

Title	複数の動的輪郭モデルの競合による領域抽出に関する研究
Author(s)	松澤, 悠樹
Citation	
Issue Date	1999-03
Type	Thesis or Dissertation
Text version	author
URL	http://hdl.handle.net/10119/1294
Rights	
Description	Supervisor:阿部 亨, 情報科学研究科, 修士

修 士 論 文

複数の動的輪郭モデルの競合による領域抽出に関する研究

指導教官 阿部 亨 助教授

審査委員主査 阿部 亨 助教授

審査委員 堀口 進 教授

小谷 一孔 助教授

北陸先端科学技術大学院大学
情報科学研究科情報システム学専攻

710094

松澤 悠樹

1999 年 2 月 15 日

目次

1	序論	1
1.1	背景と目的	1
1.2	本論文の構成	2
2	動的輪郭モデル	3
2.1	はじめに	3
2.2	原理	3
2.3	従来研究	4
2.4	問題点	5
2.5	広い範囲の領域情報を用いた領域抽出	8
2.5.1	クラスタリングと動的輪郭モデルによる領域抽出	8
2.5.2	小領域の成長と競合による領域抽出	8
2.6	問題点	9
2.7	まとめ	9
3	複数の動的輪郭モデルの競合による領域抽出	11
3.1	はじめに	11
3.2	初期閉曲線の生成	14
3.2.1	曲線の設定と特徴量の取得	14
3.2.2	判別基準に基づく曲線分割	14
3.3	各領域における特徴量の分布推定	18
3.3.1	混合分布	18
3.3.2	EM アルゴリズムによる混合分布パラメータの算出	18
3.3.3	Fisher の線形識別法による射影軸の決定	19
3.4	領域競合	21

3.4.1	閉曲線の膨張	21
3.4.2	交差判定と境界の生成	21
3.4.3	対数尤度比に基づく競合	21
3.5	まとめ	23
4	領域抽出実験	24
4.1	はじめに	24
4.2	ノイズに対するロバスト性の評価	24
4.2.1	尤度比効果の検証	24
4.2.2	複数領域の競合効果の検証	28
4.3	実画像からの領域抽出	31
4.3.1	基本モデルによる抽出	31
4.3.2	提案手法による抽出	36
4.4	まとめ	41
5	結論	42

目 次

2.1	動的輪郭モデル	4
2.2	対象が良好に抽出できる例	6
2.3	対象の抽出が困難な例	7
2.4	クラスタリングを用いた手法	10
2.5	小領域の成長と競合による手法	10
3.1	処理の流れ	13
3.2	初期閉曲線の生成	16
3.3	曲線に沿った画像の断面	17
3.4	Fisher の線形識別法による射影軸の決定	20
3.5	対数尤度比による競合	22
4.1	初期閉曲線	26
4.2	抽出結果 (上段:濃度勾配, 下段:濃度勾配 + 尤度比)	26
4.3	抽出精度 (濃度勾配 vs 濃度勾配+尤度比)	27
4.4	初期閉曲線	29
4.5	抽出結果 (上段:単体, 下段:複数)	29
4.6	抽出精度 (単体 vs 複数)	30
4.7	複数の領域からなる対象 (ボール, 基本モデル)	32
4.8	複雑な形状 (手, 基本モデル)	33
4.9	複数の領域からなる背景 (バナナ, 基本モデル)	34
4.10	テクスチャ (シマウマ, 基本モデル)	35
4.11	複数の領域からなる対象 (ボール, 提案手法)	37
4.12	複雑な形状 (手, 提案手法)	38
4.13	複数の領域からなる背景 (バナナ, 提案手法)	39
4.14	テクスチャ領域 (シマウマ, 提案手法)	40

表 目 次

4.1	実験に用いた係数 (勾配)	25
4.2	実験に用いた係数 (勾配+尤度比)	25
4.3	実験に用いた係数 (単体)	28
4.4	実験に用いた係数 (複数)	28
4.5	Sobel フィルタ	32
4.6	実験に用いた係数 (基本モデル)	32
4.7	実験に用いた係数 (提案手法)	37

第 1 章

序論

1.1 背景と目的

対象とする物体の領域を画像から正確に抽出することは、画像処理・認識における重要な課題である。'80 年代後半に Kass らにより提案された動的輪郭モデル (Active Contour Model) [1] は代表的な領域抽出法の一つであり、閉じた領域を安定して抽出できることに加えて、抽出対象の特徴をエネルギー関数として抽出処理に埋め込むことができるという優れた特徴を持つため、盛んに研究が行われている [2] [3]。

しかし、従来提案されている動的輪郭モデルを用いた領域抽出法の多くは、対象領域の特徴量が比較的均一な場合には有効であるが、輪郭線付近の局所的な領域情報に強く依存して輪郭モデルの修正を行うため、対象領域あるいは背景領域が、複雑な形状やテクスチャを持つ場合は、対象領域の正確な抽出が困難となる。

この問題に対処するため、予め画像をクラスタリングし、得られた小領域の集合に対し動的輪郭モデルを適用する手法 [4] や、画像内に多数の小領域を設定し、それらを MDL [5] に基づき成長・競合させることで対象領域を抽出する手法 [6] など、より広い範囲の領域情報を抽出処理に導入する手法が提案されている。これらは、前述の問題に対し有効な手法ではあるが、(1) 予め画像全体に対するクラスタリングが必要、(2) 多数の小領域の初期位置設定が必要等の新たな問題が生じる。これらの問題を解決するためには、対象領域の抽出に必要な広い範囲の領域情報をできるだけ容易な方法で獲得し、その情報を反映した領域抽出法を実現する必要がある。

そこで本研究では、対象領域と背景領域それぞれに複数の動的輪郭モデルを配置し、隣接するモデル間での競合を行い、対象領域を複数の小領域の集合として抽出することにより、広い範囲の領域情報を抽出処理に反映させる手法を提案する。さらに、複数の動的輪

郭モデルの初期位置設定を容易にするため，画像中に設定された初期曲線を複数の曲線片に分割し，各曲線片を核として動的輪郭モデルを生成する手法も提案する．また，シミュレーション画像および実画像を用いた領域抽出実験を行い，提案手法の有効性を示す．

1.2 本論文の構成

本論文は次のように構成される。第2章では，動的輪郭モデルを用いた従来の領域抽出法の概要及びその問題点について述べる．第3章では，第2章で指摘した問題点に対処するために本研究で提案する，競合する動的輪郭モデルの概要と，初期曲線の設定から対象領域の抽出に至るまでの各処理について詳しく述べる．第4章では，シミュレーション画像及び実画像を用いた領域抽出実験の結果を示し，本手法の有効性について検討を行う．第5章では，本論文のまとめ及び今後の課題について述べる．

第 2 章

動的輪郭モデル

2.1 はじめに

対象領域の抽出は，画像認識・理解における重要な過程のひとつであることが，これまで多くの研究者によって指摘され [7]，様々な手法が研究されてきた．この中の代表的手法として，閾値処理，クラスタリング，またはエッジ探索等を挙げることができる [8]．しかしこれらの手法では，対象領域を閉じた領域として安定して抽出することは難しい．

一方で何らかの関数を，与えられた画像の特徴を反映するエネルギー関数として定義し，これを最小化することで領域抽出を行う手法がある．動的輪郭モデル (Active Contour Model) は，このようなエネルギー最小化原理に基づく領域抽出法であり，安定して閉じた領域を抽出できる手法として，幅広く研究されている [2] [3] [9]．

