

AdaBoost と Saliency Map を用いた Graph Cuts による 花卉領域の自動抽出法

福田 恵太[†] 滝口 哲也^{††} 有木 康雄^{††}

[†] 神戸大学大学院工学研究科 兵庫県神戸市灘区六甲台町 1-1

^{††} 神戸大学自然科学系先端融合研究環 兵庫県神戸市灘区六甲台町 1-1

E-mail: [†]fukuda@me.scitec.kobe-u.ac.jp, ^{††}{takigu,ariki}@kobe-u.ac.jp

あらまし 本研究では、花画像検索システムの前処理として、画像中の花卉領域を自動抽出することを目的としている。従来手法では、花卉の色や対象物体の位置を予めユーザが指定するといった制約条件があった。また、Saliency Map という視覚注意の情報が物体抽出において扱われることはなかった。そこで、本研究では、AdaBoost と Saliency Map を用いた Graph Cut による花卉領域の自動抽出手法を提案する。AdaBoost で花卉領域を検出し、物体と背景の色ヒストグラムをそれぞれ GMM に適用し尤度を求める。次に、Saliency Map を用いて視覚注意を引く強さを基に花卉領域を検出し、顕著性を事前確率と定義し、ベイズの定理から事後確率を求める。これにより seed を与えず Graph Cuts の t-link のコストを与えることができ、高精度な花卉領域の自動抽出が実現できる。また本手法は、花以外の物体に対しても同様に適用可能な手法となっている。

キーワード グラフカット, 領域抽出, AdaBoost, 顕著性マップ

Automatic Segmentation using Graph Cuts based on AdaBoost and Saliency Map

Keita FUKUDA[†], Tetsuya TAKIGUCHI^{††}, and Yasuo ARIKI^{††}

[†] Graduate School of Engineering, Kobe University, 1-1, Rokkodai, Nada, Kobe, Hyogo

^{††} Organization of Advanced Science and Technology, Kobe University, 1-1, Rokkodai, Nada, Kobe, Hyogo

E-mail: [†]fukuda@me.scitec.kobe-u.ac.jp, ^{††}{takigu,ariki}@kobe-u.ac.jp

Abstract In this paper, our goal is automatic segmentation of flower region which is processed before recognition in our flower recognition system. In conventional method, it is difficult to segment region without color or location information given by users and saliency (visual attention) is not considered yet. The proposed method can segment flower region automatically by using Graph Cuts based on AdaBoost learning and Saliency Map. AdaBoost learning determines flower location and the pixels inside and outside the rectangle specified by AdaBoost are used to build two Gaussian mixture models (GMM). Secondly, flower regions are detected based on visual attention by using Saliency Map and prior probability is defined as saliency. Posterior probability is computed from prior probability and likelihood and is given t-link cost in Graph Cuts. Our method is applicable to other objects.

Key words Graph Cuts, Region Segmentation, AdaBoost, Saliency Map

1. はじめに

一般物体認識における重要な問題の一つに、セグメンテーションの問題がある。セグメンテーションとは、画像内に存在している物体領域を抽出することであり、認識の前処理として重要な問題である。本研究では、我々が既に提案した“マルチ識別器を用いた花画像検索システム [1]”の前処理である花卉領

域の自動抽出を目的としている。

従来の高精度なセグメンテーションの一手法として、Graph Cuts が挙げられる [2] [3] [8]。Graph Cuts は、各領域からエネルギー関数を定義し、大域最小解を求めることが可能で、領域と境界の両方の特性を用いたセグメンテーションが実現できるという利点がある。

Graph Cuts を用いたセグメンテーション手法として、Boykov

らにより Interactive Graph Cuts [2] [3] が提案されている. Interactive Graph Cuts では, ユーザーが画像に対して物体と背景にそれぞれラベルを与え, 画像からノードとエッジを持つグラフを作成し, minimum cut/ max flow algorithm [5] で定義したエネルギー関数の最小化を行う. また Rother らは, 矩形領域により物体領域と背景領域を指示することでラベルを与え, セグメンテーション結果を再学習し Graph Cuts を繰り返し行う Grab Cuts [4] を提案している. しかし, これらの手法は, 予めユーザが手動でラベルを与える必要があり, 自動化は困難であった.

