

前景確率を考慮した楕円窓の最適切ではめに基づく アピアランスベース物体認識のための背景外乱除去

柴田悠太郎[†] 橋本学[†]

[†] 中京大学 情報理工部 〒470-0393 愛知県豊田市貝津町床立 101

E-mail: †{yshibata,mana}@isl.sist.chukyo-u.ac.jp

あらまし 本稿では、アピアランスベース物体認識において認識画像に予期しない背景が混入した場合でも照合精度を向上させる手法を提案する。画像に複数のプリミティブ形状を当てはめて対象物体領域を切り出し、外部領域を背景として除去する。さらに、多数の学習画像群から得られる前景確率を考慮することで楕円の当てはめを効率化する。プリミティブ形状として楕円を用い、さらに複数個用いることによって多様な形をもつ対象物体領域を近似できる。楕円の大きさや位置などの形状パラメータの決定を組み合わせ最適化問題と考え、遺伝的アルゴリズムを適用して効率的に実用解を探索する。これにより 1 枚の認識画像から背景に関する事前知識無しに安定した認識が可能となる。本手法をパラメトリック固有空間法に適用し、3 段階の複雑さを持つ各 180 枚の実画像を用いて性能を評価したところ、認識率が 67.8%~100.0%であり、本手法を適用しない場合よりも約 43%向上したことが確認できた。

キーワード プリミティブ図形, 楕円, 組み合わせ最適化, 遺伝的アルゴリズム, 固有空間, 前景確率

1. はじめに

工場の生産ラインでは更なる自動化が求められており、人間の視覚機能の一部を機械に置き換えようとする動きが加速している。ロボット視覚などにとって非常に重要な基本技術は 3 次元物体認識である。なかでも、入力された姿勢未知の対象物体の画像に対して、対象物体に関する多視点画像群と照合することで姿勢を認識するアピアランスベースの手法 [1] は、3 次元データの入力装置や特徴抽出が不要であり、実用的価値が高い。

このようなアピアランスベース手法に取り組んだものに、物体の 2 次元画像を線形結合によって表現し、エッジ位置等の特徴量を使用する手法 [2] や対象物体の 3 次元の見えの変化を効果的にグループ化して認識の効率を向上させる手法 [3]、カメラで撮影した実際の 2 次元投影像を入力し、事前に与えられた 3 次元モデルから 2 次元投影像を作成して照合する手法 [4] がある。これらの問題点は学習画像群のデータ量が膨大になるということである。これはアピアランスベース手法における基本的な問題点である。これに対しパラメトリック固有空間法 (以下の本稿では PES 法と呼ぶ) [5] は、ベクトル表現された学習画像群を主成分分析により次元を圧縮し、固有空間内で点群で表現することで大幅なデータ量の削減を実現した。さらにこれの発展として、点群をサポートベクトル回帰によって表現する手法も提案された [6]。しかし、これらの手法においても学習画像群に存在しなかった背景が入力画像に現れることで認識に影響を与え、正しい照合が困難になるという問題が残っていた。

このような問題に対する解決策が提案されている [7]~[9]。まず、背景画像と対象画像の差分として前景領域を

推定する背景差分の適用が考えられるが、事前に安定した背景のみの画像を準備しなければならない。また、学習画像群において共通的に物体領域となる部分をマスクとし、画像から物体を切り出す手法 [7] があるが、物体形状の変化が大きな場合には適切なマスクの設定は難しい。また対象物体を部分的な要素の集まりと考えて画像の局所的なウィンドウを固有空間法に応用する手法 [8] は、特徴量として明確なコーナー部の存在が必要であることから物体形状が制限される懸念がある。さらに距離画像の利用により背景の影響を低減する手法もあるが [9]、レンジファインダなどの 3 次元センサが必要であり、簡便な手法とは言い難い。さらに画像の濃度勾配を利用した特徴量のアプローチ [10][11] をアピアランスベースの手法に取り入れることも考えられるが、対象物体にテクスチャが存在することや背景に対象物体に酷似したテクスチャがないことを前提としなければならない。以上のように背景混入問題は簡便さと精度においてまだ解決しておらず、背景の影響を除去する手法の提案が必要である。

そこで本研究では、通常の 2 次元濃淡カメラの利用を前提とし、学習画像群から得られる情報を考慮することで、背景画像の事前準備が不要で、対象物体が写った認識画像 1 枚のみを用いて対象となる物体を切り出す手法を提案することを目的とする。

提案手法は、アピアランスベース物体認識において、入力画像に対してプリミティブ形状の窓を最適に当てはめ、背景要素を自動的に削除し、結果として学習画像群との照合精度を向上させる。さらに学習画像群から得られる前景確率を考慮することで背景除去の効果が向上する。プリミティブ形状とは矩形、円、楕円などの単純な図形である。本研究では、3 次元物体認識を扱うが、3 次

