

## B2-1 PSO を適用した良質解探索 GA による色抽出手法に関する研究

福井大学大学院 工学研究科 知能システム工学専攻 進化ロボット研究室

石川 雅史 (指導教員: 前田 陽一郎)

## 1. 緒言

画像処理のしきい値処理によって行われる色抽出は、ロボットビジョンやコンピュータビジョンの物体認識等を行う上で極めて重要な処理である。照明の影響を受けている環境で特定物体の領域を全て色抽出する場合、抽出対象の物体に陰影と照明の当たる領域が影響して、対象物の色情報に類似した領域も抽出されてしまい、正確な色抽出を行うことが容易ではないという問題がある。さらに照明条件が変化する動的環境下では、時間や場所によって画像の色情報が極端に変化する。このような環境で色抽出を正確かつ高速に求めることは容易ではなく、外乱の影響を受けやすい実環境での色抽出処理には、極めて困難な問題が存在する。

これまでもこのような色抽出に関する研究は、数多く提案されている。その研究例として、対象画像の明度の平均と遺伝的アルゴリズムを用いて取得したしきい値の上限・下限の関係から関係式を導き最適なしきい値を決定する手法 [1]、ニューラルネットワークによって最適なしきい値を学習する手法 [2]、色分布をファジィ集合として定義したファジィ色分類と呼ばれる色分類法を用いて照明条件の変化に対応できる手法 [3] が挙げられる。しかしながら、これらの研究は、照明の変動に対処するために様々な照明環境であらかじめ調整を行い、照明条件や色情報などの関係を求めた上で、色抽出処理で使用する色情報のしきい値を決定しなければならない。そのため、実際に色抽出処理を行う際、事前に非常に手間がかかる。

そこで本研究では、これまでに述べたような事前の条件や関係を求めることなく、抽出目標物を含む画像に対して、人為的に選択した対象物の楕円形状内の YUV 表色系によるしきい値情報を基に Particle Swarm Optimization (PSO) アルゴリズムを適用した色抽出 GA を提案する。PSO とは、鳥の群れや魚の群れなどの群れを成して行動する生物の移動パターンを模倣した確率的最適化手法であり [4]、GA に比べ学習の収束性が優れ、アルゴリズムも非常にシンプルであるのが特徴である [5, 6]。PSO は良質解探索性能に優れているが、解探索における多様性保持については GA の方が優れている。そこで本手法では、エリート更新やハミング距離などの条件に応じて PSO の処理を付加する PSO-GA を提案する。これにより、GA の最適解への収束性能向上をめざす。また、本手法の有効性を検証するために、従来の GA と PSO-GA の探索性能および色抽出性能の比較を行う。

## 2. PSO の概要

Particle Swarm Optimization (PSO) とは、群知能の一種であり、鳥群や魚群などの群れにおける社会的なモデルを参考にして考え出された確率的最適化手法である。近年、GA に代わる最適化手法として注目されている。PSO の個体は、図 1 に示すように、位置ベクトル  $\vec{x}_i$  と速度ベクトル  $\vec{v}_i$  で表されて、問題空間にランダムに配置される。そしてこれは、自分自身の速度ベクトル  $\vec{v}_i$  (現在進んでいる方向) に加え、過去

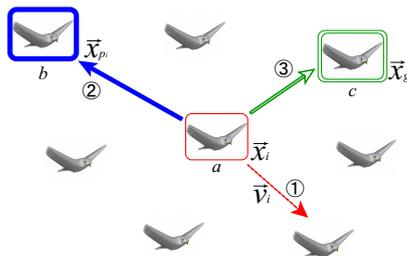


図 1: PSO の探索概念図

の自分自身が獲得した最良位置ベクトル  $\vec{x}_{p_i}$  (自己の最良経験方向) とその時の集団中のエリートがもつベクトル  $\vec{x}_g$  (集団の最良方向) をある重みづけを基に確率的に考慮することによる探索方向の決定アルゴリズムである。基本的に PSO は多様性確保よりは良質解探索を重視した最適化手法で、多峰性問題よりは単峰性問題に向いている。この操作を繰り返すことで、集団内の最良個体を中心に他の個体が移動を繰り返し、問題空間の最適値に収束する。これが PSO の基本的なメカニズムである。