このような問題を解決するために, Han らが AdaBoost と Graph Cuts を用いた自動抽出手法 [6] を提案している. AdaBoost により, 物体領域を検出し, 物体と背景の色ヒストグラムを学習し, Graph Cuts を繰り返して領域抽出する手法である. 我々は画像中の物体領域は, 背景領域に比べ視覚注意を強く引きやすい傾向があると考え, それらの情報 (Saliency) を自動物体抽出に用いることで, より精度の高い自動抽出が実現できると考えた.

そこで本稿は, AdaBoost と Saliency Map を用いた Graph Cuts による花卉領域の自動抽出法を提案する. 2. では提案手法と提案手法に用いた各手法について述べ, 3. で従来手法 [6] との比較実験とその考察について述べ, 4. で問題点, 今後の課題についてまとめる.

2. 提案手法

図 1 に提案手法の概要を示す.

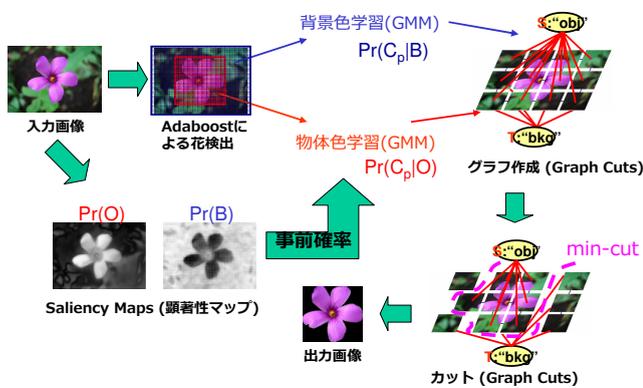


図 1 提案する花卉領域の自動抽出手法

まず, HaarLike 特徴を用いた AdaBoost 法 [11] によって, 入力画像から花卉領域を検出する. そして, 検出された矩形領域から物体 (O) と背景 (B) の色情報 $C_p(p$ は注目画素) を基に, GMM (Gaussian Mixture Model) の確率モデルを推定し, 尤度 $Pr(C_p | O)$, $Pr(C_p | B)$ を求める. 従来の Graph Cuts では手動でラベル (seed) を与える必要があるが, 提案手法では, 自動検出された矩形領域から色情報を学習するため, seed が不要である.

また入力画像から Saliency Map (顕著性マップ) [7] を定義することで, 画像の事前確率 $Pr(O)$, $Pr(B)$ を定義する. Saliency

Map は, 視覚注意を引く強さを表すマップであり, 特に物体領域では, 背景領域に比べ, 顕著性が高いと考えられる. そこで Saliency Map の情報を Graph Cuts の t-link の事前確率として用いることで, 物体領域の空間情報を得る.

GMM で求めた尤度と Saliency Map の事前確率から, ベイズの定理により事後確率 $Pr(O | C_p)$, $Pr(B | C_p)$ を計算し, 2.3.1 節の表 1 に従い, Graph Cuts の全てのエッジにコストを与える.

最後に Graph Cuts によるセグメンテーションを繰り返すことで, 花卉領域の自動抽出を実現する. 一段階前の抽出結果を基に再学習することで精度が向上するため, 繰り返し処理を行った. 本手法では, AdaBoost を用いて花を学習し, 花に特化しているが, 他の物体に対しても同様に適用が可能である.

提案手法で用いた各手法について, 2.1~2.3 節でそれぞれ述べる.

2.1 AdaBoost による花卉領域検出

本節では, 花卉領域の検出手法について述べる. 花は, 多種多様な色合いを持つため, 色情報の個体差が大きいと考えられる. そこで本論文では, Viola, Jones らによって提案された, Haar-like 特徴に基づく AdaBoost 法 [11] を用いた. これは, 図 2 のような Haar-like 特徴を特徴量とする弱学習器をカスケード型に組み合わせて, 強学習器を構成する手法である. 花卉領域を高速に検出することができる.