2.2 原理

動的輪郭モデルとは，図 2.1 に示すように，閉曲線に対して対象領域の輪郭付近で最小となるようなエネルギー関数を定義し，これを最小化することで領域抽出を行なう手法である．

一般にエネルギー関数 E_{ACM} は式 (2.1) に示すように，式 (2.2) の形状エネルギー項 E_{int} と式 (2.3) の画像エネルギー項 E_{image} の和を閉曲線に沿って積分する形で定義される．形状エネルギー項は閉曲線の周囲長と形状の複雑さを，画像エネルギー項は閉曲線に沿った画像の濃度勾配の大きさを表している．ここで， $\mathbf{v}(s) = (x(s), y(s))$ ($0 \leq s \leq 1$) は閉曲線を， $\mathbf{v}_s(s)$ ， $\mathbf{v}_{ss}(s)$ は s に関する 1 次微分，2 次微分を， $\nabla I(\mathbf{v}(s))$ は濃度勾配を， α ， β ， γ は正の重み係数をそれぞれ表す．

最急降下法等を用いてエネルギーの最小化を行うことで、与えられた初期閉曲線は、周囲長が短くなるように、かつ曲線全体が滑らかになるように変形していき、最終的には対象領域の輪郭線付近に収束することになる。

$$E_{ACM} = \int_0^1 \{E_{int}(\mathbf{v}(s)) + E_{image}(\mathbf{v}(s))\} ds \quad (2.1)$$

$$E_{int}(\mathbf{v}(s)) = \frac{1}{2} \{ \alpha |\mathbf{v}_s(s)|^2 + \beta |\mathbf{v}_{ss}(s)|^2 \} \quad (2.2)$$

$$E_{image}(\mathbf{v}(s)) = -\frac{1}{2} \gamma |\nabla I(\mathbf{v}(s))|^2 \quad (2.3)$$




図 2.1: 動的輪郭モデル

2.3 従来研究

動的輪郭モデルは、閉じた領域を安定して抽出することができる上に、抽出対象の特徴をエネルギー関数として抽出処理に埋め込むことができるという利点を持つため、提唱されて以来活発に研究が行われている。ここで代表的な手法をいくつか示す。

まず、対象や背景の色やテクスチャに対応する画像エネルギー関数を導入した手法として [10] [11] [12] [13] が挙げられる。

対象の形状に着目した手法としては、形状の変化に対応する方法 [14]、凹領域を抽出するエネルギー関数の導入 [15]、有穴領域の抽出を目的とする手法 [16]、形状を文法規則と

して記述し，事前知識として抽出処理に埋め込む方法 [17] 等が提案されている．複数の物体の抽出法としては，閉曲線を分裂させる方法 [18] が報告されている．

高速計算法としては，グリーディアルゴリズムを用いる手法 [19]，動的計画法を利用する手法 [20]，あるいは，スプライン曲線を用いる手法 [21] が報告されている．

また，動的輪郭モデルを用いた移動物体の追跡法についても活発に研究が行われている [22] [23] [24] [25] ．

2.4 問題点

動的輪郭モデルは，対象領域の輪郭線が鮮明で，背景のノイズが少ない場合には，大変良好な抽出結果を与える．

動的輪郭モデルを用いて，実画像から領域抽出を行った例を図 2.2 に示す．(a) の入力画像に対して空間微分を行った結果が (b) のエッジ画像である．(c) に示される初期閉曲線を式 (2.1) を最小化する方向へ変形して得られた結果が (d) である．この例では，対象領域 (ビール瓶) の輪郭線が鮮明であることに加え，背景に抽出を妨げるエッジが存在しないため，抽出結果は大変良好である．

しかし，動的輪郭モデルには以下の問題がある．(1) 初期輪郭の位置によって抽出結果が変化する．(2) 輪郭線の変形が，局所的な領域情報，すなわち式 (2.3) に示す輪郭線に沿った濃度勾配に依存して行われるため，ノイズ等の影響を受けやすい．このため，対象や背景が特徴量の異なる複数の領域から構成されている場合やノイズが存在する場合には対象の抽出が困難になる．対象の抽出が困難な例を図 2.3 に示す．前述の場合と同様に，(a) の入力画像に対して空間微分を行った結果が (b) であり，(c) の初期輪郭を変形して得られた抽出結果が (d) である．(b) と (d) から分かるように，対象領域 (ビール瓶) の輪郭エッジが途切れている部分では閉曲線の対象領域内部への入り込みが生じ，輪郭付近に疑似エッジが存在する部分では閉曲線の収縮が停止してしまい，対象領域全体としては不正確な抽出になっている．



(a) 原画像

(b) 微分画像



(c) 初期輪郭

(d) 抽出結果

図 2.2: 対象が良好に抽出できる例



(a) 原画像



(b) 微分画像



(c) 初期輪郭



(d) 抽出結果

図 2.3: 対象の抽出が困難な例

2.5 広い範囲の領域情報を用いた領域抽出

この問題に対処するためには、輪郭線付近の局所的情報だけでなく、より広い範囲の領域情報を抽出処理に導入することが必要である。この考えに基づいた領域抽出法としては、予め画像をクラスタリングし、得られた小領域の集合に対し動的輪郭モデルを適用する手法 [4] や、画像内に多数の小領域を設定し、MDL [5] に基づき成長・競合させることで対象領域を抽出する手法 [6] 等が提案されている。以下でこれらの手法の概要と問題点について述べる。

2.5.1 クラスタリングと動的輪郭モデルによる領域抽出

栄藤らは、領域の混合密度記述 [26] を求めた後に、動的輪郭モデルを適用して領域抽出を行う方法 [4] を提案した。

まず入力画像は、図 2.4(b) に示すように、K 平均法にクラスの分割と統合処理を組み合わせた ISODATA 法 [27] によりクラスタリング処理される。分割と統合は AIC [28] に基づき行われる。ここで、各小領域内では特徴量が正規分布に従うと仮定し、各小領域の分布パラメータを算出して、領域全体を混合密度として記述する。

次に (c) に示すように対象領域の周囲に初期輪郭線を設定し、クラスタリングした各小領域について、閉曲線の内部に属するものは対象領域、外部に属するものは背景とする。そのうえで、閉曲線の各制御点の特徴量に関する、対象領域と背景領域に対する尤度を求め、これらが均衡する位置へ各制御点を移動する。こうして輪郭モデルの変形が行われ、対象領域が抽出される。

2.5.2 小領域の成長と競合による領域抽出

Zhu らは、図 2.5(b) に示すように、画像全体に多数の小領域を手動で設定し、(c) に示すように、これらの小領域が MDL [5] に基づき成長と競合を行うことで領域分割を行う手法 [6] を提案した。この手法は、画像中に多くの種領域を設定するために、広域的な領域情報を領域抽出の処理に反映することができ、対象や背景が複数の領域から構成されている場合にも有効である。

2.6 問題点

前述のいずれの手法も，対象や背景が複数の領域から構成されている場合にも，対象を抽出できる手法である．

しかし，前者に関しては，動的輪郭モデルによる抽出とは別に，予め画像全体に対してクラスタリング処理を行う必要があるという問題がある．また後者に関しても，多くの小領域を手動で設定する必要があることに加えて，初期領域の位置が変化すると抽出結果が変化してしまうことや，対象を，滑らかな輪郭線を持つ領域として抽出できない等の問題が存在する．

このように，対象や背景が複数の領域から構成される場合の領域抽出は，難しい問題であるため，特別な前処理や初期設定を行わずに，安定して対象領域を抽出できる手法は現在のところ報告されていない．