元形状を直接操作 [12] するのではなく、2次元濃淡画像の照合により2次元形状を操作し、背景除去に活用するという立場をとる。一般に単一のプリミティブ形状では多種多様な形状を持つ物体領域を近似することは困難であるが、提案手法では複数の楕円を組み合わせて用いることによって汎用性を確保する。

楕円の大きさや位置などの形状パラメータの決定を組み合わせ最適化問題と捉えることができるが、現実には組み合わせ数がきわめて膨大であり全探索による求解が困難である。そこで本研究では遺伝的アルゴリズム (GA) [13] によって近似的に実用的な解を探索する。照合には省メモリに優れた PES 法を利用するが、本手法は様々なアピアランススペースの手法に応用できるものである。楕円がより前景部分で探索が行われるようにするため学習画像群によって作成される前景確率マップを用いて前景確率を求め、照合に組み込む。

提案手法により入力画像中の対象物体に応じて自動的かつ最適に複数の楕円を当てはめ、複雑背景における背景の影響を低減し、物体の姿勢を安定に認識することが可能となる。必要な認識画像は1枚のみであり、背景に関する事前知識は不要である。また前景確率を考慮することで適切でない切り出しの影響を軽減する。さらに本手法は対象物体のテクスチャの有無に関係なく認識できる手法であり、汎用性も高い。

以下、本稿では第2章にて PES 法の原理と問題点を明らかにする。提案手法として、第3章は楕円モデルの設計、前景確率マップの作成方法とそれによって求められる前景確率を組み込んだ学習画像群との照合について記述し、第4章では GA による楕円の最適当てはめについて述べる。第5章では提案手法の評価実験を行い、第6章にて本研究の成果をまとめる。

2. パラメトリック固有空間法における背景混入に起因する問題点

2.1 概要

パラメトリック固有空間法 (PES 法) [5] とは、アピアランススペース物体認識の一種であり、入力された姿勢未知の物体の画像に対してベクトル表現された姿勢既知の学習画像群とのノルムを計算し、最小になったものの姿勢を認識結果とする手法である。主成分分析 (PCA) により学習画像の次元を圧縮することにより、少ない記憶容量で3次元物体を表現できるという利点がある。

2.2 学習フェーズ

学習画像に対して物体以外の部分に0を代入し、背景を同じ濃度にするを想定する [5]。各学習画像に対して、画素値を要素とする画像ベクトルを $\tilde{\mathbf{x}}_n (n = 1, \dots, N)$ とする。 N は学習画像の枚数である。 $\mathbf{x}_n = \tilde{\mathbf{x}}_n / \|\tilde{\mathbf{x}}_n\|$ により大きさを1に正規化する。すべての学習画像の平均画像 \mathbf{c} を計算し、各学習画像から平均画像 \mathbf{c} を差し引き、

行列 \mathbf{X}

$$\mathbf{X} = \left[\mathbf{x}_1 - \mathbf{c}, \mathbf{x}_2 - \mathbf{c}, \dots, \mathbf{x}_N - \mathbf{c} \right]^T \quad (1)$$

を作る。次に学習画像の共分散 $\mathbf{X}\mathbf{X}^T$ により各学習画像の固有値、固有ベクトルを求める。そして、大きい方から順に上位 $k (< N)$ 個の固有値に対応する固有ベクトル ($\mathbf{e}_1 \dots \mathbf{e}_k$) それぞれを軸とした k 次元の固有空間を作る。これに式 (2) によって各学習画像 \mathbf{x}_n を投影する。この投影された学習画像 \mathbf{g}_n の点の並びによって形成されたデータ列を多様体と呼ぶ。

$$\mathbf{g}_n = \left[\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_k \right]^T \left(\mathbf{x}_n - \mathbf{c} \right) \quad (2)$$




図1 多様体作成に用いた画像群の例




図2 PCAによる次元圧縮後の空間にプロットされた多様体の例 (上位3次元のみ表示)

図1は多様体を形成する際に用いた画像の例である。図2には図1の画像群によって形成された多様体の例を示す。多様体の生成には、通常細かいピッチで変化する視線方向から撮影された多数の画像が使用される。両図では代表的な角度のみを表示している。一般的なアピアランススペースの3次元物体認識には、3自由度の角度パラメータが必要となるが、本研究では背景除去の効果を示すことが目的であるため、鉛直軸周りの回転角度 θ のみを使用している。

2.3 認識フェーズ

認識画像 \mathbf{f}_r も学習画像と同じように画像ベクトルの大きさを1に正規化し、さらに学習画像の平均画像 \mathbf{c} を差し引いた後に学習で得られた固有空間に投影する。これを \mathbf{z} とする。固有空間における学習画像 $\mathbf{g}_n (n$ は θ_n に対応する) と認識画像 \mathbf{z} との相違度合いを表すユーク