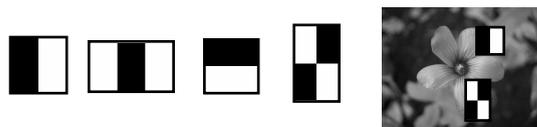


図 2 Haar-like 特徴に基づく AdaBoost 法

花卉領域を検出する目的は, 花卉の色情報を学習するためである. 矩形領域の内側を物体色, 外側を背景色と定義し, それぞれの色ヒストグラムを Gaussian Mixture Model に適用することで, 尤度 $Pr(C_p | O)$, $Pr(C_p | B)$ を求める. これにより 2.3 節で述べる Graph Cuts に対して, seed を与えることなく t-link のコストを算出することが可能となる.

2.2 Saliency Map による事前確率

本節では, 画像中の物体領域を視覚注意から算出する手法について述べる. 本稿では, Itti, Koch らに提案された Saliency Map (顕著性マップ) [7] を用いた. Saliency Map は, 画像中に存在する視覚的注意を引く領域を表現することができるため, 物体領域は背景領域に比べ, 顕著性が高いと考えられる. そこで, Saliency Map の情報を Graph Cuts の t-link の事前確率として用いることで, 物体領域の空間情報を得ることができる.

本研究では図 3 に示すように画像各部の明るさや色, 線方向等の局所的な変動量を各部の特徴として算出し, 顕著性と定義した.

まず入力画像から Gaussian Pyramid によりダウンサンプリングした 9 枚のスケール (スケール $c \in \{0..8\}$ で, 0 は原画像, 8 は $1/256$ の縮小) の画像を作成する. 次に, 各画素において,

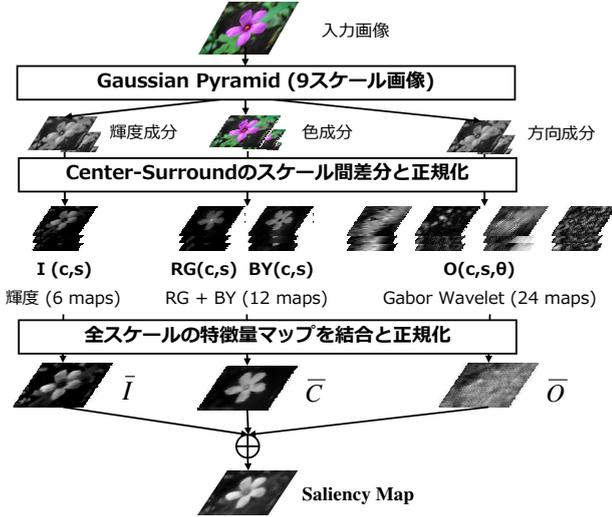


図3 Saliency Map の作成

Center-Surround のスケール間差分を求め、特徴量マップを作成する。Center とはスケール $c \in \{2, 3, 4\}$ のスケール画像上の画素であり、Surround とは $\delta \in \{3, 4\}$ とすると、スケール $s = c + \delta$ のスケール画像上の対応する画素である。対応する画素のスケール間差分は、注目画素とその周辺画素との差分を表しており、注目画素が白で、周辺が黒、あるいはその逆の場合に、大きな値をとる。本研究では、特徴量を参考文献[7]と同様にスケール $c \in \{0..8\}$ の輝度成分 $I(c)$ 、色成分 赤 $R(c)$ 、緑 $G(c)$ 、青 $B(c)$ 、黄 $Y(c)$ 、方向成分 $O(c, \theta)$ とした。輝度成分 $I(c)$ 、色成分 $R(c)$ 、 $G(c)$ 、 $B(c)$ 、 $Y(c)$ は、それぞれ RGB を用いて次式で定義される。