2.7 まとめ

本章では，まず動的輪郭モデルの原理について述べるとともに，従来研究の紹介をした．

次に動的輪郭モデルは有効な領域抽出法であるが，局所的な領域情報に依存して領域抽出を行うため，対象や背景が複数の領域から構成されている場合には正確な領域抽出が困難になるという問題点を指摘した．

そしてこの問題に対処するためには，広域的な領域情報を抽出処理に取り込む必要があることについて述べ，この方針に基づいて行われた従来研究を紹介した．




図 2.4: クラスタリングを用いた手法




図 2.5: 小領域の成長と競合による手法

第 3 章

複数の動的輪郭モデルの競合による領域抽出

3.1 はじめに

本研究では，広い範囲の領域情報を反映した領域抽出法として，複数の動的輪郭モデルの競合による領域抽出を提案する．

本手法では，各閉曲線の変形に特徴量に関する尤度比を導入し，各閉曲線内部とその隣接領域内部の領域情報を抽出処理に反映させる．さらに，複数の閉曲線同士が競合することで，各々の閉曲線の変形処理に領域全体の情報を反映させる．これにより，従来の閉曲線に沿った局所的な領域情報に加えて，より広い範囲の領域情報が各閉曲線の変形処理に反映されることになる．

本手法において，まず使用者は複数の初期閉曲線を設定するために，適当な初期曲線を対象領域及び背景領域に配置する．次に各曲線を分割し，各曲線片を核とする閉曲線を生成する．各閉曲線について，閉曲線内の領域では特徴量が正規分布に従い，全領域に対する特徴量の分布は混合分布で表されると仮定し，閉曲線の内部領域の特徴量分布を推定する．推定された分布パラメータを基に，Fisher の線形識別法により任意の 2 領域の識別に適した特徴空間内での軸を決定する．この軸上での領域間の対数尤度比に基づき各閉曲線を膨張・競合させ，分布パラメータの推定値を逐次更新し，最終的に複数の領域の集合として対象領域の抽出を行う．

図 3.1 に本手法の処理の流れを示す．初期曲線の設定から領域抽出に至る過程は次の通りである．

STEP 1 初期曲線の設定・特徴量に基づく分割

STEP 2 初期閉曲線の生成

- (a) 混合分布パラメータの算出
- (b) Fisher の線形識別法による射影軸の算出

STEP 3 閉曲線の膨張

STEP 4 交差判定

STEP 5 境界の生成

STEP 6 対数尤度比による競合

- (a) 混合分布パラメータの更新
- (b) Fisher の線形識別法による射影軸の更新
- (c) STEP 3 ~ STEP 6 の反復

STEP 7 抽出終了

次節以降で各処理の詳細について述べる．




図 3.1: 処理の流れ

3.2 初期閉曲線の生成

3.2.1 曲線の設定と特徴量の取得

対象領域の抽出に適した混合分布パラメータを算出するためには、対象領域と背景領域の特徴をできるだけ正確に反映した標本点を選択することが重要である。このためには、対象領域と背景領域を特徴量が均一な領域に分割して、各領域ごとにパラメータを求めれば良い。しかし複数の閉曲線を適切な位置に手動で配置することは大変な労力を要するうえに、各領域に正確に閉曲線を配置することは領域抽出そのものを行うこととなる。本研究では、この問題に対処するために、使用者が与えた初期曲線を分割し、これを核とする閉曲線を生成することで、パラメータ算出に適した位置に初期閉曲線を配置する手法を提案する。

図 3.1(b) に示すように、使用者はまず、対象領域及び背景領域に曲線を設定する。次に各曲線に沿って画像の特徴量を取得し、主成分分析 [27] によって決定される特徴量の分散が最大になる特徴空間内の軸へ、全標本点を射影する。 x を標本点の n 次元特徴ベクトルとすると、各標本点は式 (3.1) により射影される。

$$z = Lx \quad (3.1)$$

$$L = (l_1, l_2, \dots, l_n)^t$$

ただし、 $l_1, l_2, \dots, l_n$ は n 次元の特徴量に関する共分散行列の固有値 $\lambda_1, \lambda_2, \dots, \lambda_n$ ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$) に対応する固有ベクトルを表す。この変換により得られる n 次元ベクトル z の第一成分 (第一主成分) を、初期曲線に沿った画像特徴量とする。主成分分析の第一主成分は、曲線に沿った特徴量の大局的な変動を表すので、ノイズ等による特徴量の細かな変動が曲線の分割結果に及ぼす影響を軽減することができる。

3.2.2 判別基準に基づく曲線分割

対象領域を抽出しやすい混合分布パラメータを得るためには、各閉曲線内部の特徴量の分散が小さく、特徴量の平均は分離していることが望ましい。そこで、本手法では、分割後に線分間の特徴量の分離度が最大となるように、大津の判別基準 [29] [30] に基づき初期曲線の分割点を決定する。

いま、式 (3.2) に示すように、長さ L の曲線を $M - 1$ 個の分割点 $k_i (i = 1, \dots, M - 1)$ で M 個の線分に分割する場合を考える。

$$1 \leq k_1 \leq k_2 \leq \dots \leq k_{M-1} < L \quad (3.2)$$

この場合，クラス（線分）間分散 σ_B^2 は，式（3.3）から求めることができる．

$$\sigma_B^2(k_1, \dots, k_{M-1}) = \sum_{j=1}^M \omega_j \mu_j - \mu_T^2 \quad (3.3)$$

ただし， ω_j は第 j 線分長が曲線全体の長さに占める割合を， μ_j は第 j 線分の特徴量の平均を表す． μ_T は，曲線全体における特徴量の平均であり，曲線の分割点には依存しない．そこで， σ_B^2 を評価する代わりに，式（3.4）で表される ρ_M を評価関数として用いる．

$$\rho_M(k_1, \dots, k_{M-1}) = \sum_{j=1}^M \omega_j \mu_j \quad (3.4)$$

ρ_M を最大とする分割点を総当りで探索すると，計算量は $O(L^M)$ となり分割数が増加すると探索すべき総数が急増する．しかし，この問題を式（3.5）～（3.7）のような動的計画法の問題に帰着させることで，探索の計算量を $O(ML^2)$ に削減できる．

$$\rho_M^*(L) = \max_{M-1 \leq k_{M-1} \leq L} [\rho_{M-1}^*(k_{M-1}) + g_L(k_{M-1})] \quad (3.5)$$

$$g_L(k) = \omega_M \mu_M^2 = \frac{[\mu(L) - \mu(k)]^2}{\omega(L) - \omega(k)} \quad (3.6)$$


$$\rho_1^*(k) = \omega_1 \mu_1^2 = \frac{\mu(k)^2}{\omega(k)} \quad (3.7)$$

ここで， $\mu(k)$ ， $\omega(k)$ は，初期曲線の始点から長さ k までの範囲における特徴量の平均と分散を表す．

使用者が指定した分割数に各曲線を分割した後，図 3.1 の (c) に示すように各曲線片を一定の幅の閉曲線に膨張させ，これを領域抽出のための初期閉曲線とする．閉曲線の幅は抽出する対象の大きさに応じて使用者が決定する．