リッドノルム $d(\theta_n)$ を最小にする姿勢 θ_R を認識結果とする。

$$d(\theta_n) = \|\mathbf{g}_n - \mathbf{z}\| \quad (3)$$

$$\theta_R = \operatorname{argmin}_{\theta_n} d(\theta_n) \quad (4)$$

姿勢を認識することは、認識画像 \mathbf{z} が多様体のどこに位置しているかに対応する。

2.4 背景外乱に起因する問題点

本節では背景の混入に寄因して発生する認識性能低下の例を示す。以下に多様体を作成した画像群（視線方向角を水平2度ずつ変化させた180枚）を図3に例示する。2種類の画像群それぞれの多様体を図4に示す。

図4のように複雑背景下における3次元物体の背景ありの固有空間の多様体は3次元物体だけの背景なしと比較して形などに差があることが分かる。提案手法は学習に背景なしを用いる。図5に認識失敗の実例を示す。図4(a)の多様体に対して図5(a)の認識画像をプロットすると、本来図5(b)が正解であるが、ユークリッドノルム d がより小さい図5(c)にマッチしている。すなわち認識画像と学習画像との距離 d が誤った画像ペアで最小となっている。これは、図3(a)のような背景なし画像によって作成された固有空間に図3(b)のような背景あり画像をプロットすると、背景の影響により誤認識を起こしていることを意味している。




図3 背景が異なる多様体の作成画像群の例 (512x512)

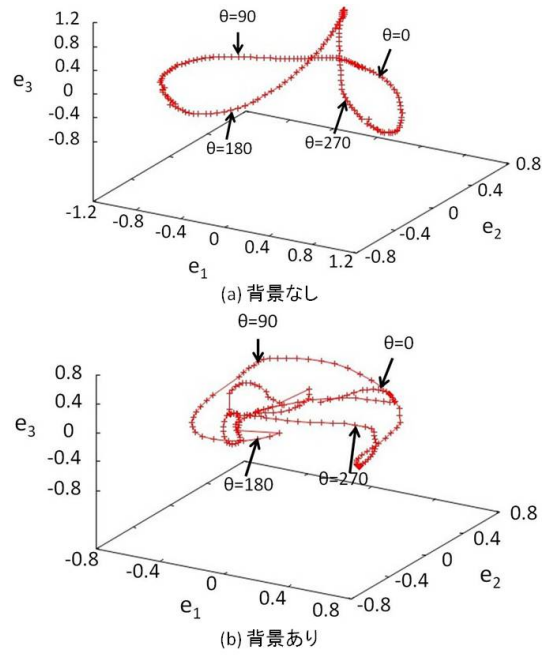


図4 多様体における背景混入の影響




図5 認識失敗例 (d は認識画像と学習画像の固有空間におけるユークリッドノルム)

3. 楕円窓の最適当てはめによる背景除去

3.1 提案手法の概要

複数の楕円を画像中の物体領域に最適に当てはめ、内部を物体領域、外部を背景領域と考えて、物体領域を切り出し、背景を除去する。最適とは、認識に影響がない程度に物体領域を切り出すことである。複数の楕円を用いることでさまざまな物体を効率よく近似できると考えられる。図6に提案手法のブロック図を示す。まず学習フェーズは、多視点画像群から特徴を抽出し、学習データベースの作成とマスク処理し、前景確率マップを生成の2つの流れがある。次に認識フェーズは、楕円を生成し、入力画像から楕円によって背景を除去し、特徴抽出と前景確率マップに楕円を当てはめ、前景確率の計算がある。これらを用いて学習データベースと照合し、誤差をフィードバックして楕円パラメータを更新していく流れである。前景確率を考慮することで楕円窓の最適当てはめによる背景除去の効果が向上する。なお、本研究ではこの組み合わせ最適化問題の解法として遺伝的アルゴリズム (GA) を使用する。詳細は4章にて説明する。