$$I = (r + g + b)/3 \quad (1)$$

$$R = r - (g + b)/2 \quad (2)$$

$$G = g - (r + b)/2 \quad (3)$$

$$B = b - (r + g)/2 \quad (4)$$

$$Y = (r + g)/2 - |r - g|/2 - b \quad (5)$$

また画像座標 (x, y) の方向成分 $O(x, y, \theta)$ としては、輝度成分 $I(x, y)$ に式 (6) のように Gabor フィルタ $\psi(x_0, y_0, \theta)$ を畳み込み、振幅成分を求めた。 h_x, h_y はフィルタの窓幅、 θ はフィルタの回転角であり、本手法では $h_x = 8, h_y = 8, \theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ の四方向を用いた。

$$O(x, y, \theta) = \sum_{x_0=-h_x}^{h_x} \sum_{y_0=-h_y}^{h_y} \psi(x_0, y_0, \theta) I(x + x_0, y + y_0) \quad (6)$$

$$\psi(x_0, y_0, \theta) = \frac{K^2}{\sigma^2} \exp\left(-\frac{(x_0^2 + y_0^2)K^2}{2\sigma^2}\right) \cdot \exp\left(j\{Kx_0\cos\theta + Ky_0\sin\theta\}\right) \quad (7)$$

次に、以下の式で、Center $c \in \{2, 3, 4\}$ と Surround $s = c + \delta$ ($\delta \in \{3, 4\}$) のスケール間差分 (\ominus) を求め、特徴量マップ

を作成する。

$$I(c, s) = |I(c) \ominus I(s)| \quad (8)$$

$$RG(c, s) = |(R(c) - G(c)) \ominus (G(s) - R(s))| \quad (9)$$

$$BY(c, s) = |(B(c) - Y(c)) \ominus (Y(s) - B(s))| \quad (10)$$

$$O(c, s, \theta) = |(O(c, \theta) \ominus O(s, \theta))| \quad (11)$$

式 (9), (10) は、受容野が赤でオン、緑でオフといった色の二重反対ユニットになっていることに基づいている。 $I(c, s)$, $RG(c, s)$, $BY(c, s)$ は c の 3 通りと s の 2 通りで 6 マップ存在する。 $O(c, s, \theta)$ は c の 3 通り、 s の 2 通り、 θ の 4 通りで合計 24 マップ存在する。作成された特徴量マップをさらに次式で結合し、3 ch 特徴量マップを作成する。なお $N(\bullet)$ は各特徴量マップの正規化処理を表す。

$$\bar{I} = \oplus_c \oplus_s N(I(c, s)) \quad (12)$$

$$\bar{C} = \oplus_c \oplus_s [N(RG(c, s)) + N(BY(c, s))] \quad (13)$$

$$\bar{O} = \sum_{\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}} \oplus_c \oplus_s N(O(c, s, \theta)) \quad (14)$$

最後に、これらを次式のように線形和で統合することで、顕著性 *Saliency* を求めた。なおそれぞれの特徴量マップの重みは実験的に決定した。

$$Saliency = (0.4 * N(\bar{I}) + 0.4 * N(\bar{C}) + 0.2 * N(\bar{O})) \quad (15)$$

一般的に、画像中に存在する物体領域は、背景領域に比べ、視覚的注意を引き、特に花では、背景が葉である場合が多く、花卉領域では周辺に比べ、より顕著性が現れるため、この顕著性をセグメンテーションにおける空間情報の事前確率として与えた。事前確率 $Pr(O)$, $Pr(B)$ を次式で定義する。

$$\begin{cases} Pr(O) = Saliency \\ Pr(B) = 1 - Pr(O) \end{cases} \quad (16)$$

この事前確率は Graph Cuts のセグメンテーションで用いる。2.3.2 節で詳細を述べる。

2.3 Graph Cuts によるセグメンテーション

本節では、Graph Cuts によるセグメンテーションについて述べる。画像 P に対する各ピクセルを $p \in P$ としたとき、ラベルを $A = (A_1, \dots, A_p, \dots, A_{|P|})$ の二値ベクトルとし、各 A_p には物体 ("obj") か背景 ("bkg") のラベルが与えられる。また p の近傍のピクセルを $q \in N$ と定義する。Graph Cuts ではエネルギー関数を式 (17) のように定義する。