$$\vec{v}_i^{k+1} = \omega \vec{v}_i^k + c_1 \phi_1(\vec{x}_{p_i} - \vec{x}_i^k) + c_2 \phi_2(\vec{x}_{p_g} - \vec{x}_i^k) \quad (1)$$

$$\vec{x}_i^{k+1} = \vec{x}_i^k + \vec{v}_i^{k+1} \quad (2)$$

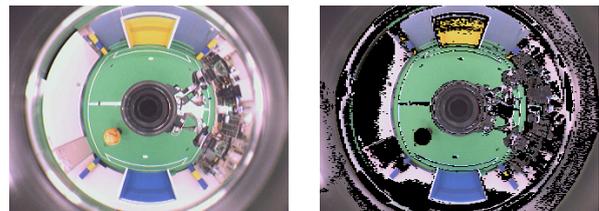
## 3. GA による色抽出のしきい値自動調整手法

今回対象としている問題およびその問題を解決するための提案手法について以下に説明する。

## 3.1 問題設定

本手法で扱う問題は、目標の対象物の周囲に複数のノイズを含む画像に対し、最適なしきい値を自動的に調節することでその対象物のみを抽出できるようにしきい値を決定することである。ここで我々の扱うノイズとは、目標対象物以外の領域を抽出した点またはその集まりのことを指す。以下、同義で用いる。また、様々な照明条件及び特異な画像においても安定した色抽出を行う必要がある。このように安定した色抽出を行うには、輝度情報を含む色空間におけるしきい値の上下限値の適切な設定作業が重要になる。

一般に、目標の対象物から人為的に色情報を取得した場合、この色情報を基に画像全体を色抽出すると、図 2(b) のように、対象物の周囲に複数のノイズを含んでしまう。そこで、本研究では色抽出におけるしきい値情報 (ここでは YUV 表色系を用いた) を遺伝子で表現した遺伝的アルゴリズム (GA) を用いて対象の画像に対して、適切なしきい値を決定し、目標の対象物のみを抽出できる手法を提案する。



(a) 原画像 (b) ノイズを含んだ画像

図 2: 色抽出の画像例

本手法では、まず目標対象物の領域を人為的に選択しておき (以下、選択領域と呼ぶ)、その領域内における色情報 (Y,U,V) の最大値、最小値を求める。そして、この色情報をもつ遺伝子をエリート個体として GA の初期集団の中にコード化して含める。これは、GA の初期探索において目標としている解にできるだけ速く向かわせるためである。しかしながら、この操作は探索初期には極めて高い適応度を持つエリート保存にあたるので局所解に初期収束しないよう突然変異率などを慎重に選ぶ必要がある。本手法により、選択した対象物ができる限り多く抽出し、かつ選択範囲以外ではできるだけ抽出しないような色情報のしきい値を求めることが可能となる。

## 3.2 色情報のコーディング

今回使用するカメラ画像のカラーフォーマットが RGB であるため、式 (3) を用いてビデオフォーマットでよく用いられ、色抽出作業に比較的向いていると言われる YUV 表色系

に変換し、このカラーフォーマットを GA の学習データとして用いた。

$$\begin{aligned} \text{(輝度)} \quad Y &= 0.257R + 0.504G + 0.098B + 16 \\ \text{(青色差)} \quad U(Cb) &= -0.148R - 0.291G + 0.439B + 128 \\ \text{(赤色差)} \quad V(Cr) &= 0.439R - 0.368G - 0.071B + 128 \end{aligned} \quad (3)$$