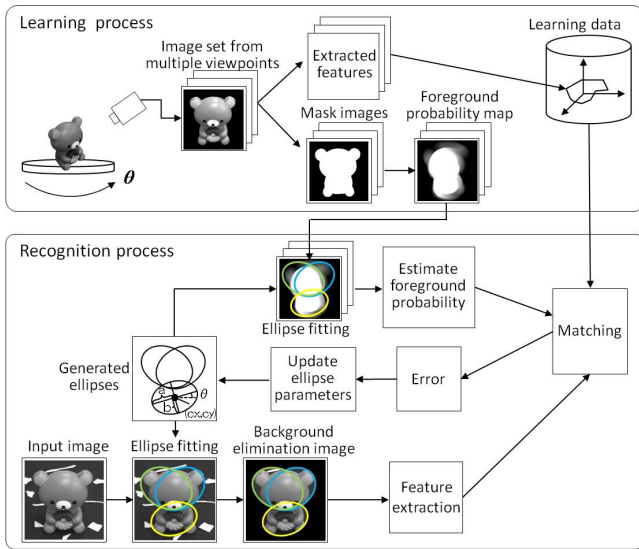


図 6 提案手法の概念図

3.2 楕円モデルの設計

図 7 のように、認識画像に対して複数の楕円形の窓を当てはめて抽出した対象物体の領域のみを学習画像群との照合に用いる。これは、式 (5) の cx , cy , a , b , θ の楕円パラメータを制御して位置や縦横比、傾きを変化させる。これにより楕円形状が多様に変化し、複数の楕円を用いることで、複雑な形状に対応する。今回は、予備実験により楕円数を 3 に固定した。




図 7 複数の楕円窓による対象物体の抽出

$$\left(\frac{(X_i - cx) \cos \theta + (Y_i - cy) \sin \theta}{a} \right)^2 + \left(\frac{-(X_i - cx) \sin \theta + (Y_i - cy) \cos \theta}{b} \right)^2 = 1 \quad (5)$$

3.3 前景確率の利用による照合精度の向上

3.3.1 前景確率利用の考え方

アピアランス空間物体認識において学習画像群を用いるため、そこから得られる情報を利用することを考える。そこで本研究では、学習画像群から前景確率マップの作成する。これは、各画素が前景として使用されている確率を持ったものである。これにも楕円を当てはめ、内部の値の平均である前景確率を算出する。これを楕円の当てはめが適切であるかの評価のために用いることで楕円が物体領域に集まりやすくなり、適切でない切り出しの影響を軽減する効果が期待できる。

3.3.2 前景確率マップの生成

学習画像群から前景確率マップを複数作成することを想定する。その際に学習画像をグループ化する。各学習画像の重なり率を見てグループに含めるかどうかを判断する。重なり率がしきい値以上なら同一グループにする。この例を図 8 に示す。図 8(b) を例にとると、重なり率は図 8(f) の白い領域の面積を図 8(b) の前景領域の面積で割ることで求められる。図 8(b) は重なり率がしきい値以上なため図 8(a) と同じグループになる。

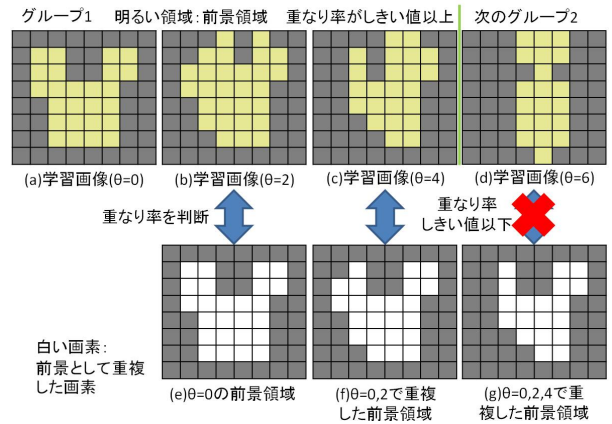


図 8 学習画像のグループ化

学習画像群から前景確率マップ $p_g(i, j) (g = 1, \dots, G)$ の作成の方法は式 (6)、式 (7) と図 9 に示す。 g は θ_n に対応した 1 つのグループであり、 G はグループの数である。まず、学習画像 $T_{\theta_n}(i, j)$ が前景であれば 1、背景なら 0 のマスク $M_{\theta_n}(i, j)$ を作成する。これを画素単位で足し、使用した学習画像の枚数 H で割り、前景確率マップ $p_g(i, j)$ を得る。図 10 は各グループの前景確率マップの例である。明るいところほど前景確率が高いことを意味している。

$$M_{\theta_n}(i, j) = \begin{cases} 1 & T_{\theta_n}(i, j) \neq 0 \\ 0 & otherwise \end{cases} \quad (6)$$

$$p_g(i, j) = \sum_{\theta_n=0}^h M_{\theta_n}(i, j) / H \quad (7)$$

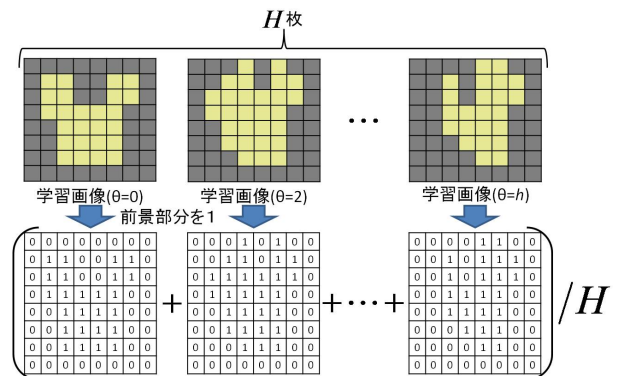


図 9 前景確率マップの作成




図 10 実際の前景確率マップ

3.3.3 前景確率を用いた学習画像群との照合

前節で得られた前景確率マップ $p_g(i, j)$ を用いて前景確率 p_θ を求める。式 (8) にそれを示す。 M, N は画像のサイズを表している。 $m_{ellipse}$ は入力画像から切り出す楕円の面積である。