本手法を実画像に適用して，初期閉曲線を生成した例を図 3.2 に示す．(a) が入力画像で抽出対象は黄色と濃紺色の部分から構成されるバスケットボールである．(b) にフリーハンドで設定した初期曲線を示す．曲線の端点 A から B までの特徴量 (R,G,B 各 256 階調) と第一主成分に関する画像の断面を図 3.3 に示す．この図から，主成分分析を行うことにより，元の特徴量が，より線分間の分散の大きい値に変換されていることが分かる．分割数を 4 に設定した場合，分割点 $k_i (i = 1, 2, 3)$ は，図 3.3 の $\uparrow$ で示される位置になる．これらの分割点は，実際の画像中では，図 3.2 (c) の '□' で示す位置に対応する．

この結果から，視覚的にも適切な位置で曲線の分割が行われていることが分かる．最後に各曲線片を幅 8 画素の閉曲線に膨張させた様子を図 3.2(d) に示す．



(a) 原画像

(b) 初期曲線



(c) 分割結果

(d) 初期閉曲線

図 3.2: 初期閉曲線の生成




図 3.3: 曲線に沿った画像の断面

3.3 各領域における特徴量の分布推定

3.3.1 混合分布

画像中に複数の領域を設定し、各領域における特徴量の分布を推定するために、各閉曲線の内部領域で特徴量の分布が正規分布に従うと仮定し、領域全体における特徴量の分布を式 (3.8) のような各領域の密度関数の荷重和 (混合分布) で表現する。

$$p(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \sum_{i=1}^k \xi_i p(\mathbf{x}; \boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i) \quad (3.8)$$

ここで、 k は領域数を、 $\mathbf{x}$ は n 次元特徴ベクトルを、 $\boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i, p(\mathbf{x}; \boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i)$ は領域 i における特徴ベクトルの平均、共分散行列、確率密度関数を各々表す。また、 ξ_i は領域 i に対する重み確率を表す。

3.3.2 EM アルゴリズムによる混合分布パラメータの算出

混合分布のパラメータを推定するためには、不完全データからの最尤推定法である EM アルゴリズム [31] [32] [33] を用いる。EM アルゴリズムは次に示す E-step と M-step から構成される。以下、 $\mathbf{x}$ で特徴ベクトルを、 z で $\mathbf{x}$ が属する領域番号を、 $\boldsymbol{\theta}^{(t)}$ で反復計算 t 回目での密度関数のパラメータを表す。

E-step

$(\mathbf{x}, z)$ の対数尤度の条件付き期待値を計算する。

$$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(t)}) = E[\log p(\mathbf{x}, z; \boldsymbol{\theta}) | \mathbf{x}, \boldsymbol{\theta}^{(t)}]$$

M-step

$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(t)})$ を最大とする $\boldsymbol{\theta}$ を $\boldsymbol{\theta}^{(t+1)}$ とする。

正規混合分布の場合は次の手順となる。

(1) $\mathbf{x}_j$ が領域 z に含まれる条件付き確率を計算。

$$\begin{aligned} w_{zj}^{(t)} &:= p(z | \mathbf{x}_j; \boldsymbol{\theta}^{(t)}) \\ &= \frac{\xi_z^{(t)} p(\mathbf{x}_j; \boldsymbol{\mu}_z^{(t)}, \boldsymbol{\Sigma}_z^{(t)})}{\sum_{i=1}^k \xi_i^{(t)} p(\mathbf{x}_j; \boldsymbol{\mu}_i^{(t)}, \boldsymbol{\Sigma}_i^{(t)})} \end{aligned} \quad (3.9)$$

(2) 領域 i の重み確率 ξ_i を次式で更新。

$$\xi_i^{(t+1)} = \frac{1}{N} \sum_{j=1}^N w_{ij}^{(t)} \quad (3.10)$$

(3) 各領域のパラメータを次式で更新．

$$\boldsymbol{\mu}_i^{(t+1)} = \frac{1}{N_{\xi_i^{(t+1)}}} \sum_{j=1}^N w_{ij}^{(t)} \boldsymbol{x}_j \quad (3.11)$$

$$\boldsymbol{\Sigma}_i^{(t+1)} = \frac{1}{N_{\xi_i^{(t+1)}}} \sum_{j=1}^N w_{ij}^{(t)} (\boldsymbol{x}_j - \boldsymbol{\mu}_i^{(t+1)})(\boldsymbol{x}_j - \boldsymbol{\mu}_i^{(t+1)})^t \quad (3.12)$$

ただし， N は全標本数を， $\boldsymbol{\mu}_i^{(t)}$ ， $\boldsymbol{\Sigma}_i^{(t)}$ は反復計算 t 回目での領域 i における特徴ベクトルの平均および共分散行列を表す．EM アルゴリズムで得られる解は局所最適なものではあるが，解の収束性が保証されているので，閉曲線が膨張・競合する過程で式 (3.9) ~ (3.12) の計算を各パラメータが収束するまで，または指定回数行うことで各抽出段階での準最適な混合分布パラメータを求めることができる．

3.3.3 Fisher の線形識別法による射影軸の決定

EM アルゴリズムにより複数の領域全体を表現する分布パラメータが得られた．次に，任意の 2 領域を識別するために，2 領域間の特徴量について領域間の分散が大きく領域内の分散が小さくなる射影軸を Fisher の線形識別法 [26] で決定する．

$\boldsymbol{x}$ を n 次元特徴ベクトル， $\boldsymbol{\omega}$ を重みベクトルとしたとき，式 (3.13) に示す評価関数を定め， $J(\boldsymbol{\omega})$ を最大にする $\boldsymbol{\omega}$ を Lagrange の未定乗数法より求めると，式 (3.14) となる．

$$J(\boldsymbol{\omega}) = \frac{\boldsymbol{\omega}^t \hat{\boldsymbol{\Sigma}}_B \boldsymbol{\omega}}{\boldsymbol{\omega}^t \hat{\boldsymbol{\Sigma}}_w \boldsymbol{\omega}} \quad (3.13)$$

$$\boldsymbol{\omega} = \hat{\boldsymbol{\Sigma}}_w^{-1} (\bar{\boldsymbol{x}}_1 - \bar{\boldsymbol{x}}_2) \quad (3.14)$$

$$\hat{\boldsymbol{\Sigma}}_B = (\bar{\boldsymbol{x}}_1 - \bar{\boldsymbol{x}}_2)(\bar{\boldsymbol{x}}_1 - \bar{\boldsymbol{x}}_2)^t$$

$$\hat{\boldsymbol{\Sigma}}_w = \frac{1}{N} (N_1 \hat{\boldsymbol{\Sigma}}_1 + N_2 \hat{\boldsymbol{\Sigma}}_2)$$

ここで， $\bar{\boldsymbol{x}}_i$ ， $\hat{\boldsymbol{\Sigma}}_i$ ， N_i は，領域 i における特徴ベクトルの平均，標本共分散行列および標本数を表し， N は全標本数を示す．

このとき n 次元特徴ベクトル $\boldsymbol{x}$ は式 (3.15) により射影され，図 3.4 に示す 2 領域の識別に適した射影軸が求められる．

$$y = \boldsymbol{\omega}^t \boldsymbol{x} \quad (3.15)$$




図 3.4: Fisher の線形識別法による射影軸の決定

3.4 領域競合

3.4.1 閉曲線の膨張

初期曲線の分割結果から生成された閉曲線は，式 (3.16) によって定義される閉曲線内部の面積 [34] を増加させる方向へと膨張していく．ここで $x_s(s)$, $y_s(s)$ は x と y の s に関する 1 次微分を， κ は重み係数を表す．

$$E_{area} = \frac{1}{2} \kappa \int_0^1 ds (x(s)y_s(s) - y(s)x_s(s)) \quad (3.16)$$