YUV のしきい値情報を表現するための GA の遺伝子情報として、Y,U,V のそれぞれの起点と幅を図 3 に示すようにコーディングする。本研究では、グレイコーディングを用いた。このコーディングで色空間におけるしきい値の起点と幅を用いたのは、しきい値の上限と下限を使用した場合、上限と下限が逆転する問題を避けるためである。しかしながら、このしきい値の起点と幅の情報を持つ遺伝子をデコードすると、しきい値の上限と下限の関係からしきい値の範囲を超えてしまう場合がある。このような場合は、YUV 表色系における範囲の上限と下限に合わせてデコードした個体のしきい値を頭切りするものとする。

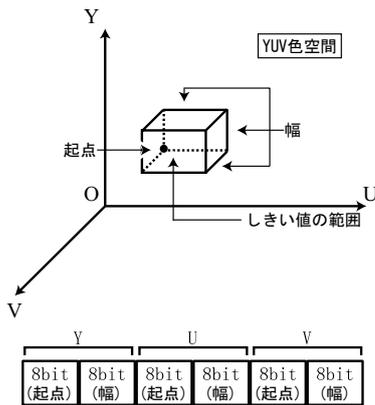


図 3: 個体の遺伝子構造

### 3.3 しきい値調整のための適応度関数

目標対象物の画素を多く抽出して、対象物以外の領域のノイズなどはできる限り抽出しないような各色要素 (Y,U,V 値) のしきい値の範囲を効率的に探索するために、以下の式 (4) で適応度を計算する。

$$f = \frac{S}{S_{all}} \left( \frac{S}{A} - k \frac{N}{A} \right) \quad (4)$$

$f$ : 個体の適応度  
 $S_{all}$ : 選択領域の全画素数  
 $k$ : 重み係数

適応度関数で用いる重要なパラメータは以下の 3 つである。

- 選択度  $S$ : 選択領域内で抽出した画素数
- ノイズ  $N$ : 選択領域外 (ノイズ領域) で抽出した画素数
- 抽出度  $A$ : 画像全体で抽出した全画素数

式 (4) は、全抽出点における選択領域内と選択領域外の抽出画素数の割合を求め、その重み付き差分を取り、この差分の増加が対象物の選択エリア抽出とノイズの除去に相当する。さらに選択領域内で抽出した画素の割合が高いものをより高い適応度とするため右辺の係数  $\frac{S}{S_{all}}$  を乗じている。

### 3.4 提案手法の処理手順

前節までに述べた設定を基に以下に示すような処理手順で GA によるしきい値調整処理を行う。

- Step1: 前処理  
 あらかじめ対象物の領域を人為的に選択し、その領域における YUV の最大値と最小値を取得する。取得したしきい値情報から式 (4) の適応度を計算して、この適応度を基準適応度  $f_s$  とする。
- Step2: 初期化  
 初期集団の個体をランダムに生成する。さらに、その生成された集団に Step1 で取得したしきい値情報をコード化したものを初期世代のエリート個体として付加する。

- Step3: 色抽出処理  
 すべての個体において YUV のしきい値情報を基に実際に色抽出処理を行う。
- Step4: 個体評価、エリート保存  
 Step3 の色抽出結果より式 (4) の適応度関数を用いて各個体の適応度を求める。求めた適応度の中で最大適応度  $f_{max}$  の個体をエリートとして保存する。このとき、適応度が等しい個体が存在する場合、選択領域内に抽出点が多い方の個体をエリート個体とする。
- Step5: 選択、交叉、突然変異  
 適応度に従った確率で選択するルーレット選択を用いて個体を選択して、一点交叉を行う。さらに生成された個体に対して、突然変異を行う。この Step3~5 の処理を終了世代まで繰り返す。
- Step6: 終了条件  
 Step5 までの処理を終えて、最終世代でのエリート個体の適応度  $f_{max}$  が Step1 で求めた基準適応度  $f_s$  よりも評価が良くなった場合 ( $f_{max} - f_s > 0$ )、学習は成功したことになる。ただし、今回の実験では、学習が成功しない場合を考慮して、2000 世代で探索を終えるように設定した。