$$if(i, j \text{ が楕円内}) \quad p_\theta = \sum_{j=0}^M \sum_{i=0}^N p_g(i, j) / m_{ellipse} \quad (8)$$

評価値 e_θ を用いて学習画像群との類似度を求める。式 (9) に示す。 d_θ は固有空間における学習画像と認識画像との距離である。 ω_1, ω_2 は重み係数である。

$$e_\theta = \omega_1 \frac{1}{1 + d_\theta} + \omega_2 p_\theta \quad (9)$$

ω_1, ω_2 は合計が 1 であり、評価値 e_θ は 0 から 1 に正規化されている。

4. GA による楕円切り出しの最適化

4.1 基本的な考え方

式 (5) における楕円パラメータの組み合わせ数は非常に膨大になり、全探索によって大局解を求めることは難しい。例えば cx, cy, a, b を 8 ビット、 θ は 1[deg] おきの 360 通りの 9 ビットの場合には、約 10^{12} のオーダーになる。そこで本研究では、遺伝的アルゴリズム (GA) によって近似的に実用的な解を探索する。GA では、準最適解と準最適解との組み合わせでより良い解を生成するという Building block の考え方により効率よく解を探索する手法である。これを本研究における問題と比較すると、部分的に正しい当てはめ結果の合成により大局的に正しい当てはめ結果を期待することに対応し、GA による探索が適していると考えられる。GA による楕円の最適当てはめから認識までの流れを図 11 に示す。

図 11 のように、まず最初に初期個体群を生成する。後で述べるように、各個体は 1 つの染色体をもち、染色体は画像内にセットされた楕円の位置等のパラメータを表現している。次に認識画像から楕円によって物体領域を切り出し、背景領域を除去した画像を生成する。これを用いて適応度を計算する。さらに遺伝的操作によって新たな個体を生成し、認識画像から楕円によって物体領域を切り出し、背景領域を除去した画像を生成する。これ

を用いて適応度を計算し、良い結果が得られたら終了し、得られなかったら遺伝的操作から繰り返し行う。

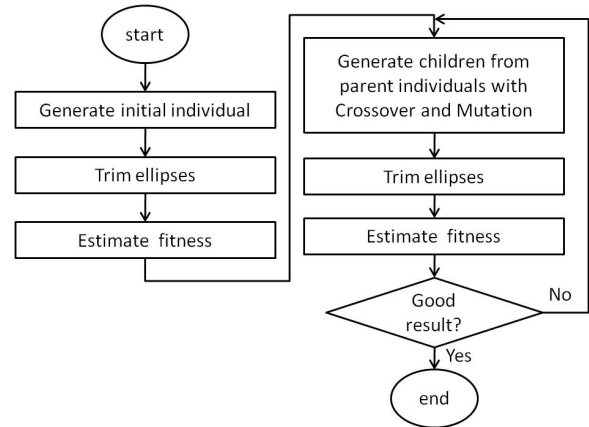


図 11 GA による楕円最適当てはめの流れ

4.2 染色体の表現

本研究では、図 12 に示すように楕円パラメータを並べた 1 次元染色体を定義する。各染色体は楕円パラメータにランダムで初期値を与えることによって生成される。これにより探索範囲に染色体を散りばめ、探索効率を向上させる。




図 12 染色体の定義

4.3 適応度の定義

GA の解の良さを表す個体の適応度 F は、次式 (10) のように定義する。 e_θ は式 (9) で計算される評価値であり、 F が大きいほど対象物体が適切に切り出せたことになる。なお e_θ は 0 から 1 に正規化されている。

$$F = \max e_\theta \quad (10)$$

4.4 遺伝的操作

交叉は探索範囲をまんべんなく探索していくために図 13 のような一様交叉を用いる。まず交叉の対象となる楕円をランダムに決定し、選ばれた楕円に対して一様交叉を適用する。これによって選ばれなかった楕円は確率的に交叉を行うかどうか決定する。これにより一つの楕円のみに対して一様交叉が適用される場合からすべての楕円に対して一様交叉が適用される場合が存在することに

