

## 前景・背景色分布の同時マッチングによる画像セグメンテーション

谷合 竜典<sup>†a)</sup> ファン ヴェトクォク<sup>††</sup> 高橋 桂太<sup>†††</sup>  
苗村 健<sup>†</sup>

## Foreground-Background Image Segmentation Using Dual Distribution Matching

Tatsunori TANIAI<sup>†a)</sup>, Viet-Quoc PHAM<sup>††</sup>, Keita TAKAHASHI<sup>†††</sup>,  
and Takeshi NAEMURA<sup>†</sup>

あらまし 本研究では、画像の前景及び背景領域の近似的な色分布（色ヒストグラム）が与えられた際に、画像領域を前景と背景の二つに分割する画像セグメンテーション手法を提案する。我々のアプローチは、与えられた入力色分布と求める分割領域の色分布の類似度を直接評価するグローバル尺度に基づくものである。これは従来の画素ごとに独立なゆう度を与えるローカル尺度よりも優れた精度を有することが近年示されている。我々の提案する手法の最大の特徴は、前景と背景の二つの入力色分布を用いることであり、これによりグローバル尺度のロバスト性を大幅に向上させる。そのため我々は、二つの入力色分布と求めるセグメンテーションとの適合性を同時に評価する新たな数学的モデルを提案し、更に各色分布マッチング項の重みを対応する領域面積に比例するように与えた。実験では、画像や動画に対するセグメンテーションを行い、本手法の有効性を示しただけでなく、グローバル尺度とローカル尺度のロバスト性に関する詳細な比較検証を行った。

キーワード 画像セグメンテーション, グラフカット, エネルギー最適化, 高階エネルギー関数

## 1. ま え が き

本論文では、画像の前景及び背景の近似的な色分布（色ヒストグラム）のみを入力とし、対応する前景・背景領域を求める2値セグメンテーション問題を扱う。例えば動画を処理する場合、そのような色分布は前のフレームから得られる。セグメンテーションを行う際の手掛りとして、色分布の情報以外にも、例えばユーザの入力により前景背景の位置的な情報を与えたり [1]~[3]、動画であれば物体の時系列上の動きを追跡することで更なる手掛りを与える [4], [5] ことは可能である。しかし本研究では、あえて色分布以外の入力要素を排除することで、入力色分布のみから対応領域

を求めるための根本的なアルゴリズムの導出に論点を絞る。すなわち、ここでの本質的な問いは、いかにして入力色分布とセグメンテーションとの適合性（アピアランス適合性）を評価するかにある。

近年まで、アピアランス適合性はローカル尺度が主流であった [1]~[3], [6]。ローカル尺度は、各画素  $p$  が前景か背景かを表すラベル値  $L_p$  に対して、画素ごとに独立のゆう度を与えるもので、unary term の和  $\sum_p u_p(L_p)$  として表される。通常はこれに、隣接する2画素間の連続性を記述する pairwise term の和  $\sum_{(p,q)} v_{pq}(L_p, L_q)$  を加えることで、全体のエネルギーを Markov Random Field (MRF) モデルとして定義する。このようなエネルギーの最適化は、MRF 上での MAP 推定に相当し、グラフカット [7], [8] と呼ばれる最適化手法を用いて直接的に大域解を求められる。しかし一般に、ローカル尺度はモデルが簡素であるため、縮小バイアスにより物体の細端部が切断されやすい問題がある [9]。

一方、最近の研究 [10]~[12] により、領域全体のアピアランス適合性を記述するグローバル尺度が、従来のローカル尺度よりも有効であることが示された。このグローバル尺度は、入力された色分布  $\mathcal{H}$  と抽

<sup>†</sup> 東京大学大学院情報理工学系研究科, 東京都  
Graduate School of Information Science and Technology,  
The University of Tokyo, 7-3-1 Hongo, Bunkyo-ku, Tokyo,  
113-8656 Japan

<sup>††</sup> (株) 東芝研究開発センター, 川崎市  
Toshiba Corporate Research and Development Center, 1  
Komukai Toshiba-cho, Saiwai-ku, Kawasaki-shi, 212-8582  
Japan

<sup>†††</sup> 名古屋大学大学院工学研究科, 名古屋市  
Graduate School of Engineering, Nagoya University, Nagoya-  
shi, 464-8603 Japan

a) E-mail: taniai@nae-lab.org

出領域の色分布  $\mathcal{P}(\mathbf{L})$  との適合性をアピアランスの評価尺度とするもので、例えば二つの色分布の類似度の負値  $-\text{similarity}(\mathcal{P}(\mathbf{L}), \mathcal{H})$  や、色分布の距離  $\text{distance}(\mathcal{P}(\mathbf{L}), \mathcal{H})$  として定式化される。しかし、このようなグローバル尺度は、直接的に unary term として定式化できないため、最適化はやや複雑となる。なぜなら、全ての画素のラベル値  $\mathbf{L}$  が定まらない限り、その抽出領域の色分布  $\mathcal{P}(\mathbf{L})$  も計算することができないからである。

Rother ら [10] の提案した Trust Region Graph Cut (TRGC) は、このようなグローバル尺度を、近似的に MRF モデルに取り入れた初めての例である。TRGC 法では、アピアランス適合性を二つの色分布の差分の  $l_1$  ノルムとして定式化した。しかし情報理論の観点から、差分の  $l_1$  ノルムよりも Bhattacharyya 尺度 [13] の方が分布の比較尺度として優れていることが指摘されている [11], [14]。

Ayed ら [11] は、アピアランス適合性の尺度を Bhattacharyya 係数 [13], [14] として定式化し、入力色分布に対し、色分布が適合する画像領域を抽出する手法 Bhattacharyya Measure Graph Cut (BMGC) を提案した。BMGC 法もまた、グローバル尺度をグラフカットで解ける形に落とし込んだもので、同じく MRF モデルに基づく TRGC 法や、Active Contour モデルに基づく他の手法 [15]~[17] よりも、高い精度と効率を有することが報告された。しかし、BMGC 法は入力色分布として、本来は未知であるはずの物体領域の真の色分布を必要とし、近似的な入力色分布では大きく精度を損なう場合がある [12]。

この問題に対して文献 [12] では、Iterated Distribution Matching (IDM) を提案している。IDM 法では、入力色分布が抽出領域の色分布と適合するという従来の仮定（適合仮定）に加え、その相補領域の色分布とは異なるという新たな仮定（相補仮定）を設けることで、バウンディングボックスで得られるような近似的な入力色分布に対しても比較的精度の良い結果が得られることを示した。しかし、前景と背景の色分布が似ている画像などに対して、この仮定を直接用いることは必ずしも有効ではない。このことは本論文の 4.2.3 にて実証する。

これまでに提案されてきたグローバル尺度に分類されるセグメンテーション手法 [10]~[12] はいずれも、前景あるいは背景どちらかの入力色分布に対して、それと適合する画像領域を抽出するという基本方針をも