## 4. 簡略化 PSO を有する良質解探索 GA

本研究では前述の GA による解探索性能をさらに向上させるため、簡略化 PSO 処理を付加した良質解探索 GA (PSO-GA) を提案する。ここでは速度・位置更新の処理を GA の過去の最良個体とエリート個体との距離に応じて適応させる手法について説明する。

### 4.1 速度更新

図 4 のように個体の過去の最良遺伝子 (記憶遺伝子) と集団のエリートとの遺伝子列間で差分によるハミング距離を計算する。その後、これらの遺伝子列の論理積を求めることで変動した遺伝子座を求め、この遺伝子列を速度遺伝子とする。

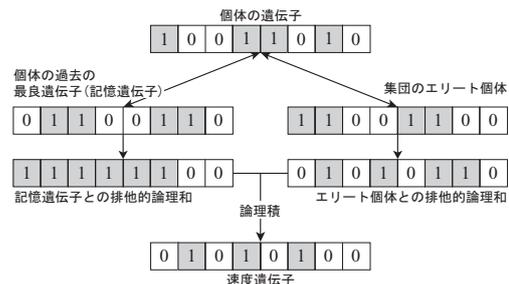


図 4: 提案する遺伝子の速度更新処理

### 4.2 位置更新

図 5 のように速度更新で得た速度遺伝子と個体の遺伝子を比較し、速度遺伝子の 1 である遺伝子座に対応する個体の遺伝子座をロジスティック曲線が表す確率で反転させる。ロジ

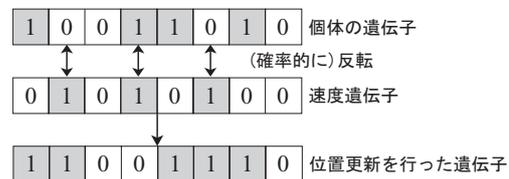


図 5: 提案する遺伝子の位置更新処理

スティック曲線は、生物群の成長曲線などによく利用される代表的な曲線である。ロジスティック曲線は、ロジスティック方程式 ( $f(x) = \frac{1}{1+ce^{-ax}}$ ) のパラメータ  $a, c$  を変化させることで曲線の形状が決定する。今回はロジスティック方程式のパラメータを  $a = -0.02, c = 10$  に設定した。

### 4.3 PSO 実行判定

GA の全ての世代に対して PSO を実行すると、PSO は収束性能が通常の GA よりも優れているために初期収束に陥り

最適解に到達しない可能性がある。そこで図 6 に示す 3 種類の PSO 実行条件を設定した。式 (4) で算出した適応度が負の個体  $X_{neg}$  (選択領域の抽出量よりノイズ量の方が多い個体) に対してのみ以下の PSO 処理を実行条件に従って行う。

- PSO-GA1  
GA で進化を進め、エリート保存でエリートが更新された場合に  $X_{neg}$  に対して PSO 処理を実行する。(図 6(a) 参照)
- PSO-GA2  
PSO-GA1 の実行条件に加え、現世代での集団のハミング距離の平均  $HD_{ave}$  が特定のビット数  $B_{hd}$  を上回った場合に  $X_{neg}$  に対して PSO 処理を実行する。(図 6(b) 参照)
- PSO-GA3  
PSO-GA1 の実行条件に加え、1 個体の遺伝子のビット数 (48bit) における現世代での集団のハミング距離の平均 ( $HD_{ave}$ ) の割合 ( $= \frac{HD_{ave}}{48}$ ) による確率に従って  $X_{neg}$  を選択し、選択された個体だけにのみ PSO 処理を実行する。(図 6(c) 参照)