なる。同様の処理を楕円パラメータに対しても行う。

突然変異においても交叉と同様に操作対象とする楕円パラメータを決定し、そのパラメータについて突然変異を行う。すなわち、ランダムに選んだビットが「1」ならば「0」に、「0」ならば「1」に変更する処理を行い、突然変異とする。これにより局所解にトラップされることを防ぐため、適応度向上の効果が期待できる。図14は突然変異の例である。

図13, 14で示されている染色体は、楕円一つではなく一つの楕円パラメータに対応している。

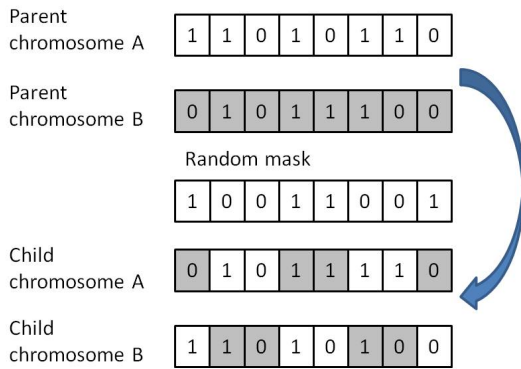


図13 一様交叉の例




図14 突然変異の例

交叉率 λ_c と突然変異率 λ_m は以下の式 (12) によって決定される。交叉率 λ_c と突然変異率 λ_m はそれぞれ交叉と突然変異が行われるかどうかの判断に使用する。最大適応度 F_{max} と平均適応度 F_{ave} の差 F_{dif} がしきい値を越えるなら交叉率 λ_c と突然変異率 λ_m は固定の値となり、しきい値以下なら最大適応度 F_{max} と平均適応度 F_{ave} の差 F_{dif} によって変動していく仕組みになっている。これにより探索効率の向上が期待できる。

$$F_{dif} = F_{max} - F_{ave} \quad (11)$$

$$\lambda_c = \begin{cases} F_{dif}/th & F_{dif} \leq th \\ 1 & \text{otherwise} \end{cases} \quad (12)$$

$$\lambda_m = \begin{cases} (th - F_{dif})/th & F_{dif} \leq th \\ 0.03 & \text{otherwise} \end{cases}$$

4.5 世代交代の終了条件

GAの終了条件としては、最大適応度が0.945に達したときとした。ただし処理時間の最大値を保証するため、世代が100世代を越えた場合も終了する。これらのしきい値は実験的に決定した。

5. 実験結果と考察

本手法の位置と姿勢の推定精度、信頼性、汎用性、GAの有効性を実証するために以下の3種類の実験を行った。実験に用いた背景なし学習画像（視線方向角を水平2度ずつ変化させた計180枚）の中から $\theta = 0$ の場合を15(a)に、テスト用として3種類の認識対象画像を図15(b)~(c)に例示する。AからCの順に背景の複雑さが高くなっている。




図15 学習画像の例と背景の複雑さの異なる3種類の認識画像 (512x512)

5.1 位置と姿勢の推定精度

図16はさまざまな視線角度における学習画像群と認識画像の類似度マップである。縦軸に各学習画像が並び、横軸に認識画像が並んでいる。高さはそれぞれの類似度を示している。正しく照合すれば対角線上の S が高くなる。図16(a)の左図は類似度が明確でないのに対し、図16(a)の右図は対角成分が急激に高くなっている。よって提案手法ではどの背景下の認識画像でも対角成分の類似度が高く、背景除去が良好に行われていることが分かる。

図17は認識画像に対してパラメトリック固有空間法 (PES法) と提案手法における推定した角度の画像を示す。図17(c)のPES法は、図17(a)の認識画像との誤差が+76[deg]となり、明らかに誤った角度を推定しているのに対し、図17(d)の提案手法の誤差は-2[deg]となり、かなり近い角度を推定している。すなわち、姿勢の推定精度が向上したことが分かる。