つ。一方、本研究では、前景及び背景の二つの入力色分布を用いて、両者の適合性を同時に評価する新たな数学的モデルを提案し、近似的な入力色分布に対してもロバストで高精度なセグメンテーションを実現する。

以下に本論文の構成を述べる。2. では、提案する前景背景の同時マッチングモデルの定式化を行う。特に 2.1 では、アピアランスの評価尺度を前景マッチング項と背景マッチング項の和として与えることを述べ、2.2 では、それらの項の適切な重みパラメータを導出する。この重みパラメータの導出は、本論文の最も重要な貢献である。このような重みパラメータの推定問題は、純粋に一つの入力色分布に対してマッチングを行う手法 [10], [11] では存在しなかった問題であり、IDM 法 [12] においても、各項の重みは常に 1 に固定され考慮されていなかった。3. では、BMGC 法 [11] を拡張する形で提案する最適化手法を示す。4. では実験により提案手法の有効性を示す。ここでは、ローカル尺度による手法 [1] や、BMGC 法 [11], IDM 法 [12] と比較しながら、導出した重みパラメータの有効性、前景背景を同時にマッチングすることの有効性、ローカル尺度に対するグローバル尺度の有効性の三つを主な観点として検証を行う。5. では、本論文の結論と今後の展望を述べる。なお、本論文は文献 [18], [19] をもとに拡張したものである。

## 2. 前景・背景色分布の同時マッチング

### 2.1 推定モデルの定式化

画像の座標集合  $P \subset \mathbb{R}^2$  に対して、2 値セグメンテーションラベル  $\mathbf{L}$  を割り当てる問題を考える。 $\mathbf{L}$  は画像の各画素  $p$  に対し前景  $F$  または背景  $B$  をとり、 $\mathbf{L} = \{L_p | L_p \in \{F, B\}, \forall p \in P\}$  とする。画像の前景領域を  $\mathbf{R}_F^L = \{p \in P | L_p = F\}$ 、背景領域を  $\mathbf{R}_B^L = \{p \in P | L_p = B\}$  と表す。更に画像領域  $\mathbf{R}_l^L$  ( $l = F, B$ ) の色分布を  $\mathcal{P}_l^L$  とし、和が 1 になるように正規化して定める。

本研究では、入力として前景と背景の近似色分布  $\mathcal{H}_F \simeq \mathcal{P}_F^{L^*}$ 、 $\mathcal{H}_B \simeq \mathcal{P}_B^{L^*}$  のみが与えられることを想定する。ただし  $L^*$  は  $\mathbf{L}$  の真値とする。 $L^*$  の推定はエネルギー関数  $\mathcal{E}(\mathbf{L})$  を最小化するラベルを求めるときで行う。 $\mathcal{E}(\mathbf{L})$  は

$$\mathcal{E}(\mathbf{L}) = \underbrace{\lambda_F \mathcal{M}_F(\mathbf{L})}_{\text{前景マッチング項}} + \underbrace{\lambda_B \mathcal{M}_B(\mathbf{L})}_{\text{背景マッチング項}} + \underbrace{\lambda_S \mathcal{S}(\mathbf{L})}_{\text{平滑化項}} \quad (1)$$

とし、 $\mathcal{M}_l(\mathbf{L})$  は色分布の類似度  $B(\cdot, \cdot)$  の負値

$$M_l(\mathbf{L}) = -B(\mathcal{P}_l^L, \mathcal{H}_l) \quad (l = F, B) \quad (2)$$

とする。すなわちアピアランス適合性の尺度として、前景色分布の適合性を評価する前景マッチング項と、背景色分布の適合性を評価する背景マッチング項の和を与えることで、前景と背景の色分布の同時マッチングを行うモデルである。なお  $\lambda_S S(\mathbf{L})$  は 2 画素間のラベルの連続性を記述する平滑化項で、 $S(\mathbf{L})$  は pairwise term により表されるものとする。

ここで、画像領域  $\mathbf{R}_l^L$  の色分布  $\mathcal{P}_l^L$  は、離散確率分布  $\mathcal{P}_l^L(z) : Z \rightarrow \mathbb{R}$  である。ただし  $Z$  は、色空間  $C \subset \mathbb{R}^n$  (RGB 色空間では  $n = 3$ ) を離散的なビン  $z$  により量子化した離散色空間である。分布の推定には、適当なカーネル関数  $K_\zeta(\cdot), \zeta \in C$  によるカーネル密度推定  $\mathcal{P}_l^L(\zeta)$  を用い、更にそれを  $Z$  により量子化した離散確率分布

$$\forall z \in Z \quad \mathcal{P}_l^L(z) = \sum_{p \in \mathbf{R}_l^L} K_\zeta(I_p) / |\mathbf{R}_l^L| \quad (3)$$

として与える。なお、 $I_p \in C$  は画素  $p$  の色ベクトルとし、 $|\mathbf{R}|$  を領域  $\mathbf{R}$  の画素単位の面積  $|\mathbf{R}| = \sum_{\mathbf{R}} 1$ 、 $K_\zeta(I_p) = \int_z K_\zeta(I_p) d\zeta$  とする。カーネル関数  $K_\zeta(I_p)$  の選択には、一考の余地があり、例えば  $n$  次元ガウス関数  $\mathcal{N}(\zeta; I_p, \sigma^2)$  を与えれば、少ないサンプル数でもロバストに色分布を推定できる可能性もある [9]。そこで本論文では、定式上は  $K_\zeta$  に具体的な関数を与えることなく、一般化して議論を進める。ただし実際に計算する場合は、その簡単さから、カーネル関数  $K_\zeta(I_p)$  をディラックのデルタ関数 ( $I_p \neq \zeta$  に対して 0,  $I_p = \zeta$  を含む任意の区間で積分すると 1) とし、 $\mathcal{P}_l^L(z)$  をヒストグラムとして与えることを想定する。例えば、各成分が  $[0, 255]$  の値をとる RGB 空間を、 $4 \times 4 \times 4$  サイズの立方体ビン  $z$  で量子化すると、色分布は  $64 \times 64 \times 64$  の三次元ヒストグラムになる。

また、 $\mathcal{B}(\cdot)$  を確率分布の類似度の尺度である Bhattacharyya 係数とし、確率分布  $f(z), g(z)$  に対して

$$\mathcal{B}(f, g) = \sum_{z \in Z} \sqrt{f(z)g(z)} \leq 1 \quad (4)$$

と定義する。これは  $f = g$  のときに最大値 1 をとる。

以上の定義を用いると、式 (1) の  $\mathcal{E}(\mathbf{L})$  において  $\lambda_B = 0$  とした場合の  $\mathcal{E}_F(\mathbf{L})$  や、 $\lambda_F = 0$  とした場合の  $\mathcal{E}_B(\mathbf{L})$  は、BMGC 法 [11] のモデルと等価となる。本論文では、特に  $\mathcal{E}_F(\mathbf{L})$  による前景マッチング