$$E(A) = \lambda \cdot R(A) + B(A) \quad (17)$$

$\lambda (\geq 0)$ は、領域に対するペナルティ関数 $R(A)$ と、境界に対するペナルティ関数 $B(A)$ の比率を表す。またそれぞれのペナルティ関数は式 (18) (19) のように定義する。

$$R(A) = \sum_{p \in P} R_p(A_p) \quad (18)$$

$$B(A) = \sum_{\{p, q\} \in N} B_{\{p, q\}} \cdot \delta(A_p, A_q) \quad (19)$$

and

$$\delta(A_p, A_q) = \begin{cases} 1 & (\text{if } A_p \neq A_q) \\ 0 & (\text{otherwise}) \end{cases} \quad (20)$$

$R(\cdot)$ はピクセル p が物体もしくは背景のモデルにどれだけ適合しているかを示す関数である。 $B_{\{p,q\}}$ は近傍のピクセルとの関係を示し、 p と q の輝度値が似ていれば大きな値を出力する関数である。 以上によりエネルギー関数 $E(A)$ を最小とするラベル A を求めることで、セグメンテーションを行う。

2.3.1 グラフの作成とカット

Graph Cuts では、画像から図 4 のようにノードとエッジを持つグラフを作成し、minimum cut/ max flow algorithm [5] で定義したエネルギー関数の最小化を行う。

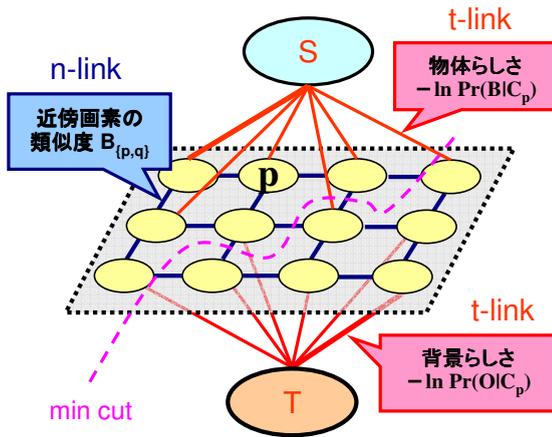


図 4 画像 (3 × 4 ピクセル) のグラフ作成

まず、画像の各ピクセルに対応したノードと、sink (T) と呼ばれるターミナルを用意する。各ピクセルに対応したノード間を結ぶエッジを n-link と呼ぶ。また各ノードからターミナルを結ぶエッジを t-link と呼ぶ。次に、表 1 に従い、全てのエッジに対してコストを与える。本手法では物体と背景の色情報を学習する過程を 2.1 節で述べた AdaBoost の花卉検出結果を基に行うため、seed が存在しない。t-link のコストで用いた事後確率の推定方法は、2.3.2 節で詳細を述べる。

表 1 エッジのコスト

edge	cost	for
n-link	$B_{\{p,q\}}$	$\{p,q\} \in N$
t-link	$\lambda \cdot R_p(\text{"bkg"})$	$p \in P$
	$\lambda \cdot R_p(\text{"obj"})$	$p \in P$

表 1 の変数 $B_{\{p,q\}}$ を式 (21)、変数 $R_p(\text{"bkg"})$ 、 $R_p(\text{"obj"})$ を式 (22) で定義する。 I_p は輝度値であり、 $dist(p,q)$ は近傍との距離を表す。

$$B_{\{p,q\}} \propto \exp\left(-\frac{(I_p - I_q)^2}{2\sigma^2}\right) \cdot \frac{1}{dist(p,q)} \quad (21)$$

$$\begin{cases} R_p(\text{"obj"}) = -\ln Pr(O | C_p) \\ R_p(\text{"bkg"}) = -\ln Pr(B | C_p) \end{cases} \quad (22)$$

