

AdaBoost と Saliency Map を用いた Graph Cuts による物体領域の自動抽出法 Automatic Segmentation of object region using Graph Cuts based on AdaBoost and Saliency Map

福田 恵太† Keita Fukuda
滝口 哲也‡ Tetsuya Takiguchi
有木 康雄‡ Yasuo Ariki

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。

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 [1] が挙げられる。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。

しかし、予めユーザが手動でラベルを与える必要があるため、自動化は困難であり、また物体抽出に視覚注意の情報が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 Cuts により物体領域の自動抽出手法を提案する。

2. 提案手法の概要

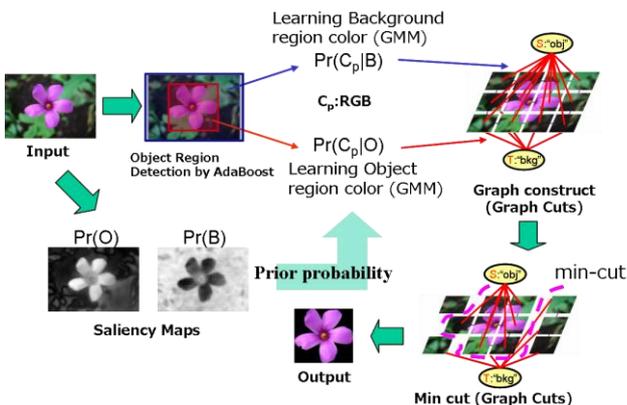


図 1. 提案する物体領域の自動抽出手法

図 1 に提案する物体領域の自動抽出法の流れを示す。まず、Haar-Like 特徴を用いた AdaBoost 法によって、入力画像から物体領域を検出する。これは 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。図 1 の例のように、花領域を検出する場合、花画像を正画像とし、学習する必要がある。

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。

† 神戸大学大学院工学研究科

‡ 神戸大学自然科学系先端融合研究環

従来の Graph Cuts では物体と背景の学習のために、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) 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、画像中の視覚注意を引く強さを表すマップを示し、この情報を 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、4.1 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、物体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、繰り返し処理を行う。

3. Saliency Map による事前確率の推定

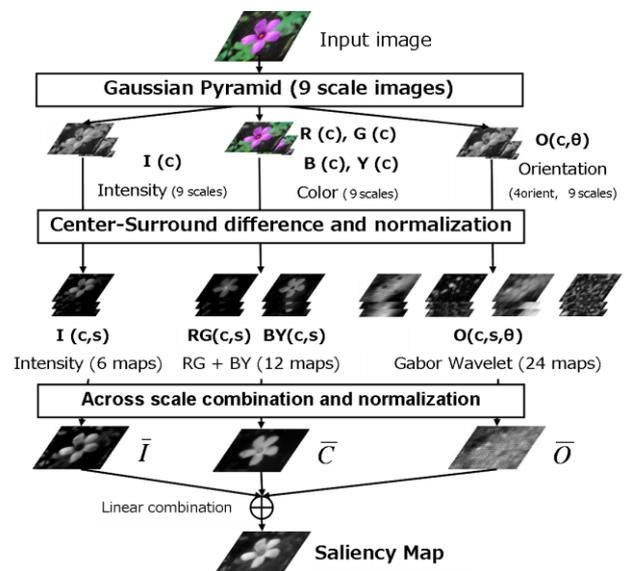


図 2. Saliency Map の作成

本章では、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。本論文では、Itti, Koch らによって提案された Saliency Map (顕著性マップ) [2] 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、一般的に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。

図2に Saliency Map について示す. 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枚のスケールの画像を作成し, 各画素で特徴量のスケール間差分を求め, 特徴量マップを作成する. 本研究では, 参考文献[2]と同様に, 特徴量に輝度成分, 色成分, 方向成分を用いた.

4. Graph Cuts によるセグメンテーション

4.1 Graph Cuts

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. 画像の各ピクセル $p \in P$ に対応したノードと, sink (T)と source (S)と呼ばれるターミナルを作成する. 各ピクセルに対応した近傍ノード間 $\{p, q\}$ を結ぶエッジを n-link と呼び, また各ノードからターミナルを結ぶエッジ $\{p, S\}$, $\{p, T\}$ を t-link と呼ぶ. それぞれ表1に従い, 全てのエッジにコストを与える.

表1 エッジに与えるコスト

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

$B_{\{p, q\}}$ は注目画素 p と近傍画素 q の輝度値が類似しているほど, 値が大きくなる関数である. また $R_p(\cdot)$ はそれぞれ物体及び背景らしさを示す事後確率であり, 4.2 節で詳細を述べる. また λ は n-link と t-link の重み比率である.