BMGC 法を F-BMGC,  $\mathcal{E}_B(\mathbf{L})$  による背景マッチング BMGC 法を B-BMGC と呼び区別する。しかし、これらは図 1 に示すように、入力色分布  $\mathcal{H}_F$  や  $\mathcal{H}_B$  が正確でない場合には、真の解  $\mathbf{L}^*$  を捉えられない。一方で、式 (1) の提案する同時マッチングモデルは、前景背景の両方の色分布を用いた二つのコストの和であるため、真の解をより多くの場合で捉えられると期待される。これは、提案モデルがより多くの情報 (制約) を用いていることによる。本論文では、この提案手法を双分布マッチング法 (以下 DDM: Dual Distribution Matching) と呼ぶことにする。

## 2.2 モデルの重みパラメータ推定

提案する式 (1) のモデルは、 $\mathcal{E}(\mathbf{L})$  の最小解が真の解  $\mathbf{L}^*$  となるように、前景項及び背景項に対して適切な重みパラメータ  $\lambda_F, \lambda_B$  を与える必要がある。そこで本研究では、まず画像全体の色分布のマッチングという概念を新たに導入する。これにより、前景マッチングや背景マッチングといった個別の概念を統一的に扱うことができ、これらの重みパラメータを導くことができる。以下に導出を述べる。

まず、画像全体の色分布  $\Omega$  を任意のラベル  $\mathbf{L}$  により

$$\Omega(z) = r_F^L \mathcal{P}_F^L(z) + r_B^L \mathcal{P}_B^L(z) \quad (5)$$

と表す<sup>(注1)</sup>。ここで  $r_l^L$  は、画像全体の面積  $|\mathbf{R}|$  を用いて  $r_l^L = |\mathbf{R}_l^L| / |\mathbf{R}|$  ( $l = F, B$ ) と定義される  $\mathbf{L}$  の前景または背景の面積率である。一方で、画像全体の色分布の別の表現として  $\tilde{\Omega}$  を考え、前景背景の入力色分布  $\mathcal{H}_F, \mathcal{H}_B$  の線型結合により、以下のように近似的に表す：

$$\tilde{\Omega}(z; \eta) = \eta \mathcal{H}_F(z) + (1 - \eta) \mathcal{H}_B(z), \quad \eta \in [0, 1] \quad (6)$$

入力色分布が正確で、かつ  $\eta$  が真の前景の面積率  $r_F^{L^*}$  に一致すれば、 $\tilde{\Omega}$  は画像全体の色分布  $\Omega$  と一致する。




図 1 同時マッチングエネルギー関数  
Fig. 1 Dual matching energy function.

(注1)：画像全体の色分布  $\Omega$  は、その表現として式 (5) 右辺のような変数ラベル  $\mathbf{L}$  を含む形式を与えられるが、 $\Omega$  自体は  $\mathbf{L}$  によらない既知の分布であることに注意。

この  $\tilde{\Omega}$  と  $\Omega$  の二つの分布をなるべく等しくするため、両者の類似度を評価するエネルギー関数  $\mathcal{E}_A(\eta)$  を

$$\mathcal{E}_A(\eta) = -B \left( \Omega(z), \tilde{\Omega}(z; \eta) \right) \quad (7)$$

と定め、この  $\mathcal{E}_A(\eta)$  を最小化するパラメータを  $\eta_F = \arg \min \mathcal{E}_A(\eta)$  とする。なお、 $\eta_F, \eta_B = 1 - \eta_F$  は、 $\mathcal{H}_F, \mathcal{H}_B$  により画像全体の色分布を記述する際に、各分布がもつ相対的な影響度を表す。更に、 $\mathcal{H}_F$  と  $\mathcal{H}_B$  が同程度の正確さをもつ場合には、真のラベル  $L^*$  で表される面積率の推定値となること ( $\eta_F \simeq r_F^{L^*}$ ,  $\eta_B \simeq r_B^{L^*}$ ) が期待される。これは、式(5)より画像全体の色分布に対して  $\Omega(z) = r_F^{L^*} \mathcal{P}_F^{L^*}(z) + r_B^{L^*} \mathcal{P}_B^{L^*}(z)$  という表現が可能だからである。

一方で、付録に示すとおり、この関数  $\mathcal{E}_A(\eta)$  の上界であり、前景マッチングと背景マッチングの二つの項からなる以下の同時マッチング関数が求まる：

$$\mathcal{E}_A(\eta) \leq \sqrt{\eta} r_F^L \mathcal{M}_F(L) + \sqrt{(1-\eta)} r_B^L \mathcal{M}_B(L) \quad (8)$$

式(8)の右辺を  $D(L; \eta)$  と定義する。これはすなわち、画像全体の色分布の推定値  $\tilde{\Omega}$  の正しさを評価するエネルギー  $\mathcal{E}_A(\eta)$  と、前景背景の色分布をそれぞれマッチングさせるエネルギー  $D(L; \eta)$  が関連づけられることを意味する。ここで  $\mathcal{E}_A(\eta)$  や  $D(L; \eta)$  の関係を整理すると

$$\mathcal{E}_A(\eta_F) \leq \mathcal{E}_A(\eta) \leq D(L; \eta) \quad (9)$$

となるから、 $D(L; \eta)$  に対して  $\eta = \eta_F$  とすることは、その下界  $\mathcal{E}_A(\eta)$  を  $\mathcal{E}_A(\eta_F)$  に最小化することである。図2では、これらの関係を図示しているので参照されたい。また、このとき  $D(L; \eta_F)$  がその最小値  $\mathcal{E}_A(\eta_F)$  をとる条件として2通りの十分条件

$$r_F^L = \eta_F, \mathcal{P}_F^L(z) = \mathcal{H}_F(z), \mathcal{P}_B^L(z) = \mathcal{H}_B(z) \quad (10)$$

$$\mathcal{P}_F^L(z) \cdot \mathcal{H}_B(z) = \mathcal{P}_B^L(z) \cdot \mathcal{H}_F(z) = 0 \quad (11)$$

が与えられる。式(10)を適合条件、式(11)を相補条件とする。適合条件は、前景背景の入力色分布 ( $\mathcal{H}_F, \mathcal{H}_B$ ) とセグメンテーション結果から計算される前景背景の色分布 ( $\mathcal{P}_F^L, \mathcal{P}_B^L$ ) が一致し、かつ同様に2通りに表される面積率 ( $\eta_F, r_F^L$ ) が一致することを表す。相補条件は、前景と背景の色分布のインターセクションが零であることを表す。この適合条件及び相補条件はどちらもセグメンテーションを行う際の指標として有効とされるものである[12]。この条件が満たさ




図2  $\mathcal{E}_A(\eta)$  と  $D(L; \eta)$  の関係。理想的には、 $D(L; \eta_F)$  の最小点で、適合条件または相補条件が満たされ、 $D(L; \eta_F) = \mathcal{E}_A(\eta_F)$  が成立すると期待される。

Fig. 2 Relation of  $\mathcal{E}_A(\eta)$  and  $D(L; \eta)$ . It is ideally expected that  $D(L; \eta_F)$  is minimized to  $\mathcal{E}_A(\eta_F)$  when the matching or complementary condition is satisfied.

