

B

Fig. 1 Algorithm of hierarchical structural shape description.











(d) $\sigma = 25$

図2 入力バターン(a)とその輪郭線(b)および マルチレベル平滑化とスケルトン(c)~(g) Fig.2 Input pattern(a), its contour(b), multi-smoothing and skeletons(c)~(g).







図4 'ラクダ'のtree表現 Fig.4 Tree representations of 'camel'.







図6 'ウシ'の階層的構造記述 Fig.6 Hierarchical structural description of 'cow'.



đ







N1

N2

32

33



図7 'キリン'の階層的構造記述 Fig.7 Hierarchical structural description of 'giraffe'.





(b)

図8 解像度ビラミッドによる形状記述(a)および 階層的カテゴリー化と階層的形状学習(b) Fig.8 Shape descriptions using resolution

pyramids(a), Hierarchical categorization and hierarchical shape learning(b).







×---

図10 学習パターンの一例 Fig.10 Examples of training samples.



図11 交差部分のあるシルエットとそのスケルトン Fig.11 Silhouettes and the skeletons which have cross parts.



図12 ループのある近似スケルトンの模式図

Fig.12 A model figure of an approximate skeleton which has a loop.



Ĩ

es.

Ŷ



図13 交差部分のセグメンテーション Fig.13 Segmentation of cross parts.



図14 交差部分の候補セグメント Fig.14 Segmentation candidates of cross parts.



図15 交差部分のセグメンテーション例 Fig.15 Examples of cross parts' segmentation.



図16 交差部分の長さおよび方向

Fig.16 Lengths and directions of a cross part.

-

-









図17 セグメンテーション結果(図11に対する) Fig.17 Results of segmentation for Fig.11.($\alpha = \beta = \gamma = 1$)

and C

10