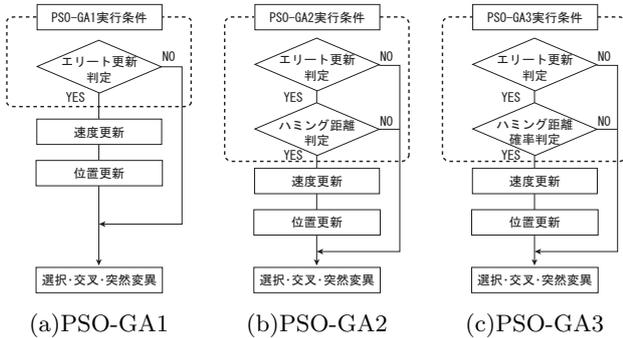


図 6: 3 種類の PSO 実行判定

#### 4.4 PSO-GA による処理手順

ここでは、前節の簡略化 PSO 処理をしきい値調整 GA に加えた PSO-GA の処理手順を説明する。図 7 に PSO-GA のフローチャートを示す。尚、前章で説明した前処理、色抽出処理、個体評価、エリート保存の各処理は、本手法でも同様に扱うので説明を割愛する。

- Step1: 前処理
- Step2: 初期化  
初期集団の個体をランダムに生成し、この各個体の遺伝子を各個体の記憶遺伝子として記憶する。また、生成された初期集団に Step1 で得たしきい値情報をコード化したものを初期世代のエリート個体として付加する。
- Step3: 色抽出処理
- Step4: 個体評価、エリート保存
- Step5: 記憶遺伝子更新  
各個体に対して個体の遺伝子とその個体の記憶遺伝子の適応度を比較して、個体の遺伝子の方が適応度が高い場合、記憶遺伝子を個体の遺伝子に置き換える。
- Step6: ハミング距離  
集団の中からランダムに個体を選択し、選択された個体の遺伝子と他の個体の遺伝子とのハミング距離 (2 つの遺伝子の排他的論理和の 1 となるビットの合計) を求める。その後、得られたハミング距離の平均  $HD_{ave}$  を算出する。
- Step7: PSO 実行判定  
前節で説明した PSO 実行判定 (PSO-GA1/PSO-GA2/PSO-GA3) に従って、Step8 の処理の有無を決定する。
- Step8: 速度更新、位置更新  
適応度が負の個体  $X_{neg}$  に対して、前節で説明したように速度・位置更新処理を行う。
- Step9: 選択、交叉、突然変異  
ルーレット選択を用いて個体を選択して、その個体の遺伝子に対して一点交叉を行う。また交叉を行った親個体には、その個体もつ記憶遺伝子に対しても遺伝子の交叉と同一の交叉点で一点交叉を行う。これは、交叉によ

って新たに生成された個体に親個体もつ記憶遺伝子を継承するためである。さらに生成された個体に対して、突然変異を行う。この Step3~9 の処理を終了世代まで繰り返す。

- Step10: 終了判定  
Step9 までの処理を終えて、最終世代でのエリート個体の適応度  $f_{max}$  が Step1 で求めた基準適応度  $f_s$  よりも評価が良くなった場合 ( $f_{max} - f_s > 0$ )、学習は成功したことになる。ただし、今回の実験では、学習が成功しない場合を考慮して、2000 世代で探索を終えるように設定した。