れるときに同時マッチング関数  $D(L; \eta_F)$  が最小化され、画像全体の色分布をマッチングする関数  $\mathcal{E}_A(\eta_F)$  に一致することになる。

以上により、アピアランスの評価関数を  $\mathcal{A}(L) = D(L; \eta_F)$  として与えたエネルギー関数

$$\mathcal{E}(L) = \underbrace{\sqrt{\eta_F} r_F^L \mathcal{M}_F(L) + \sqrt{\eta_B} r_B^L \mathcal{M}_B(L)}_{\text{アピアランス項 } \mathcal{A}(L)} + \underbrace{\left( \sqrt{\eta_F} r_F^L + \sqrt{\eta_B} r_B^L \right)}_{\lambda_S} \lambda_S \mathcal{S}(L) \quad (12)$$

を本論文の提案手法とする。ただし、式(12)の  $\lambda_S$  は、 $\mathcal{A}(L)$  の大きさ  $|\mathcal{A}(L)|$  の上界が  $\sqrt{\eta_F} r_F^L + \sqrt{\eta_B} r_B^L$  によっても制限されることを考慮して定めた。このエネルギー関数を最適化する際は、はじめに面積率の推定値  $\eta_F = \arg \min \mathcal{E}_A(\eta)$  を求めて<sup>(注2)</sup>、 $\eta_F$  と  $\eta_B = 1 - \eta_F$  により関数  $\mathcal{E}(L)$  を定め、それから次章で述べる方法により  $\mathcal{E}(L)$  を  $L$  について最適化する。一方、 $r_F^L$  と  $r_B^L$  はセグメンテーション  $L$  に依存して定義されているため、最初は1として与え<sup>(注3)</sup>、繰り返し演算で解を更新していく過程で、直前のセグメンテーション結果から計算される面積率に基づいて逐次更新する。すなわち、 $\eta_F$  と  $\eta_B$  は、入力色分布と対象画像の色分布の比較により、最初に一度だけ計算され、その後も変更されないが、 $r_F^L$  と  $r_B^L$  は、セグメンテ

(注2) :  $\mathcal{E}_A(\eta)$  は、 $\eta \in [0, 1]$  の1変数関数であり、かつ  $\partial^2 \mathcal{E}_A / \partial \eta^2 = \frac{1}{4} \sum_{z \in Z} (\mathcal{H}_F(z) - \mathcal{H}_B(z))^2 \sqrt{\Omega(z)} (\tilde{\Omega}(z; \eta))^{-3/2} \geq 0$  となる下に凸の関数であるため、適当な方法により容易に最小化できる。

(注3) : 次章の式(18)で示すように、最適化手順の中では  $r_F^L, r_B^L$  は実際は補助ラベルに対して定義するため、初期値はいずれも1となる。



ションが進行するのに伴って、値が更新されてゆく。

なお、ここで導かれた前景背景の重みパラメータは、極めて直感的な物理的解釈を与えることができる。すなわち、 $\mathcal{M}_F(\mathbf{L})$ と $\mathcal{M}_B(\mathbf{L})$ にはそれぞれ前景と背景の面積に比例した重み（面積率）を与えるべきということである。更に、上述の導出が示すように、このエネルギー関数を用いることは、前景・背景の色分布の同時マッチングを行うだけでなく、 $\eta_F \simeq r_F^{L^*}$ のときには画像全体の色分布のマッチングにもなっている。

ただし注意されたいのは、導かれた重みパラメータが面積率と解釈されるのは、あくまで入力色分布 $\mathcal{H}_F$ と $\mathcal{H}_B$ が同程度の正確さで与えられた場合である。したがって、 $\mathcal{H}_F$ と $\mathcal{H}_B$ の正確さが大きく異なる場合には、式(12)の重みパラメータは面積率とは異なる値を導くことが予想される。しかし、 $\mathcal{H}_F$ と $\mathcal{H}_B$ の正確さに応じてその重み付けを変えること自体は、むしろ推奨される振舞いである。更に、式(12)の導く重みパラメータは、常に真の面積率の重み付けを与えるよりも、ある程度柔軟な重み付けになることが期待される。その理由として、例えば、背景の入力色分布 $\mathcal{H}_B$ が対象画像と全く関係ない情報を持ち、 $\mathcal{H}_B$ に全く信頼性がない場合を考える。これは、画像全体の色分布 $\Omega(z)$ を用いて $\mathcal{H}_B(z) \cdot \Omega(z) = 0$ と表される。このとき、必ず $\eta_F = 1$ かつ $\eta_B = 0$ となり、式(12)から背景マッチング項が消えて、前景マッチングのみを行うモデルになる。なお、このような場合でも本手法が動作することは4.2.3にて実証する。このように、式(12)にて導出された重みパラメータは、厳密には、面積率と入力色分布の正確さを掛け合わせたような重み付けとも解釈される。しかし本論文では、読者の直感的な理解を促進するため、式(12)による重み付けを以降もあえて“面積率”と表現することにする。

### 3. エネルギー関数 $\mathcal{E}(\mathbf{L})$ の最適化

#### 3.1 補助関数

式(12)の $\mathcal{E}(\mathbf{L})$ は、unary termとpairwise termのみの組合せでは表されないため、グラフカット[7],[8]を直接適用して最適化することができない。そこで、BMGC法[11]に倣い、unary termとpairwise termの和から成る補助関数を導入することで $\mathcal{E}(\mathbf{L})$ の最適化を試みる。ここで $g(\mathbf{L}, \mathbf{L}^c)$ が $f(\mathbf{L})$ の補助関数であるとは、関数 $g$ が以下の条件を満たすことである：

$$f(\mathbf{L}) \leq g(\mathbf{L}, \mathbf{L}^c) \quad \text{and} \quad f(\mathbf{L}) = g(\mathbf{L}, \mathbf{L}) \quad (13)$$

なお、 $\mathbf{L}^c$ は補助ラベル[11]と呼ばれる定数ラベルであり、 $\mathbf{L}$ に対して $\mathbf{R}_i^{\mathbf{L}^c} \supseteq \mathbf{R}_i^{\mathbf{L}}$ なる包含関係を有する。また、 $g(\mathbf{L}, \mathbf{L}^c)$ の第1, 2引数は非可換である。関数 $g$ が $f$ の補助関数であるとき、一つ前の結果 $\mathbf{L}^{(\tau)}$ を補助ラベルとして用いた

$$\mathbf{L}^{(\tau+1)} = \arg \min_{\mathbf{L}} g(\mathbf{L}, \mathbf{L}^{(\tau)}) \quad (14)$$

なる繰り返し更新において、 $f(\mathbf{L}^{(\tau)})$ が増加しないことが、式(13), (14)より以下のようにして示せる：

$$\begin{aligned} f(\mathbf{L}^{(\tau+1)}) &\leq g(\mathbf{L}^{(\tau+1)}, \mathbf{L}^{(\tau)}) \leq g(\mathbf{L}^{(\tau)}, \mathbf{L}^{(\tau)}) \\ &= f(\mathbf{L}^{(\tau)}) \end{aligned}$$