また面積に加え，閉曲線上の各制御点は式 (3.17) で定義する尤度比も増加する方向へと移動する．ここで $I(\mathbf{v}(s))$ は点 $\mathbf{v}(s)$ における特徴量を， μ , σ は領域の特徴量の平均と標準偏差を， p は領域における特徴量の尤度を， η は正の重み係数をそれぞれ表す．

$$E_{image}(\mathbf{v}(s)) = -\eta \log \frac{p(I(\mathbf{v}(s)))}{p(I_{3\sigma})} \quad (3.17)$$

$$I_{3\sigma} = \mu + 3\sigma$$

形状に関するエネルギーは，式 (3.18) で定義する． $\mathbf{v}_s(s)$ は 1 次微分を， $\mathbf{v}_{ss}(s)$ は 2 次微分を表す．

$$E_{int}(\mathbf{v}(s)) = \frac{1}{2} \left\{ \alpha |\mathbf{v}_s(s)|^2 + \beta |\mathbf{v}_{ss}(s)|^2 \right\} \quad (3.18)$$

3.4.2 交差判定と境界の生成

膨張過程で互いに交差が生じた場合，図 3.1 の (e) , (f) に示すように新たな境界を生成する．交差判定は，式 (3.19) で示される方程式が解を持つか否かで行う．

$$p(\mathbf{v}_{i+1} - \mathbf{v}_i) + \mathbf{v}_i = q(\mathbf{v}_{j+1} - \mathbf{v}_j) + \mathbf{v}_j \quad (3.19)$$

$$(0 \leq p \leq 1, 0 \leq q \leq 1)$$

ここで $\mathbf{v}_i$ は第 m 閉曲線の第 i 制御点を， $\mathbf{v}_j$ は第 n 閉曲線の第 j 制御点を表す．交点が発見されたならば交点間に新たな制御点を補間して，境界を生成する．

3.4.3 対数尤度比に基づく競合

領域 i の閉曲線が，領域 j の閉曲線と接する部分を変形するための，画像エネルギーは，式 (3.20) で定義される．

$$E_{image}(\mathbf{v}(s)) = -\frac{1}{2} \gamma |\nabla I(\mathbf{v}(s))|^2 - \eta \log \frac{p_i(I(\mathbf{v}(s)))}{p_j(I(\mathbf{v}(s)))} \quad (3.20)$$

$I(v(s))$ で点 $v(s)$ における特徴量を， p_i で領域 i における特徴量の尤度を表すと，第 1 項は特徴量の勾配を第 2 項は対数尤度比を各々表すことになる．ここで γ, η は，各項に対する正の重み係数である．前述の EM アルゴリズムにより求めた各領域内の特徴量パラメータを，Fisher の線形識別法に適用し，求められた射影軸上で対数尤度比を決定する．対数尤度比については，以下の関係が成り立つ．

$$\log \frac{p_i(I(v(s)))}{p_j(I(v(s)))} \geq 0 \quad \Rightarrow \quad v(s) \in R_i$$

この状況を図 3.5 に示す．




図 3.5: 対数尤度比による競合

また対数尤度比の符号に合わせて式 (3.16) の面積項の係数の符号を式 (3.21) のように切り替えることで，各閉曲線に対数尤度比が正の領域では膨張し，負の領域では収縮する傾向を持たせる．ここで a は正の定数を表す．

$$\kappa = \begin{cases} a & \text{if } \log \frac{p_i(I(v(s)))}{p_j(I(v(s)))} \geq 0 \\ -a & \text{if } \log \frac{p_i(I(v(s)))}{p_j(I(v(s)))} < 0 \end{cases} \quad (3.21)$$

式 (3.20)，式 (3.18) 及び式 (3.16) を式 (3.22) へ代入したものを全体のエネルギーとし，閉曲線上の各制御点の 8 近傍を探索し，最急降下法を用いて，エネルギーを最小化する方向へ制御点を移動させていくことで領域競合が実現される．

$$E_{ACM} = \int_0^1 \{E_{int}(\mathbf{v}(s)) + E_{image}(\mathbf{v}(s)) + E_{area}(\mathbf{v}(s))\} ds \quad (3.22)$$

混合分布パラメータを推定した後，Fisher の線形識別法で射影軸を決定し，その射影軸上で，対数尤度比に基づき各閉曲線が膨張と競合を行うという一連の処理を，全閉曲線の動きが収束するまで反復することで，対象領域内部に設定された初期曲線から生成される複数領域の集合として，対象領域が抽出される．

3.5 まとめ

本章では、従来の動的輪郭モデルが輪郭線に沿った局所的な領域情報に基づいて領域抽出を行うため、対象や背景が特徴量の異なる複数の領域から構成されている場合には、正確に対象領域の抽出が行えないという問題点を指摘した．

そして、この問題に対処するために、複数の動的輪郭モデルを対象及び背景に設定し、各閉曲線を領域間の特徴量に関する対数尤度比に基づき競合させることで対象領域の抽出を行う手法を提案した．さらに、複数の閉曲線を手動で設定するための負担を軽減するために、対象及び背景に設定した任意の曲線群を判別基準に基づき分割し、各曲線片を核として初期閉曲線を生成する手法を提案した．

本手法は、対象領域を複数の小領域の集合として抽出するので、対象や背景が特徴量が異なる複数の領域から構成されている場合にも適用できる領域抽出法である．

第 4 章

領域抽出実験

4.1 はじめに

本章では，前章で提案した手法の有効性を検証するために行った領域抽出実験の結果を示す．はじめにシミュレーション画像を用いて，ノイズに対するロバスト性について提案手法と基本型の動的輪郭モデルで比較を行う．次に，対象領域が様々な状況にある実画像に対して，提案手法と基本型の動的輪郭モデルを用いて領域抽出を行い，両手法の比較を行う．

4.2 ノイズに対するロバスト性の評価

4.2.1 尤度比効果の検証

画像エネルギーに尤度比を用いることによるロバスト性の向上を検証するために，画像エネルギー関数として濃度勾配のみを用いた基本型の動的輪郭モデルと，尤度比および濃度勾配を併用した本手法で用いる動的輪郭モデルについて領域抽出精度の比較を行った．

実験に使用した原画像を図 4.1 に示す．画像サイズは 255×255 画素，対象領域は中心 $(127, 127)$ ，半径 60 の円である．画像特徴量は濃淡値 (256 階調) で，対象と背景の濃淡値はそれぞれ平均 150，分散 25 および平均 100，分散 25 の正規分布に従っている．抽出実験には，図 4.1 の画像に対し，平均 0，標準偏差を 0 から 20 まで変化させたガウスノイズを付加したものをを用いた．初期閉曲線は，図 4.1 中の白線で示すように，中心 $(127, 127)$ ，半径 45 の円とした．

エネルギー関数の係数は実験的に決定したものをを用いた．各手法で使用した係数の値

を表 4.1 と表 4.2 に示す．ここで σ はノイズの標準偏差を， α, β は式 (3.18) の， κ は式 (3.16) の， γ, η は式 (3.20) の係数を表す．

抽出精度の評価基準として，対象領域の輪郭に関する基準と対象領域の面積に関する基準を設定した．輪郭の抽出精度は， $R_{edge} = N_1/N_2$ で定義する．ここで N_1 は対象領域の半径を r として $[r-1, r+1]$ の範囲入った制御点数を， N_2 は全制御点数を表す [21]．面積の抽出精度は， $R_{area} = N(A \cap B)/N(A \cup B)$ で定義する．ここで $N(Z)$ は領域 Z 内の画素数を， A は対象領域を， B は抽出領域を表す．