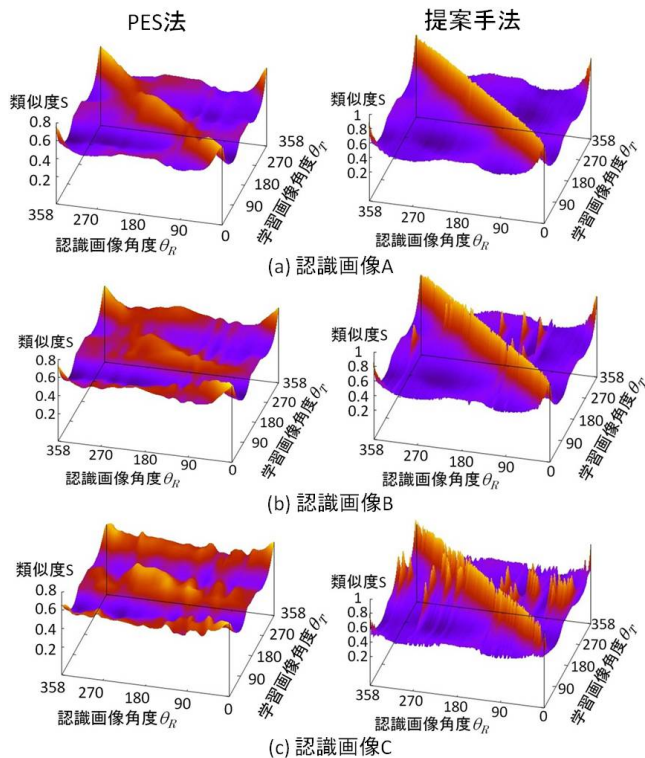


図 16 学習画像と認識画像の類似度マップ




図 17 推定された角度画像

5.2 信頼性および汎用性の評価実験

認識画像も学習画像と同様に視線方向角を水平2度ずつ変化させた180枚の画像を取得し、それぞれに対して適切な姿勢を推定するかどうかの実験を行い、認識率を調べた。表1は認識率の評価結果である。認識画像A～Cは図15(b)～(d)に対応している。正解角度との誤差が±3ステップ(±6[deg])以内のものを正解とした。ただし、今回の認識率の実験において、固有空間における各学習画像間の点の補間を行わなかった。この理由は、認識画像と正解の学習画像との距離が最小になってはじめて補間の効果が出てくるからである。いずれの画像でも提案手法がPES法を上回っていることが確認できた。また、認識画像Cの場合、前景確率の考慮ありは前景確率の考慮なしのと比較して10.6%の認識率が向上している。よって、多様な背景において十分な認識率が得られたことから提案手法の汎用性を示すことができた。さらに、前景確率を考慮することの効果も示せた。しかし、認識画像Cの認識率は認識画像A、Bに比べると低くなっている。これは複雑な背景に寄因して対象物体に似た背景物体が増え、認識に影響を与えたためと考えら

れる。

表 1 認識率の比較結果

認識画像	PES 法	前景確率の考慮なし	前景確率の考慮あり
A	63.9%	99.4%	100.0%
B	43.3%	87.8%	92.2%
C	22.2%	57.2%	67.8%

5.3 GAの挙動に関する分析

図18はGAによって親から生成された子個体が楕円による切り出しが良くなっている様子を示す。親1は背景を多く含み、親2は物体領域を失うとともに背景を含んでいる。しかし、これらの親から生成された子(同図(c))は背景部分が減少し、楕円が物体領域に集まり、より高い適応度を得ていることが確認できる。この実験により、GAにより解の探索が効果的に行われていることが示された。

図19(a)は5.2節における実験の失敗画像の例である。この画像では背景部分を含み、対象物体領域が背景として除去されている。この時の姿勢推定の誤差は+54[deg]である。この失敗例においてGAの個体数や交叉率、突然変異率、終了条件などのパラメータを再度調節して実験を行ったところ、図19(b)の結果が得られた。図19(a)に比べ、背景領域の過剰切り出しと前景領域の切り出し不足が減少し、良好な切り出し結果となっている。この結果、姿勢推定の誤差は+2[deg]となり、姿勢の推定精度も向上した。この分析から、図19(a)の失敗原因はGAの探索パラメータの調整不足に寄因していると思われる。性能向上のためにはパラメータ調整の最適化が必要である。




図 18 親から産まれた良好な個体例




図 19 切り出した画像の例

5.4 照明変動の影響

外乱には背景以外に照明変動が考えられる。本節では照明変動が提案手法に与える影響を分析する。図 20 は照明変動を模擬し、濃度値が正弦波状に変化するシェーディングを付加した画像を例示したものである。周期は画像サイズの 4 分の 1、シェーディングの方向は 45[deg]、シェーディングの強さである振幅を 20 とした。表 2 は照明変動がある画像 90 枚による認識率である。提案手法は画像ベクトルの大きさを正規化することで照明変動を抑制する機能を有するものの、それだけでは照明変動への対応が不足していることから、照明変動なしよりも認識率が平均約 9% 低くなったと考えられる。また提案手法は、画像のすべての画素を照合に用いるので、照明変動した部分が認識に影響を与えるため、部分的に輝度値が変わるような照明変動には適用しにくい手法であると考えられる。