以上の補助関数の性質を図3にて視覚的に表したので参照されたい。

#### 3.2 BMGC法の概要[11]

本論文で提案する最適化アルゴリズムは、BMGC法がもととなっている。そこで、提案アルゴリズムの理解を促進させるため、ここでBMGC法の概要を述べる。

BMGC法は、目的関数として、前景または背景色分布どちらか一方のマッチングを行うエネルギー関数 $\mathcal{E}_i(\mathbf{L}) = \mathcal{M}_i(\mathbf{L}) + \lambda \mathcal{S}(\mathbf{L})$  ( $i = F, B$ )をもつ。BMGC法によれば、以下の式(15)で与えられる関数 $G_i(\mathbf{L}, \mathbf{L}^c, \epsilon)$ は、unary termにより表され、かつ $\epsilon = 0$ のとき、式(13)の条件を満たす $\mathcal{M}_i(\mathbf{L})$ の補助関数である。

$$G_i(\mathbf{L}, \mathbf{L}^c, \epsilon) = (1 - \epsilon) \sum_{p \in \mathbf{R}_i^{\mathbf{L}^c}} \frac{\mathcal{M}_i(\mathbf{L}^c)}{|\mathbf{R}_i^{\mathbf{L}^c}|} +$$




図3 補助関数の概念図[20]. 式(13)の性質を満たした補助関数 $g$ は、式(14)による繰り返し最小化によって、目的関数 $f$ の単調減少をもたらす。

Fig. 3 Auxiliary function [20]. Iteratively minimizing auxiliary functions  $g$  that satisfy the conditions in Eq.(13) results in monotonic decrease of their objective function  $f$ .




図4 補助ラベル. 図中の閉曲線(破線を含む)は各ラベルの境界線を表し, 各線の内側をそのラベルの前景領域, 外側を背景領域とする.

Fig.4 Auxiliary labels. Closed lines (including dashed ones) indicate borderlines of labels, where inner area is foreground and outer area is background.

$$\sum_{p \in \mathbf{R}_l^L} \frac{\delta_{L_p^c=l}}{|\mathbf{R}_l^{L^c}|} \left( \mathcal{M}_l(L^c) + \sum_{z \in Z} K_z(I_p) \sqrt{\frac{\mathcal{H}_l(z)}{\mathcal{P}_l^{L^c}(z)}} \right) \quad (15)$$

ここで,  $L^c$  は  $\mathbf{R}_l^{L^c} \supseteq \mathbf{R}_l^L$  を満たす補助ラベルで, ラベル値  $\bar{l}$  は  $l$  の反転, 更に  $\delta_{(\text{true})} = 1$  及び  $\delta_{(\text{false})} = 0$  と定義される. また,  $\epsilon$  には  $[0, 1]$  の小さな値を与えることで, 近似的に  $\mathcal{G}_l(\mathbf{L}, L^c, \epsilon)$  を補助関数とみなす. これを用いて, 目的関数  $\mathcal{E}_l(\mathbf{L})$  に対して, unary term と pairwise term の和による補助関数  $\hat{\mathcal{E}}_l(\mathbf{L}, L^c, \epsilon) = \mathcal{G}_l(\mathbf{L}, L^c, \epsilon) + \lambda \mathcal{S}(\mathbf{L})$  を与える.

目的関数  $\mathcal{E}_l(\mathbf{L})$  を最適化するときは, 式 (14) の反復更新  $\mathbf{L}^{(\tau+1)} = \arg \min_{\mathbf{L}} \hat{\mathcal{E}}_l(\mathbf{L}, L^c, \epsilon)$  に従って補助関数に繰り返しグラフカットを適用する. その際, 補助ラベルの初期値  $\mathbf{L}^{(1)}$  は全画素  $p$  に対して  $L_p^{(1)} = l$  と与え, グラフカットを繰り返すごとに  $\mathbf{R}_l^{L^{(1)}} \supseteq \mathbf{R}_l^{L^{(2)}} \supseteq \mathbf{R}_l^{L^{(3)}} \dots$  と対応領域を縮小させながら収束するまで更新していく. また, 収束性を保証するために反復ごとに  $\epsilon$  を減少させている. 結果が収束するまで, およそ 3, 4 回ほどグラフカットを実行する.

### 3.3 エネルギー関数 $\mathcal{E}(\mathbf{L})$ の上界関数の導出

提案する最適化手法でも, BMGC 法に倣い, 補助関数を式 (12) の重み付きの前景及び背景マッチング項に導入する. 各重み付きマッチング項の補助関数は,  $\mathcal{M}_l(\mathbf{L})$  の補助関数  $\mathcal{G}_l(\mathbf{L}, L^c, \epsilon)$  を用いて

$$\sqrt{\eta_F r_F^{L^a}} \mathcal{G}_F(\mathbf{L}, L^a, \alpha) \geq \sqrt{\eta_F r_F^L} \mathcal{M}_F(\mathbf{L}) \quad (16)$$

$$\sqrt{\eta_B r_B^{L^b}} \mathcal{G}_B(\mathbf{L}, L^b, \beta) \geq \sqrt{\eta_B r_B^L} \mathcal{M}_B(\mathbf{L}) \quad (17)$$

と与えられる. ここで,  $L^a$  と  $L^b$  は, 図 4(a) で図説するように, それぞれ  $\mathbf{R}_F^{L^a} \supseteq \mathbf{R}_F^L$  及び  $\mathbf{R}_B^{L^b} \supseteq \mathbf{R}_B^L$  を満たす補助ラベルである. また,  $\alpha, \beta \in [0, 1]$  である.

最後にこれらを用いて, unary term と pairwise term による式 (12) の  $\mathcal{E}(\mathbf{L})$  の上界関数

$$\hat{\mathcal{E}}(\mathbf{L}, L^a, L^b, \alpha, \beta) = \sqrt{\eta_F r_F^{L^a}} \mathcal{G}_F(\mathbf{L}, L^a, \alpha) + \sqrt{\eta_B r_B^{L^b}} \mathcal{G}_B(\mathbf{L}, L^b, \beta) + \hat{\lambda}_S \mathcal{S}(\mathbf{L}) \geq \mathcal{E}(\mathbf{L}), \quad (18)$$

$$\hat{\lambda}_S = \lambda \left( \sqrt{\eta_F r_F^{L^a}} + \sqrt{\eta_B r_B^{L^b}} \right) \geq \lambda_S \quad (19)$$

を定め, これを反復的に最小化することで  $\mathcal{E}(\mathbf{L})$  を最適化する. ただし, この  $\hat{\mathcal{E}}(\mathbf{L}, L^a, L^b, \alpha, \beta)$  に関しては,  $\alpha = \beta = 0$  かつ  $\mathbf{L} = L^a = L^b$  のとき  $\mathcal{E}(\mathbf{L}) = \hat{\mathcal{E}}(\mathbf{L}, L^a, L^b, \alpha, \beta)$  となり, 形式上, 式 (13) の条件を満たすが, 厳密には関数  $\hat{\mathcal{E}}$  は関数  $\mathcal{E}$  の補助関数としては機能しない. なぜなら,  $\mathbf{L}$  に対して包含関係の異なる二つの補助ラベル  $L^a, L^b$  が存在するからである(注4). しかしながら,  $\mathbf{R}_F^{L^a} \supseteq \mathbf{R}_F^{L^b}$  かつ  $L^a \simeq L^b$  なる補助ラベルが与えられた際には  $\hat{\mathcal{E}}(\mathbf{L}, L^a, L^b, \alpha, \beta)$  は  $\mathcal{E}(\mathbf{L})$  の良い近似関数となると期待される. したがって以下に述べる最適化アルゴリズムでは, 真のラベル  $L^*$  の境界に向けて補助ラベル  $L^a, L^b$  を外側と内側から徐々に近づけつつ (図 4(b) 参照), 繰り返しグラフカットを適用して  $\mathcal{E}(\mathbf{L})$  の最適化を行う.