図 4.2 に各手法の抽出結果を，図 4.3 に輪郭と面積基準の抽出精度を示す．抽出精度は輪郭，面積基準ともに提案手法が基本型を上回っている．特に面積基準については，ノイズの偏差が 6 を越えた辺りから手法間の差が顕著になる．これは，提案手法では尤度比項の働きにより輪郭線がノイズに捕まりにくくなるためと考えられる．

σ	0	2	4	6	8	10	12	14	16	18	20
γ	2.00	1.10	0.50	0.25	0.24	0.19	0.16	0.14	0.14	0.18	0.18
α, β, κ	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00

表 4.1: 実験に用いた係数 (勾配)

σ	0	2	4	6	8	10	12	14	16	18	20
γ	1.80	1.10	0.50	0.20	0.20	0.16	0.14	0.12	0.13	0.00	0.00
$\alpha, \beta, \kappa, \eta$	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00

表 4.2: 実験に用いた係数 (勾配+尤度比)




图 4.1: 初期閉曲線






图 4.2: 抽出結果 (上段:濃度勾配, 下段:濃度勾配 + 尤度比)



輪郭線基準



面積基準

圖 4.3: 抽出精度 (濃度勾配 vs 濃度勾配+尤度比)

4.2.2 複数領域の競合効果の検証

画像エネルギーに尤度比項と濃度勾配項を持つ動的輪郭モデルを単体で用いた場合と複数で競合させた場合の抽出精度を比較した。

実験の原画像を図 4.4 に示す。画像サイズは 255×255 画素，対象領域は，中心 $(127, 127)$ ，長径 80，短径 60 の楕円である。画像特徴量は濃淡値 (256 階調) で，対象領域の濃淡値は 50 ~ 150 まで，背景領域は 0 ~ 180 まで変化している。単体の初期閉曲線は図 4.4 中の白線で示す中心 $(127, 127)$ ，長径 65，短径 45 の楕円とした。複数の動的輪郭モデルを用いる場合については，単体の閉曲線を 2 等分したものに加え，その周辺に 4 つの閉曲線を配置した。各手法で使用した係数値を表 4.3 と表 4.4 に示す。抽出精度の評価は前述の実験と同じく面積に関する基準と輪郭線に関する基準を用いた。ただし輪郭線基準は，真の輪郭線から ± 1 画素の範囲に入った制御点数に基づき算出した。また複数の動的輪郭モデルを用いた場合の輪郭線基準の抽出精度は，対象内部の 2 つの閉曲線から両者の境界部分を除いた部分に関して計算を行った。


各手法の抽出結果を図 4.5 に，抽出精度を図 4.6 に示す。抽出精度は，輪郭基準，面積基準ともに複数の動的輪郭モデルを用いた場合が単体の場合を上回っている。これより，提案手法は単体での抽出法に比べて，ノイズに対してロバストな抽出であることが分かる。

σ	0	2	4	6	8	10	12	14	16	18	20
γ	2.00	1.10	0.50	0.35	0.30	0.18	0.17	0.14	0.15	0.16	0.16
$\alpha, \beta, \kappa, \eta$	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00

表 4.3: 実験に用いた係数 (単体)

σ	0	2	4	6	8	10	12	14	16	18	20
γ	3.50	1.40	0.50	0.35	0.16	0.15	0.13	0.10	0.04	0.04	0.04
$\alpha, \beta, \kappa, \eta$	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00


表 4.4: 実験に用いた係数 (複数)



单体

複数

图 4.4: 初期閉曲線




$\sigma = 4$


$\sigma = 12$

$\sigma = 20$

图 4.5: 抽出結果 (上段:单体, 下段:複数)



輪郭線基準



面積基準

図 4.6: 抽出精度 (単体 vs 複数)

4.3 実画像からの領域抽出

前述の2つの実験から、尤度比と複数の動的輪郭モデルの競合を用いることによりノイズに対するロバスト性が向上することが確認された。次に基本型の動的輪郭モデル及び本手法を実画像に適用して領域抽出実験を行い、両手法の実画像に対する有効性を比較した。実験には以下の場合に相当する実画像を使用した。(1) 対象領域が特徴量の異なる複数の領域からなる場合、(2) 対象領域が複雑な形状をしている場合、(3) 背景領域が特徴量の異なる複数の領域からなる場合、(4) 対象及び背景がテクスチャ領域からなる場合。

4.3.1 基本モデルによる抽出

画像エネルギー関数に濃度勾配だけを用いる動的輪郭モデルを単体で使用して抽出実験を行った。ただし収縮の傾向を持たせるためにエネルギー関数に面積項は使用している。

実験結果を、図 4.7 から図 4.10 に示す。各図の (a) に原画像を、(b) にエッジ画像を、(c) に初期閉曲線を、(d) に抽出結果をそれぞれ示す。

エッジ検出には、表 4.5 に示す 3×3 の Sobel フィルタを使用した。エネルギー関数の係数は実験的に求めたものを使用した。各係数の値を表 4.6 に示す。ここで、 α 、 β は式 (2.2) の、 κ は式 (3.16) の、 γ は式 (2.3) の係数を表す。

図 4.7 は、対象領域が特徴量の異なる複数の領域からなる場合として、バスケットボールに対応する領域を抽出した様子である。この例では、輪郭エッジが鮮明に検出できたので、(d) に示すように抽出結果は良好である。ただし、右上のエッジが途切れている部分でやや不正確な抽出が見られる。

図 4.8 は、対象領域が複雑な形状をしている場合として、手に対応する領域を抽出した様子である。この例でも、全体の輪郭エッジは鮮明なので抽出結果は良好である。ただし、薬指と中指の間の鋭角部分が抽出できなかった。これは、輪郭線が一部途切れているために閉曲線が内部まで入り込んでしまうことと、形状エネルギーの2次微分項の働きにより閉曲線が鋭角を検出しにくいためと考えられる。


図 4.9 は背景領域が特徴量の異なる複数の領域からなる場合として、バナナの房に対応する領域を抽出した例である。また、図 4.10 は対象及び背景がテクスチャ領域からなる場合として、シマウマに対応する領域を抽出した例である。これら2つの場合は、対象の輪郭付近に多くの疑似エッジが存在して初期閉曲線が対象の輪郭線に収束しないため、図 4.9 の右下の部分や図 4.10 の下の部分で不正確な抽出になった。

$\partial f / \partial x$			$\partial f / \partial y$		
-1	0	1	-1	-2	-1
-2	0	2	0	0	0
-1	0	1	1	2	1

表 4.5: Sobel フィルタ


	α	β	κ	γ
ボール	1.0	1.0	1.0	1.0
手	1.0	1.0	1.2	1.0
バナナ	1.0	1.0	1.5	0.5
シマウマ	1.0	1.0	0.8	0.2

表 4.6: 実験に用いた係数 (基本モデル)



(a) 原画像

(b) 微分画像




(c) 初期閉曲線

(d) 抽出結果

図 4.7: 複数の領域からなる対象 (ボール, 基本モデル)



(a) 原画像



(b) 微分画像



(c) 初期閉曲線



(d) 抽出結果

図 4.8: 複雑な形状 (手, 基本モデル)



(a) 原画像

(b) 微分画像



(c) 初期閉曲線


(d) 抽出結果

図 4.9: 複数の領域からなる背景 (バナナ, 基本モデル)