最後に、作成したグラフに対して、最小カットを求める。式 (23) は、カット C が通る S 側から T 側へ向かうエッジの重み w_e の和を表し、この最小化問題を解く。なお式 (17) におけるラベル A の配置エネルギーとそれに対応するカットのコストは等価 [2] である。

$$|C| = \sum_{e \in C} w_e \quad (23)$$

min cut/max flow algorithm [5] を用いることでこの問題を解き、物体と背景のグラフを分割する。カットの後に、 S と繋がっているピクセルは物体、同様に T と繋がっているピクセルは背景とすることで、画像のセグメンテーションが実現する。

なお参考文献 [6] [9] と同様に、前回の処理結果から色情報を再学習し、繰り返し Graph Cuts のセグメンテーションをすることで、学習精度が向上するため、本研究でも繰り返し処理を用いた。

2.3.2 事後確率の推定 (t-link)

本節では t-link のコストとなる事後確率の推定について述べる。概要を図 5 に示す。

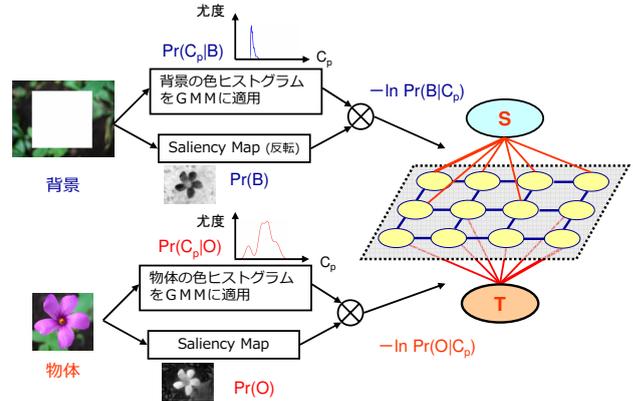


図 5 事後確率の推定

まず、2.1 節で述べた AdaBoost で検出した矩形領域の内側から物体の色ヒストグラム、外側から背景の色ヒストグラムを求め、GMM (Gaussian Mixture Model) の確率モデルを推定し、尤度 $Pr(C_p | O)$ 、 $Pr(C_p | B)$ を求める。また式 (24) で表される GMM のモデルパラメータの推定 ($\alpha_i, \mu_i, \Sigma_i$) には、EM algorithm を用いた。なお混合分布数は $K = 5$ とした。

$$Pr(C_p | \bullet) = \sum_{i=1}^K \alpha_i p_i(C_p | \mu_i, \Sigma_i) \quad (24)$$

次に、2.2 節で述べた Saliency Map から求めた事前確率 $Pr(O)$ 、 $Pr(B)$ と尤度 $Pr(C_p | O)$ 、 $Pr(C_p | B)$ を用いてベイズの定理より事後確率 $Pr(O | C_p)$ 、 $Pr(B | C_p)$ を計算し、式 (22) により、 $\{p,S\}$ と $\{p,T\}$ 間の t-link のコストを計算し、Graph Cuts によるセグメンテーションを行う。なお、検索対象となる物体領域の抽出を目的としているため、後処理で特徴量が得やすいように、複数個の領域が得られた場合は、面積最大の領域を結果とし、常に 1 つの領域が出力されるようにしている。

3. 実験

3.1 実験概要

花画像 150 枚に対して、抽出精度の比較実験を行った。Saliency Map は用いないで、AdaBoost のみを用いた Graph Cuts によりセグメンテーションを実行する従来手法 [6] を、比較対象とした。Graph Cuts に手動で seed を与え、正確に抽出したマスク画像を正解とし、各手法におけるセグメンテーション結果の誤検出率を求めた。参考文献 [9] と同様に、誤検出率は以下の式から求める。

$$\text{誤検出率 } Err[\%] = \left(\frac{\text{物体領域の誤検出ピクセル数}}{\text{全ピクセル数}} + \frac{\text{背景領域の誤検出ピクセル数}}{\text{全ピクセル数}} \right) \times 100 \quad (25)$$