### 3.4 最適化アルゴリズム

式 (12) のエネルギー関数  $\mathcal{E}(\mathbf{L})$  の最適化アルゴリズムを手続き 1 に示す. これは大まかに, 前景・背景補助ラベル更新 (手続き 2, 3) 及びセグメンテーションの 2 ステップと, その間での補助ラベルの調整 (手続き 4) の繰返しからなる. 重みパラメータは, まず,

(注4): 関数  $\mathcal{E}(\mathbf{L})$  の上界関数  $\hat{\mathcal{E}}(\mathbf{L}, L^a, L^b, \alpha, \beta)$  は, 変数ラベル  $\mathbf{L}$  の境界を定数である二つの補助ラベル  $L^a, L^b$  で挟み込む形をとる (図 4(a)). このため, 式 (14) に倣った単純な繰返し更新  $\mathbf{L}^{(\tau+1)} = \arg \min_{\mathbf{L}} \hat{\mathcal{E}}(\mathbf{L}, L^c, \epsilon)$  では,  $\mathbf{L} = L^c$  と固定され, 反復的な最適化処理が行えない.

式 (7) の最小化によって得られた推定値  $\eta_F$  を前景の面積率,  $\eta_B = 1 - \eta_F$  を背景の面積率とみなして初期化される. 更に, 繰り返し処理によってセグメンテーションが進行し, 各画素のラベルが更新されるたびに, 重みパラメータは式 (12) や式 (18) の定義に従って更新される. また, 途中の計算結果のラベルを格納するために, 新たに  $L^{a*}$ ,  $L^{b*}$ ,  $L^{\text{out}}$  を用いる. 更に  $L^{\text{local}}$  は, 前景背景の入力色分布を用いてローカルなアピランスマデルをもとに得られるラベルであり, 例えば Interactive graph cuts [1] などを用いる. 手続き 2 及び手続き 3 は, BMGC 法 [11] の最適化手法を直接的に拡張したもので, 前景項の補助ラベルを更新 (前景項を最適化) する場合と, 背景項の補助ラベルを更新 (背景項を最適化) する場合の 2 通りで  $\mathcal{E}(L^{(\tau)})$  の減少を試みる. 視覚的には, 前者は図 4 (b) において  $L^a$  を外側から縮小させる手続きに対応, 後者は  $L^b$  を内側から拡大させる手続きに対応している. 手続き 4 は, これまでに得られた結果を取捨選択し, 真のラベル  $L^*$  の境界と推定される領域周辺で補助ラベル  $L^a$ ,  $L^b$  を更新している. これも, 前の手続き 2, 3 と合わせて, 図 4 (b) が表す手続きに対応している.

本論文が提案する最適化手法は, 基本的には BMGC 法 [11] に基づくものであるが, そのままでは適用できないため主に以下のような拡張を行っている. (1) 二つの補助ラベル  $L^a$ ,  $L^b$  により  $L$  を挟み込む形で最適化する. (2) 補助ラベル  $L^a$ ,  $L^b$  をより良いものに調節するための手続き 4 を導入する. また全体として, 1 回の繰り返し処理の中で様々なラベルを生成し,  $\mathcal{A}(L)$  の値がより小さいラベルを妥当なものとして, 適応的に選択していくため手順が多くなっている. これは試行錯誤の結果行き着いたものであり, 今後の研究により簡素化される可能性もある.

## 4. 実 験

提案手法 DDM 法の評価にあたり, アピランス関数の重みパラメータ推定に関する評価実験と, 画像セグメンテーション, 動画セグメンテーション, ローカル/グローバル尺度のロバスト性に関する実験, 更に複数の前景領域を抽出する実験を行った. 評価の際には, GrabCut データベース [3] を用いた. これは, 図 5 に示すような 50 枚の画像及び, その Ground Truth ラベル (前景, 背景の 2 値), Lasso-Trimap ラベル (前景, 背景, 未知の 3 値) が与えられている. また, 共通して色分布の表現に, RGB 空間上の  $64 \times 64 \times 64$

### 手続き 1 $\mathcal{E}(L)$ の最適化

#### initialize

- 面積率推定:  $\eta_F = \arg \min \mathcal{E}_A(\eta)$
- 補助ラベルを初期化:  $L_p^a = F$ ,  $L_p^b = B \quad \forall p \in P$
- 結果格納ラベルの初期化:  $L^{a*} = L^{b*} = L^{\text{out}} = \text{null}$
- ローカル尺度による結果の取得:

$$L^{\text{local}} = \text{standard.graphcut}(\mathcal{H}_F, \mathcal{H}_B)$$

#### for $t = 1$ to $T$ do

- 1: 前景補助ラベル更新: 手続き 2  
入力:  $\{L^a, L^b, L^{a*}\}$ , 出力:  $L^{a*}$
- 2: 背景補助ラベル更新: 手続き 3  
入力:  $\{L^a, L^b, L^{b*}\}$ , 出力:  $L^{b*}$
- 3: 補助ラベルの調整: 手続き 4  
入力:  $\{L^{a*}, L^{b*}, L^{\text{out}}, L^{\text{local}}\}$ , 出力:  $\{L^a, L^b\}$
- 4: セグメンテーション: 式 (18) により  
 $L^{(t)} = \arg \min_L \hat{\mathcal{E}}(L, L^a, L^b, \alpha_0, \beta_0)$
- 5: 結果を比較して更新:  $L^{\text{out}} = \arg \min_{L \in \{L^{(t)}, L^{\text{out}}\}} \mathcal{A}(L)$
- 6: 補助ラベルの調整: 手続き 4  
入力:  $\{L^{a*}, L^{b*}, L^{\text{out}}, L^{\text{local}}\}$ , 出力:  $\{L^a, L^b\}$

#### end for

#### return $L^{\text{out}}$

### 手続き 2 前景補助ラベル更新

#### initialize

- $\alpha$ ,  $\beta$  の初期化:  $\alpha = \alpha_0$ ,  $\beta = \beta_0$
- 補助ラベル  $L^{(a)}$ ,  $L^{(b)}$  の初期化:  $L^{(a)} = L^a$ ,  $L^{(b)} = L^b$