(a) 原画像

(b) 微分画像



(c) 初期閉曲線

(d) 抽出結果

図 4.10: テクスチャ(シマウマ, 基本モデル)

4.3.2 提案手法による抽出

提案手法を用いて抽出を行った結果を図 4.11 から図 4.14 に示す．各図において (a) は初期曲線，(b) は初期閉曲線，(c) は領域競合を行っている状態，(d) は抽出結果である．特徴量は R,G,B 各 256 階調を用い，エッジの検出には前述の実験と同じ Sobel フィルタを使用した．閉曲線内の特徴量の分布パラメータは抽出処理 5 回につき 1 回の頻度で更新した．実験で使用したエネルギー関数の係数は実験的に決定したものをを用いた．各係数の値を表 4.7 に示す．ここで α , β は式 (2.2) の， κ は式 (3.16) の， γ , η は式 (3.20) の係数を表す．

図 4.11 は黄色と濃紺色の部分を持つバスケットボールに対応する領域を抽出した結果である．初期曲線は，基本モデルの実験で使用した初期閉曲線に対して，1 本の曲線を対象領域内に加えたものをを用いた．この例では，対象領域と背景領域間で特徴量の分離度が大きく対象領域の輪郭線も鮮明なので，領域競合によって良好な抽出結果が得られた．

図 4.12 は手に対応する領域を抽出した結果である．初期曲線は，基本モデルの実験で使用した初期閉曲線とほぼ同じ形状のものに 2 本の曲線を対象領域内に加えたものをを用いた．この場合は対象領域内部が複雑な形状をしているために，対象領域内部は，視覚的に意味のある領域分割にはなっていない．しかし対象領域と背景領域の尤度比が増加するように内部領域の分割が行われるため，対象領域全体の抽出は良好な結果である．

背景が特徴量の異なる複数の領域からなる場合を図 4.13 に示す．対象領域はバナナの房であり，背景は複数の領域から構成されている．初期曲線は，基本モデルの実験で使用した初期閉曲線に対して，2 本の曲線を対象領域内に加えたものをを用いた．この場合も対象領域内部は視覚的な分割結果と一致しないが，内部領域と背景領域の閉曲線の競合で房全体は良好な抽出結果となっている．ただし，画面下の房に影がかかっている部分で，対象と背景の特徴量の分離度が小さいためにやや不正確な抽出になっている．

テクスチャ領域の抽出例を図 4.14 に示す．対象領域は白と黒の模様を持つシマウマで，背景領域は上半分が森，下半分が草原である．初期曲線は，基本モデルの実験で使用した初期閉曲線に対して，5 本の曲線を加えたものをを用いた．この例ではシマウマの背中部分でやや不正確な抽出が見られるが，対象領域全体と背景領域の特徴量は分離度が大きいために全体の抽出結果は良好である．

	α	β	κ	γ	η
ボール	1.0	1.0	1.0	0.2	1.0
手	1.0	0.5	1.5	0.5	1.0
バナナ	1.0	1.0	1.5	0.5	1.5
シマウマ	1.0	1.0	0.8	0.2	1.0

表 4.7: 実験に用いた係数 (提案手法)







図 4.11: 複数の領域からなる対象 (ボール, 提案手法)



(a) 初期曲線



(b) 初期閉曲線




(c) 領域競合



(d) 抽出結果

図 4.12: 複雑な形状 (手, 提案手法)



(a) 初期曲線



(b) 初期閉曲線




(c) 領域競合




(d) 抽出結果

図 4.13: 複数の領域からなる背景 (バナナ, 提案手法)



(a) 初期曲線

(b) 初期閉曲線



(c) 領域競合

(d) 抽出結果

図 4.14: テクスチャ領域 (シマウマ, 提案手法)

4.4 まとめ

本章では提案手法の有効性について検証を行うための実験を行った。シミュレーション画像を用いた実験では、提案手法と基本型の動的輪郭モデルのノイズに対するロバスト性を比較した。まずエネルギー関数に尤度比を用いる提案手法と、これを用いない基本モデルで抽出精度を比較した。次に尤度比を用いる動的輪郭モデルを単体で使用して領域抽出を行う場合と複数で競合させて抽出を行う場合とで精度の比較を行った。実験の結果、画像エネルギー関数に尤度比を導入することでノイズに対するロバスト性が向上することが確認された。また複数の動的輪郭モデルの競合を導入することでもノイズに対するロバスト性が向上することが確認できた。これらの結果から、提案手法は、基本型の動的輪郭モデルよりもロバストな抽出法であることが確認された。

また実画像を用いた実験では、各種の画像に対して提案手法と基本モデルを用いて抽出実験を行った。その結果、対象領域の輪郭線が鮮明で輪郭線付近に疑似エッジが存在しない場合については、両手法とも良好な抽出結果を得た。提案手法はさらに、基本モデルでは正確な領域抽出が困難な、背景が複数の領域から構成されている場合や、背景と対象がテクスチャ領域からなる場合についても良好な抽出結果を得ることができた。

エネルギー関数の各係数については、現状では実験的に決めざるをえないが、今回行った実験の範囲では、各係数の重み比率が大きく変化しない範囲内での係数変更ならば抽出結果に大きな差異は見られなかった。したがって提案手法は係数の変更に対してある程度のロバスト性を有していると考えられる。

以上の結果から、提案手法は基本モデルに比べてよりノイズに対してロバストで、対象や背景が複数の領域から構成される場合にも適用可能な領域抽出法であることが確認できた。

第 5 章

結論

本論文では、複数の動的輪郭モデルが領域競合することにより対象領域の抽出を行う手法を提案した。また初期閉曲線の配置法についても新たな手法を提案し、初期閉曲線の設定に伴う負担を軽減した。シミュレーション画像を用いた実験では、本手法は、動的輪郭モデルを単体で用いた領域抽出法よりもノイズに対してロバストな抽出であることが確認された。また実画像を用いた実験では、対象領域が複雑な背景を持つ場合やテクスチャ特徴を持つ場合にも本手法は良好な抽出結果が得られた。

今後の課題としては、まず初期閉曲線の数を自動的に決定する方法の検討が挙げられる。これは、統計的なモデルの選択基準である AIC 等の情報量基準に基づき、初期曲線の適切な分割数を決定することで対処できると考えられる。

また、エネルギー関数の重み係数の学習法あるいは推定法の検討がある。動的輪郭モデルの従来研究では、ほとんどの場合、係数の決定は実験的に行われているのが現状であり、これに対する有効な解決策が望まれている。本手法においては、各閉曲線内の特徴量が均一になるように複数の動的輪郭モデルを配置している。したがって、各領域の抽出結果の良否を、各領域の特徴量に関する平均値からの 2 乗誤差を用いて評価し、これを小さくする抽出結果が得られるように係数を更新することで、適切な重み係数の推定が行えると考えられる。

さらに、エネルギー関数に、形状に関する事前知識を埋め込む方法の検討が挙げられる。本手法は各領域間の尤度比に基づき各輪郭線の変形を行うため、対象と背景の特徴量の分離度が小さい場合には、対象を正確に抽出することが難しい。この問題に対処するためには、対象の形状に関する事前知識を簡単な幾何学的規則の集合としてモデルに与え、これに基づき閉曲線を変形する必要があると思われる。