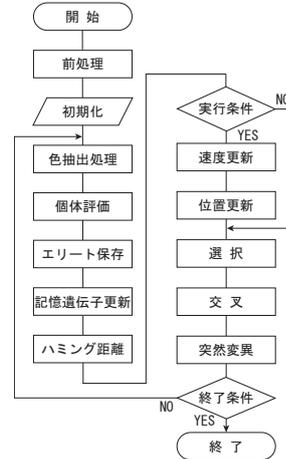


図 7: PSO-GA によるしきい値調整のアルゴリズムフロー

#### 5. 実画像による色抽出実験

本手法の有効性を検証するために色抽出シミュレータを作成し、以下に示す様々な環境でボールの抽出実験を行ったので、この結果について報告する。

##### 5.1 実験方法

本実験で使用した画像を図 8 に示す。原画像 (a) は室内の照明に加えボールにハロゲンランプを照射し、原画像 (b) は室内の照明のみの画像である。色抽出する目標対象物はオレンジボールであり、SGA と各 PSO-GA の探索性能比較実験を実施した。また GA の探索性能を公平に評価するために各 GA で使用した GA パラメータを個体数 100、交叉率 0.7、突然変異率 0.01 に統一した。尚、PSO-GA2 の PSO 実行判定における  $B_{hd}$  は 24 (個体の遺伝子長の半分) に設定した。さらに各 GA で得た色抽出結果についても評価を行った。

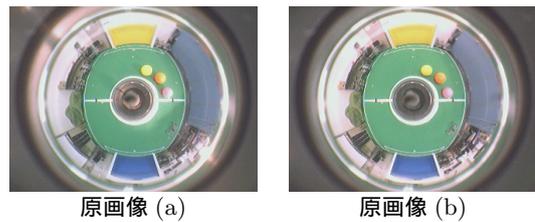


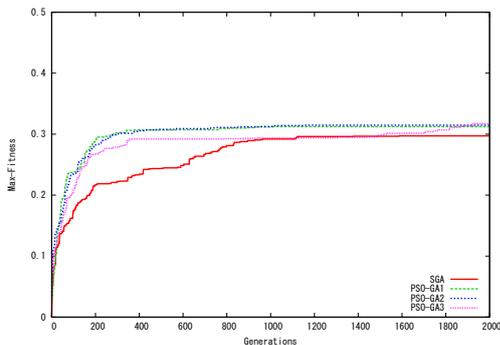
図 8: 実験で使用した原画像

##### 5.2 実験結果および考察

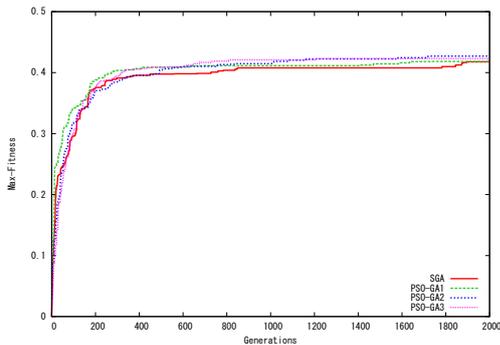
実験の学習結果を図 9 に、オレンジボールの抽出量とノイズ量を表 1 に、色抽出結果を図 10, 11 に示す。学習結果は、10 回試行した結果を平均したものをグラフ化している。また色抽出結果の出力画像は、黒色で塗りつぶされた領域が抽出領域であり、二値化画像では、白色で塗りつぶされた領域が抽出領域である。尚、PSO-GA の色抽出結果は、PSO-GA の中で比較的良好な GA の結果を示す。

学習結果では、初期探索時に SGA と PSO-GA の探索性能に大きな差が現れた。また色抽出結果においても SGA よりも PSO-GA の方が選択領域の抽出量が比較的多いことが確認できる。

原画像 (a) の実験結果において、SGA は PSO-GA と比べて初期探索時の適応度が極めて低い結果になっている。これは、イエローボールに含まれるノイズがオレンジボールの類



(a) 原画像 (a) の最大適応度



(b) 原画像 (b) の最大適応度

図 9: 学習結果

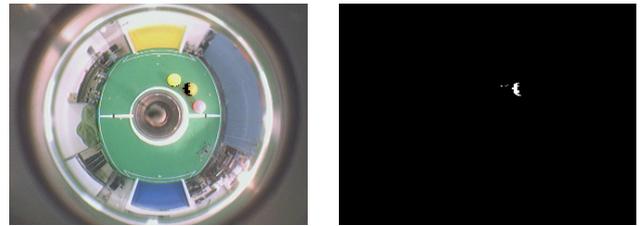
表 1: 選択領域とノイズ領域の抽出量

原画像 (a)		
GA タイプ	選択領域	ノイズ領域
SGA	65	6
PSO-GA1	77	6
PSO-GA2	77	6
PSO-GA3	76	6
原画像 (b)		
GA タイプ	選択領域	ノイズ領域
SGA	65	1
PSO-GA1	82	1
PSO-GA2	82	0
PSO-GA3	82	1