#### repeat

- 1: グラフカット: 式 (18) により  
 $L^{(\tau)} = \arg \min_L \hat{\mathcal{E}}(L, L^{(a)}, L^{(b)}, \alpha, \beta)$
- 2: 補助ラベル  $L^{(a)}$  の更新:  $L^{(a)} = L^{(\tau)}$
- 3:  $\alpha$  を減少させる:  $\alpha = \alpha^\rho$  ( $\rho > 1$ )

until  $\mathcal{A}(L^{(\tau)})$  が収束または増加するまで繰り返し

update 結果を比較して更新:  $L^{a*} = \arg \min_{L \in \{L^{(a)}, L^{a*}\}} \mathcal{A}(L)$

### 手続き 3 背景補助ラベル更新

手続き 2 と同様の手続きを行う. ただし, repeat.2 において補助ラベルを  $L^{(b)} = L^{(\tau)}$  と更新, repeat.3 において  $\beta$  を  $\beta = \beta^\gamma$  ( $\gamma > 1$ ) と減少, update において  $L^{b*} = \arg \min_{L \in \{L^{(b)}, L^{b*}\}} \mathcal{A}(L)$  のように比較して更新する.

### 手続き 4 補助ラベルの調整

$\mathcal{A}(L)$  の値が最も小さい二つのラベルを  $L^{a*}$ ,  $L^{b*}$ ,  $L^{\text{out}}$ ,  $L^{\text{local}}$  の四つの中から選択し,  $L^M$ ,  $L^N$  とする. 補助ラベル  $L^a$  及び  $L^b$  を, 図 4 (c) に示すように,  $w^{(t)}$  画素のマージン幅を伴って  $\mathbf{R}_B^{L^a} \supset (\mathbf{R}_B^{L^M} \cup \mathbf{R}_B^{L^N})$  及び  $\mathbf{R}_F^{L^b} \subset (\mathbf{R}_F^{L^M} \cap \mathbf{R}_F^{L^N})$  となるように更新する.

の三次元ヒストグラムを用いた.

#### 4.1 重みパラメータ推定の評価実験

式 (12) のアピランス関数  $\mathcal{A}(L)$  における重みパラメータ推定の有効性を検証するにあたり, 前景項と背景項の重みを均等にした重み推定なしの場合




図5 GrabCut データベース [3] の例. このデータベースは (a) テスト画像に対して, (b) 真のセグメンテーションラベルと, その前景・背景領域の境界を一定幅で縁取って未知領域とした (c) Lasso-Trimap が与えられている.

Fig. 5 Examples of the GrabCut database [3]. From the left, test image, the ground truth label, and lasso-trimap label (foreground, background, and unknown) are provided.

( $\mathcal{A}_{\text{fixed}}(\mathbf{L}) = 0.5 \cdot \mathcal{M}_F(\mathbf{L}) + 0.5 \cdot \mathcal{M}_B(\mathbf{L})$ ) と比較した. 近似的な入力色分布  $\mathcal{H}_F, \mathcal{H}_B$  は, 各画像の Lasso-Trimap の前景・背景領域から生成した. Ground Truth 前景領域ラベル  $\mathbf{G}$  (= 真のラベル  $\mathbf{L}^*$ ) を外側に整数  $h$  画素拡張したラベルを  $\mathbf{G}^{(h)}$  ( $h < 0$  のときは縮小) とする. そして, 前景項  $\mathcal{M}_F(\mathbf{L})$ , 背景項  $\mathcal{M}_B(\mathbf{L})$ , それらを重み結合した  $\mathcal{A}(\mathbf{L})$ , 及び  $\mathcal{A}_{\text{fixed}}(\mathbf{L})$  の 4 種類のエネルギーに対して,  $-10 \leq h \leq 10$  の範囲で  $\mathbf{L} = \mathbf{G}^{(h)}$  を代入して各エネルギーの値を計算した.

図 6 に, 上記の 4 種類のエネルギーの画像 50 枚に対する平均値を示す. 前景項  $\mathcal{M}_F(\mathbf{L})$ , 背景項  $\mathcal{M}_B(\mathbf{L})$  は, それぞれ対応する領域が真値よりもやや縮小されるところで最小値をとる傾向にある. これは Lasso-Trimap から入力色分布を与えたことに起因する自然な結果である. 関数  $\mathcal{A}(\mathbf{L})$  は,  $h = 0$ , すなわち  $\mathbf{L} = \mathbf{L}^*$  (真のラベル) が与えられたときに極小をとる理想的な曲線を描いている. 一方,  $\mathcal{A}_{\text{fixed}}(\mathbf{L})$  では前景項の性質に大きく影響された形を描いている. これは, データベースより与えられた 50 枚の画像のほとんどが前景よりも背景の面積が大きいいため, 前景項と背景項の重みを均等に 0.5 とした場合には前景項に過剰な重みを与えてしまうことが原因である. このことから, 面積率に基づく重み付けをしたアピランズ関数  $\mathcal{A}(\mathbf{L})$  が, 前景と背景の色分布の同時マッチングの指標として有効なことが分かる.

## 4.2 セグメンテーション精度の評価実験

### 4.2.1 共通の実験設定

本項の実験において, 特に断りがない場合には以下に述べる共通の設定を用いた.

実行時間が表示されている結果に対しては, モバイル版 Core i7 2.8 GHz (2640 M), 8 GB メモリのノートパソコンを使用した. また, セグメンテーション対象は

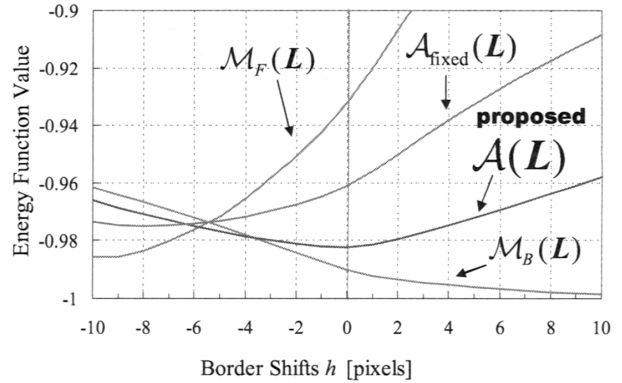


図 6  $\mathbf{L}$  境界を真のラベルからずらした際の前景項  $\mathcal{M}_F(\mathbf{L})$ , 背景項  $\mathcal{M}_B(\mathbf{L})$  とアピランズ関数  $\mathcal{A}(\mathbf{L})$ ,  $\mathcal{A}_{\text{fixed}}(\mathbf{L})$  の推移. 入力色分布  $\mathcal{H}_F, \mathcal{H}_B$  が不完全だと, 前景項や背景項だけでは真の解を与えることができないが, それらを面積率により重み付けした  $\mathcal{A}(\mathbf{L})$  は,  $h = 0$  ( $\mathbf{L}$  が真のラベル) のときに最小値をとる.