謝辞

本研究を行なうにあたり，御指導，御鞭撻をいただいた北陸先端科学技術大学院大学 阿部 亨 助教授に心より厚くお礼申し上げます．

また，様々な面で御教授いただきました北陸先端科学技術大学院大学 堀口 進教授に深く感謝致します．

北陸先端科学技術大学院大学 石原 哉 助教授には，サブテーマで熱心に御指導いただき，深く感謝申し上げます．

北陸先端科学技術大学院大学 山森 一人 助手には，公私ともに様々な御指導をいただき，深く感謝申し上げます．

北陸先端科学技術大学院大学 林 亮子 助手には，多くの有益な御意見をいただき，深く感謝申し上げます．

また，日頃よりお世話になったマルチメディア統合講座の皆様に厚くお礼申し上げます．

最後に，大学院研修の機会を与えて下さいました，防衛庁 陸上幕僚監部 飯田重喜 2 等 陸佐 に厚くお礼申し上げます．

参考文献

- [1] M. Kass, A. Witkin and D. Terzopoulos, “Snakes: Active Contour Models”, International Journal of Computer Vision, Vol. 1, No. 3, pp. 321–331 (1988).
- [2] 美濃導彦, 天野晃, “Snakes: 現在・過去・未来”, 信学技法, PRMU97-184 (1997).
- [3] 松山隆司, 久野義徳, 井宮淳 (編), コンピュータビジョン: 技術評論と将来展望, 新技術コミュニケーションズ (1998).
- [4] 栄藤稔, 白井良明, 浅田稔, “クラスタリングから得られる領域の記述に基づく動的な輪郭抽出”, 信学論, Vol. J75-D-II, No. 7, pp. 1111–1119 (1992).
- [5] J. Rissanen, “A universal prior for integers and estimation by minimum description length”, The Annals of Statistics, Vol. 11, No. 2, pp. 416–431 (1983).
- [6] S. Zhu and A. Yuille, “Region Competition: Unifying Snakes, Region Growing, and Bayes/MDL for multiband Image Segmentation”, IEEE. Trans. Pattern Anal. Machine Intell., Vol. 18, No. 9, pp. 884–900 (1996).
- [7] 小川英光, パターン認識・理解の新たな展開 – 挑戦すべき課題 –, 電子情報通信学会 (1992).
- [8] R. Gonzalez and R. Woods, Digital Image Processing, Addison-Wesley Publishing Company (1993).
- [9] A. Blake and M. Isard, Active Contours, Springer (1998).
- [10] R. Ďurikovič, K. Kaneda and H. Yamashita, “Dynamic contour: a texture approach and contour operations”, The Visual Computer, Vol. 11, pp. 277–289 (1995).
- [11] J. Ivins and J. Porrill, “Active region models for segmenting textures and colours”, Image and Vision Computing, Vol. 13, No. 5, pp. 431–438 (1995).

- [12] K. Ngoi and J. Jia, “A new color image energy for active contours in natural scenes”, *Pattern Recognition Letters*, Vol. 17, pp. 1271–1277 (1996).
- [13] R. Romfard, “Region-Based Strategies for Active Contour Models”, *IJCV*, Vol. 13, No. 2, pp. 229–251 (1994).
- [14] T. McInerney and D. Terzopoulos, “Topologically adaptable snakes”, *5th International Conference on Computer Vision*, pp. 840–845 (1995).
- [15] 坂口俊文, 美濃導彦, 池田克夫, “圧力エネルギーを持つ SNAKES”, *信学春季全大* (1990), D-523.
- [16] 上田恭敬, 田中弘美, “領域のトポロジカルな構造抽出のための符号付き動的輪郭モデル”, *信学論*, Vol. J80-DII, No. 6, pp. 1398–1405 (1997).
- [17] B. Olstad and A. Torp, “Encoding of a priori Information in Active Contour Models”, *IEEE. Trans. Pattern Anal. Machine Intell.*, Vol. 18, No. 9, pp. 863–872 (1996).
- [18] 荒木昭一, 横矢直和, 岩佐英彦, 竹村治雄, “複数物体の抽出を目的とした交差判定により分裂する動的輪郭モデル”, *信学論*, Vol. J79-DII, No. 10, pp. 1704–1711 (1996).
- [19] D. Williams and M. Shah, “A Fast Algorithm for Active Contours and Curvature Estimation”, *Computer Vision Graphics and Image Processing*, Vol. 55, No. 1, pp. 14–26 (1992).
- [20] A. Amini, T. Weymouth and R. Jain, “Using Dynamic Programming for Solving Variational Programs in Vision”, *IEEE. Trans. Pattern Anal. Machine Intell.*, Vol. 12, No. 9, pp. 855–867 (1990).
- [21] 福井和広, “領域間の分離度に基づく物体輪郭抽出”, *信学論*, Vol. J80-DII, No. 6, pp. 1406–1414 (1997).
- [22] 荒木昭一, 横矢直和, 竹村治雄, “交差判定により分裂・統合する動的輪郭モデルによる複数物体の実時間追跡”, *信学論*, Vol. J80-DII, No. 11, pp. 2940–2948 (1997).
- [23] M. Dubuisson and A. Jain, “Contour Extraction of Moving Objects in Complex Outdoor Scenes”, *International Journal of Computer Vision*, Vol. 14, pp. 83–105 (1995).

- [24] F. Leymarie and M. Levine, “Tracking Deformable Objects in the Plane Using an Active Contour Model”, IEEE. Trans. Pattern Anal. Machine Intell., Vol. 15, No. 6, pp. 617–634 (1993).
- [25] C. Vieren, F. Cabestaing and J. Postaire, “Catching moving objects with snakes for motion tracking”, Pattern Recognition Letters, Vol. 16, pp. 679–685 (1995).
- [26] R. Duda and P. Hart, Pattern Classification and Scene Analysis, Wiley Interscience, N.Y. (1972).
- [27] 鳥脇純一郎, 認識工学 – パターン認識とその応用 –, コロナ社 (1992).
- [28] H. Akaike, “A New Look at the Statistical Model Identification”, IEEE Trans., Automat. Contr., Vol. AC-19, pp. 716–723 (1974).
- [29] 大津展之, “判別および最小 2 乗基準に基づく自動しきい値決定法”, 信学論, Vol. J63-DII, No. 4, pp. 349–356 (1980).
- [30] 大津展之, 栗田多喜夫, 関田巖, パターン認識 – 理論と応用 –, 朝倉書店 (1996).
- [31] A. Dempster, N. Laird and D. Rubin, “Maximum likelihood from incomplete data via the EM algorithm”, J.Royal Statist. Soc. Ser. B, Vol. 39, pp. 1–38 (1977).
- [32] M. Tanner, Tools for Statistical Inference, Springer-Verlag (1993).
- [33] 上田修功, 中野良平, “確率的アニーリング EM アルゴリズム”, 信学論, Vol. J80-DII, No. 1, pp. 267–276 (1997).
- [34] 坂口俊文, 大山公一, “面積項をもつスネーク”, 信学春季全大 (1991), D-555.

研究業績

松澤 悠樹，堀口 進，阿部 亨，“大局情報を利用した動的輪郭モデルによる領域抽出”，電気関係学会北陸支部連合大会，F-53，pp.357 (1998)．

松澤 悠樹，堀口 進，阿部 亨，“複数の競合する動的輪郭モデルによる領域抽出”，電子情報通信学会技術研究報告，PRMU98-183，pp.51–58 (1999)．

Yuki Matsuzawa, Susumu Horiguchi, and Toru Abe, “Region Extraction Using Competition of Multiple Active Contour Models,” IEEE International Conference on Image Processing (1999) (submitted).