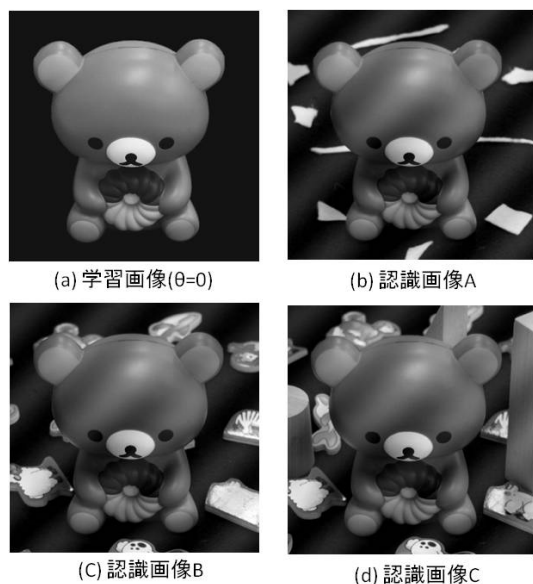


図 20 照明変動のある画像 (512x512)

表 2 照明変動がある場合の認識率

認識画像	照明変動なし	照明変動あり
A	100.0%	92.2%
B	92.2%	80.0%
C	67.8%	60.0%

5.5 処理時間

処理時間としては、学習データと認識画像 1 枚が与えられてからの認識にかかった時間を計測した結果、2687[s] (CPU: Intel® CORE™ i7, システムメモリ: 8GB, OS: Ubuntu10.04) であった。この結果から本手法をオンラインのロボットビジョンシステムとして適用するのは困難であると考えられる。これは遺伝的アルゴリズムによる世代交代と適応度の計算に時間がかかっていることが

主因である。適応度を求める際、各個体において楕円により切り出し、その画像を固有空間に投影して距離を求めなければならないからである。この問題に対しては、遺伝的アルゴリズムの探索範囲の限定等を用いることにより改善していく予定である。

6. おわりに

複雑背景下における画像中の 3 次元物体を対象に、楕円を遺伝的アルゴリズムにより最適に当てはめ、画像中の 3 次元物体領域を切り出すことで背景を削減し、照合精度を向上させる手法を提案した。実験により従来手法であるパラメトリック固有空間法に比べて認識成功率が向上したことを確認した。また、多様な背景を用いた実験を行うことで提案手法の汎用性についても実証した。また前景確率を考慮することの効果も示した。

今後は、処理時間とさらにさまざまな 3 次元物体や複雑背景に対する性能評価と改善を行っていく予定である。

文 献

- [1] Milan Sonka, Vaclav Hlavac, and Roger Boyle, Image Processing, Analysis, and Machine Vision, Pws, pp.544-553, 1998
- [2] Ullman S, and Basri R, Recognition by Linear Combination of Models, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.13, no.10, pp.992-1006, Oct.1991
- [3] Katsushi Ikeuchi, and Sing Bing Kang, Assembly Plan from Observation, AAAI Technical Report, pp.115-119, 1993
- [4] 野村由司彦, セーハン ドゥスイット, 藤井省三, “2 次元投影像からの 3 次元物体の位置・姿勢推定方法”, 信学論 (D-II), vol.J77-D-II, no.1, pp.101-107, Jan. 1994.
- [5] 村瀬洋, シュリー ナイヤー, “2 次元照合による 3 次元物体認識—パラメトリック固有空間法—”, 信学論 (D-II), vol.J77-D-II, no.11, pp.2179-2187, Nov. 1994.
- [6] 安藤慎吾, 草地良規, 鈴木章, 荒川賢一, “サポートベクトル回帰を用いた三次元物体の姿勢推定法”, 信学論 (D), vol.J89-D, no.8, pp.1840-1847, 2006.
- [7] 村瀬洋, シュリー ナイヤー, “多重解像度と固有空間表現による 3 次元物体のイメージスポッティング”, 情処論, vol.36, no.10, pp.2234-2243, Oct. 1995.
- [8] 大場光太郎, 池内克史, “局所固有空間手法による金属物体の安定認識”, 信学論 (D-II), vol.J80-D-II, no.12, pp.3147-3154, Dec. 1997.
- [9] 天野敏之, 山口証, 井口征士, “固有空間照合を用いた距離画像の仮想学習による物体認識・姿勢検出”, 信学論 (D-II), vol.J82-D-II, no.2, pp.250-258, Feb. 1999.
- [10] 三井相和, 山内悠嗣, 藤吉弘亘, “Joint 特徴量を用いた 2 段階 Boosting による物体検出”, 信学論 (D), vol.J92-D, no.9, pp.1591-1601, 2009.
- [11] 西村孝, 清水彰一, 藤吉弘亘, “2 段階の Randomized Trees を用いたキーポイントの分類”, MIRU, pp.1419-1412, Jul. 2010.
- [12] 網島宣浩, 斎藤英雄, “遺伝的アルゴリズムを用いた濃淡画像からの超 2 次元関数のパラメータ推定”, 信学論 (D-II), vol.J79-D-II, no.5, pp.795-802, Mar. 1996.
- [13] D.E.Goldberg, Genetic Algorithms in Search, Optimization, and Machine Learning, Addison Wesley, 1989.