以下、物体領域を背景領域と誤検出することを Over Segmentation、背景領域を物体領域と誤検出することを Under Segmentation とする。なお 2.1 節の AdaBoost の学習には、正画像 1332 枚、負画像 867 枚、カスケード数 15 を用いた。図 6 に、誤検出率の評価方法を示す。図中、赤色領域が、誤検出領域となる。この例では、Err 1.17% と低い誤検出率であるが、かなりの誤検出が生じていることが分かる。

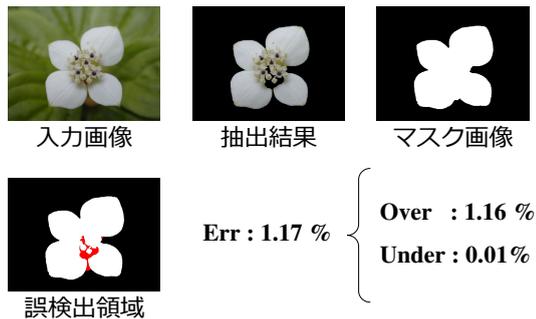


図 6 誤検出領域の評価方法

3.2 実験結果

花画像 150 枚に対するセグメンテーション結果を表 2 に示す。“AdaBoost 未検出”は AdaBoost の段階で画像から花卉領域が未検出で、色情報を学習することが不可能であった画像である。また AdaBoost で花卉領域を正確に検出できない場合なども考えられるが、この時、花卉の色情報が得られていれば、セグメンテーションは成功する。そのため最終的なセグメンテーション結果を基に、検出、誤検出を判断した。参考文献 [9] と同様に抽出精度 2.0% を基準とした。

表 2 誤検出枚数

	従来手法 [6]	提案手法
AdaBoost 未検出	24	24
誤検出 (Err 2.0% 以上)	30	23
検出 (Err 2.0% 未満)	96	103
Total (枚)	150	150

従来手法 [6] と提案手法の平均誤差率を表 3 に示す。AdaBoost で未検出であった画像については誤差率が求められないため、平均値に含まれていない。

表 3 平均誤検出率 [%]

	従来手法 [6]	提案手法
Over	1.18	1.56
Under	2.35	0.60
Err (Over + Under)	3.53	2.16

次節で、比較実験結果の考察を述べる。

3.3 考察

本節で従来手法 [6] と提案手法による実験結果について考察を述べる。従来手法 [6] と提案手法において、セグメンテーション結果に差が表れたものを図 7 に提示する。

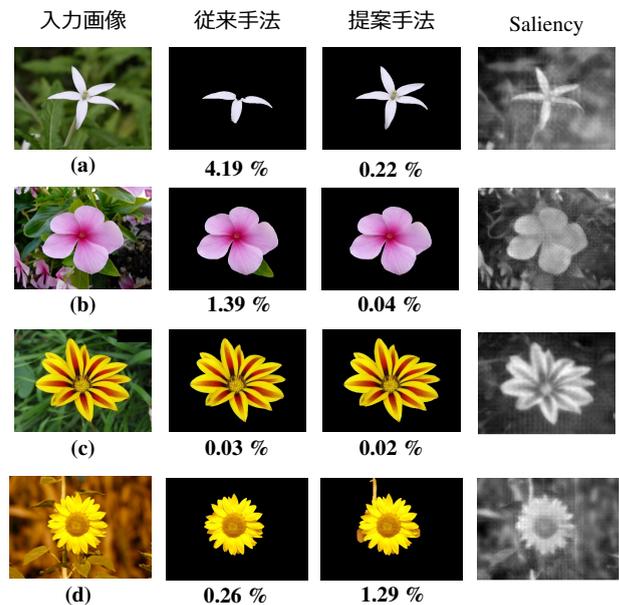


図 7 実験結果

(a) のように花卉 (物体) の面積が狭い場合では、矩形領域を基に色情報を学習すると、余分な背景領域を多く含むことになる。そのため従来手法では誤検出が生じるが、本手法では Saliency を用いることで、花卉の空間情報を事前確率で得るため、検出が可能となった。(b) でも同様に Saliency は物体領域の形状を大まかに捉えることができています。