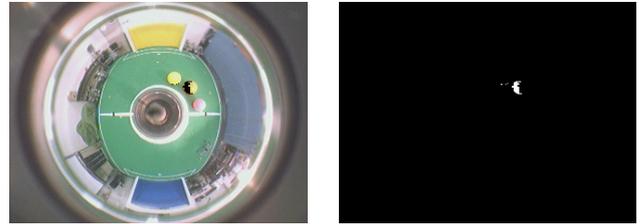
似色となり、極めて除去が困難なノイズであったと考えられる。そのため、この類似色のノイズが図 8 において多数存在し、SGA と PSO-GA との間に探索性能の差が見られたと考えられる。また、原画像 (b) の実験結果においてもわずかながら SGA よりも PSO-GA の方が探索性能が優れていたことが確認できる。さらに表 1 にも両画像における学習結果の差が現れているのが確認できる。

## 6. 結言

本研究では、目標対象物のみを効率よく色抽出するために GA を用いて Y,U,V の最適なきい値の範囲を自動調整する手法を提案し、初期集団に選択領域内の色情報をエリート個体として含めることで色抽出の最適化を実現した。さらに PSO の高い収束性能を適用させた PSO-GA による色抽出手法を提案した。本手法では、PSO のアルゴリズムである速度更新及び位置更新の処理を GA でも扱えるように簡素化し、設定した条件に応じて付加することで、良質解探索を行い、SGA よりも効率的な学習探索を実現させることができた。従来手法の SGA との探索性能比較実験では、PSO-GA の学習結果は、SGA よりも高性能な探索を行うことができ、本手法の有効性が検証された。さらに色抽出結果においても、SGA に比べ PSO-GA の方が比較的良好な色抽出を行うことが確認できた。また今回、1 回の GA 学習で単色しかしきい値探索を行えなかったため、今後は一度に多数の目標対象物 (多色) に対して、色抽出を行える手法を提案していきたい。



SGA



PSO-GA3

図 10: 原画像 (a) の色抽出結果



SGA



PSO-GA2

図 11: 原画像 (b) の色抽出結果

## 参考文献

- [1] S.Yoshimori, Y.Mitsukura, et al.: "License Plate Detection System by Using Threshold Function and Improved Template Matching Method," *Annual Meeting North American Fuzzy Information Process Society*, Vol.1, pp.357-362 (2004)
- [2] 福田善彦, 満倉靖恵, 福見稔: "ニューラルネット学習に基づいた閾値決定法による高速顔領域探索," *電子情報通信学会技術研究報告*, Vol.101, No.615, pp.163-169 (2002)
- [3] 実川達明, 菊池敏文, 上田隆一, 新井民夫, 梅田和昇, "大きな照明条件変動に対応するファジィ色分類を用いたカラーボール認識手法の開発," *Proceedings of the 2005 JSME Conference on Robotics and Mechatronics*, 2P1-S-026, pp.1-4 (2005)
- [4] J.Kennedy, R.Eberhart, "Particle Swarm Optimization," *Proceedings of the 1995 IEEE International Conference on Neural Networks*, pp.1942-1948 (1995)
- [5] 越野亮, 村田裕章, 木村春彦, "Particle Swarm Optimization の改良とポートフォリオ選択への応用," *電子情報通信学会論文誌*, Vol.J89-A, pp.48-60 (2006)
- [6] 伊藤稔, 田中雅博, "閾数値最適化のための Particle Swarm Optimization, Differential Evolution, 実数値遺伝的アルゴリズムの探索性能に関する検討," *甲南大学紀要 理工学編*, Vol.52, pp.125-135 (2005)