最後に, 作成したグラフから mincut /maxflow algorithm を用いて, 最小カットを求めることでセグメンテーションを実現する.

4.2 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3に示す.

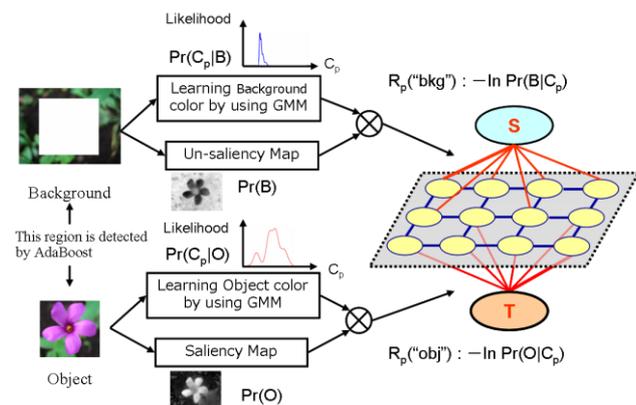


図3. t-link のコストとなる事後確率の推定

2章で述べた AdaBoost で検出した矩形領域からそれぞれ物体と背景の色ヒストグラムを求め, Gaussian Mixture

Model の確率モデルを推定し, 尤度 $\Pr(C_p|O)$, $\Pr(C_p|B)$ をそれぞれ求める.

次に, 3章で述べた Saliency Map から事前確率 $\Pr(O)$, $\Pr(B)$ を定義する. Saliency の強さを最大1 最小0 に正規化し, $\Pr(O)$ に与え, 反対に $\Pr(B)$ に $1 - \Pr(O)$ を与える.

最後に, ベイズの定理により事後確率 $\Pr(O|C_p)$, $\Pr(B|C_p)$ を t-link のエッジのコストとして与え, Graph Cuts セグメンテーションを行う.

5. 実験結果と考察

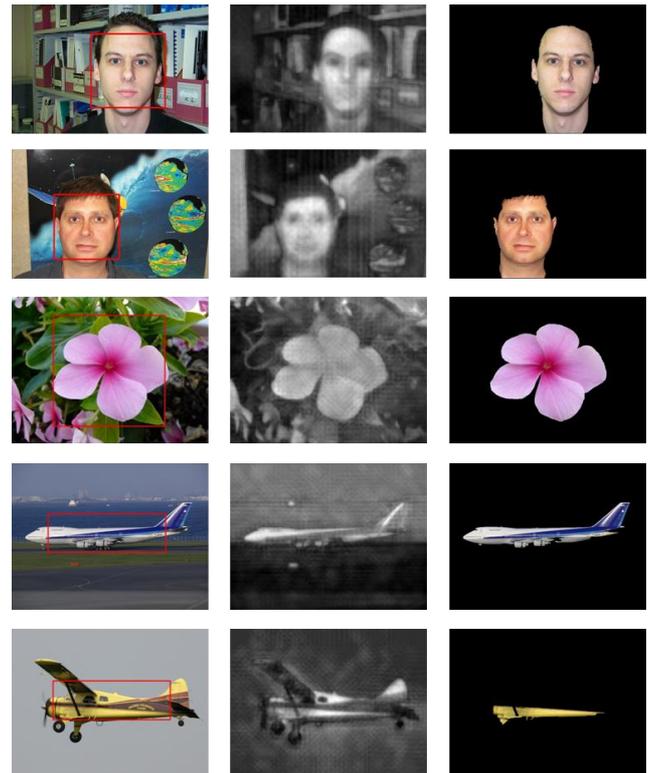


図4. 実験結果

図4に実験結果を示す. 左から AdaBoost で検出された矩形と元画像, 物体の事前確率を示す Saliency Map, 抽出結果となる. 物体が正確に検出されていない場合でも, 物体の色情報が学習できれば, 抽出が可能である. 問題点として, 飛行機のように構成する色が多数ある物体に対して, 物体全体に顕著性が現れない場合があり, 抽出が困難であった.

6. まとめ

本論文では, AdaBoost と Saliency Map を用いた Graph Cuts により物体領域の自動抽出手法を提案した. 今後の課題として, 物体全体を顕著性と捉える Saliency の定義などが挙げられる.

参考文献

- [1] Y. Boykov, M.P.Jolly, "Interactive graph cuts for optimal boundary & region segmentation of objects in N-D images."
- [2] L.Itti, C.Koch and E.Niebur, "A Model of Saliency-based Visual Attention for Rapid Scene Analysis."