(c) では複雑な色合いを持つ物体であるが、従来手法 [6]、本手法ともに検出することが可能である。

(d) では Saliency が枝の部分にも現れ、従来手法に比べ、誤検出率が高くなった。このようなエッジが強い部分や照明変化などがある画像では、Saliency が正確に取れず、誤検出率が高くなる。これはコントラストの高い領域や、小さな局所的に特徴のある領域に Saliency が集中しやすいためである。対処法として、参考文献 [10] のような概念レベルでの Saliency を定義することで、さらに改善できると考えている。

また、本稿では、花卉領域のセグメンテーションについて述べているが、本手法は、AdaBoost による物体検出の学習を他

の物体に適用することで、他物体のセグメンテーションに拡張することが可能である。

今後の課題として、AdaBoostの検出精度向上が挙げられる。特に花卉は形状が不安定なため、検出精度が低く、さらに特化した有効な特徴量を検討する必要があると考えている。

4. ま と め

本稿では、AdaBoostにより花卉領域と背景の確率モデルを推定し、Saliency Mapにより視覚注意を引く領域を抽出し、これを花卉領域の事前確率として、Graph Cutにより花卉領域を自動抽出する手法を提案した。Saliency Mapを用いることで、物体の空間情報を扱うことができ、高精度な自動抽出結果が得られた。今後の課題は、AdaBoostの検出精度を向上させ、また物体の概念レベルのSaliencyを用いることで、さらに高精度な自動抽出を検討する予定である。

文 献

- [1] 福田恵太, 滝口哲也, 有木康雄: “マルチ識別器を用いた画像検索による花図鑑システム”, MIRU2007, pp.1498-1503, 2007-08
- [2] Y. Boykov, M.P.Jolly, “Interactive graph cuts for optimal boundary & region segmentation of objects in N-D images,” In IEEE International Conference on Computer Vision and Pattern Recognition, volume 2, pages 731-738, 2004.
- [3] Y.Boykov, G.Funka-Lea, “Graph Cuts and Efficient N-D Image Segmentation,” International Journal of Computer Vision, 70(2):109-131, 2006.
- [4] C. Rother, V. Kolmogorov, A. Blake, “GrabCut: Interactive Foreground Extraction using Iterated Graph Cuts,” ACM Transactions on Graphics (SIGGRAPH'04), 2004
- [5] Y. Boykov, V. Kolmogorov, “An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimization in Vision,” PAMI, vol. 26, no. 9, pp. 1124-1137, Sept. 2004.
- [6] D.Han, W.Li, X.Lu, T.Wang and Y.Wang, “Automatic Segmentation Based on AdaBoost Learning and Graph-Cuts,” ICIAR06, pp. 215-225, 2006.
- [7] L.Itti, C.Koch and E.Niebur, “A Model of Saliency-based Visual Attention for Rapid Scene Analysis,” IEEE Trans. Pattern Analysis and Machine Intelligence, Vol.20, No.11, pp.1254-1259, 1998.
- [8] 石川博, “グラフカット”, 情報処理学会研究報告, 2007-CVIM-158-26, pp. 193-204, 2007.
- [9] 永橋知行, 藤吉弘亘, 金出武雄, “平滑化処理の繰り返しによる画像セグメンテーションのためのグラフカット”, MIRU2007, pp. 241-248, Jul, 2007.
- [10] T.Liu, J.Sun, N.Zheng, X.Tang and H.Shum, “Learning to Detect A Salient Object,” CVPR07, pp. 1-8, 2007.
- [11] P. Viola, M. Jones, “Rapid Object Detection using a Boosted Cascade of Simple Features,” In Proc. IEEE Conf. on Computer Vision and Pattern Recognition, Kauai, USA, pp.1-9, 2001