Fig. 6 Profiles of  $\mathcal{M}_F(\mathbf{L})$ ,  $\mathcal{M}_B(\mathbf{L})$ ,  $\mathcal{A}(\mathbf{L})$ , and  $\mathcal{A}_{\text{fixed}}(\mathbf{L})$ , where the border of  $\mathbf{L}$  is shifted by  $h$  pixels from the ground truth. Because the input distributions  $\mathcal{H}_F$  and  $\mathcal{H}_B$  are inaccurate, neither the foreground or background term alone captures the true solution, while  $\mathcal{A}(\mathbf{L})$  with the estimated weighting parameters takes the minimum at  $h = 0$  ( $\mathbf{L} = \mathbf{L}^*$ ).

画像の全画素とした. これは, Ground Truth/Lasso-Trimap ラベルは入力色分布の生成時のみに参照し, いかなる画素にもハード制約は与えないことを意味する. 本来, 画像セグメンテーションでは, ハード制約が極めて有効であるが, 本論文では色分布マッチングの性能を測ることを目的としているため, ハード制約は意図的に与えていない. また, 評価対象として

- DDM (提案手法)
- $\mathcal{A}_{\text{fixed}}(\mathbf{L})$  での DDM (重み推定なし)
- F-BMGC [11] (前景マッチング)
- B-BMGC [11] (背景マッチング)
- Interactive graph cuts [1] (ローカル尺度)

の五つの手法によりセグメンテーション実験を行った. (b) については, エネルギー関数とその上界関数に

$$\begin{aligned} \mathcal{E}_{\text{fixed}}(\mathbf{L}) &= \mathcal{A}_{\text{fixed}}(\mathbf{L}) + \lambda \mathcal{S}(\mathbf{L}) \\ &\leq 0.5 \cdot \mathcal{G}_F(\mathbf{L}, \mathbf{L}^a, \alpha) + 0.5 \cdot \mathcal{G}_B(\mathbf{L}, \mathbf{L}^b, \beta) + \lambda \mathcal{S}(\mathbf{L}) \end{aligned}$$

を用いて本来の DDM 法と同等の最適化手法を適用した. グラフカットのアルゴリズムは Boykov と Kolmogorov による実装 [8] を用い, 精度の評価尺度には誤り画素率 (EPR: Error Pixel Rate) 及び誤り対オブジェクト比 (EOR: Error to Object Ratio)

$$\text{EPR} = \frac{\text{誤り画素数}}{\text{総画素数}}, \quad \text{EOR} = \frac{\text{誤り画素数}}{\text{真の前景画素数}}$$

を用いてデータベースの 50 枚の画像に対する平均値により評価した。

また、平滑化項  $\lambda S(\mathbf{L})$  の  $S(\mathbf{L})$  を、(a), (b) の DDM 法及び (c), (d) の BMGC 法に対しては

$$S(\mathbf{L}) = \sum_{(p,q) \in N} \frac{\delta_{L_p \neq L_q}}{|p-q|} \left( \frac{1}{1+|I_p - I_q|^2} + \epsilon \right)$$

と定義した。これは、文献 [11] の BMGC 法において用いられた  $S(\mathbf{L}) = \sum \delta_{L_p \neq L_q} / |p-q|$  に対して、色コントラスト項を追加したものである。一方、(e) の Interactive graph cuts に対しては、従来の一般的な関数に定数  $\epsilon$  を加えて拡張し

$$S(\mathbf{L}) = \sum_{(p,q) \in N} \frac{\delta_{L_p \neq L_q}}{|p-q|} \left( e^{-\kappa |I_p - I_q|^2} + \epsilon \right)$$

と定義した。 $\kappa$  は  $\kappa = (2E[|I_p - I_q|^2])^{-1}$  により画像ごとに与えた。なお  $N$  は 8 近傍の隣接画素組の集合である。平滑化項のパラメータとして、表 1 の 2 通りのパラメータを用いた。パラメータ 1 は Lasso-Trimap から得られた入力色分布に対して平均 EPR を最大化するように調節されたもので、パラメータ 2 は真の色分布に対して同様に調節されたものである。

また、(a), (b) の DDM 法のパラメータとして、 $\alpha_0 = \beta_0 = 0.85$ ,  $\rho = \gamma = 1.1$  は文献 [11] に記載された値を用い、また経験的な値として反復回数  $T = 2$ , 補助ラベル調整時のマージン幅は  $w^{(t=1)} = 25$ ,  $w^{(t=2)} = 5$  画素とした。最適化アルゴリズム内で用いるローカル尺度による結果  $\mathbf{L}^{\text{local}}$  は (e) によるセグメンテーション結果をそのまま用いた。

#### 4.2.2 Lasso-Trimap 色分布によるセグメンテーション

ここでは、データベースの Lasso-Trimap の前景背景領域から近似分布  $\mathcal{H}_F, \mathcal{H}_B$  を生成し、それを入力として各手法でセグメンテーションを行った。入力色分布  $\mathcal{H}_F, \mathcal{H}_B$  の精度は、真の色分布との Bhattacharyya 係数で比較すると、前景の入力色分布は平均で  $0.932 \pm 0.052$ , 背景は  $0.990 \pm 0.012$ , それらを真の面積率で重み付けして足し合わせたトータルの値は  $0.982 \pm 0.011$  であった。また、“Lasso-Trimap の前景面積/真の前景面積”のように、真の領域に対する参照領域の割合で比較すると、前景の入力色分布は  $0.644 \pm$

$0.158$ , 背景は  $0.887 \pm 0.065$ , 画像全体では  $0.851 \pm 0.067$  であった。各 Lasso-Trimap の形状については公開されているデータベース [3] を参照されたい。なお、平滑化項のパラメータは表 1 に示す 2 通りの組合せを用いた。

表 2 に各手法における平均 EPR/EOR 及び標準偏差、画像 1 枚当りの平均実行時間を示す。平均 EPR 及び EOR では、共に提案手法が最も優れていた。最適な設定であるパラメータ 1 と、そうでないパラメータ 2 の場合を比較しても、大幅な精度低下は見られないことから、パラメータの設定に関して、ある程度のロバスト性があると分かる。また最適な設定での画像ごとの精度比較では、(a) 提案手法は全 50 枚中、(b) 重み推定なしに対して 41 枚、(c) F-BMGC 法に対して 46 枚、(d) B-BMGC 法に対して 41 枚、(e) Interactive graph cuts に対して 39 枚で精度が上回った。このときのセグメンテーション結果の例を図 7 に示す。結果の特徴として、(a) 提案手法は前景背景のグローバルなアピランスの適合性を評価するため、細端部においてもより正確なセグメンテーションが実現されている。一方、ローカル尺度である (e) Interactive graph cuts は細端部が切断されやすい。また、Lasso-Trimap からの入力色分布を用いたため、(c) F-BMGC 法は縮小傾向、(d) B-BMGC 法は拡大傾向にある。前景マッチング項の重みが強い (b) 重み推定なしは、(c) F-BMGC 法と同じ縮小傾向にある。

#### 4.2.3 IDM 法 [12] との比較

ここでは、近似的な背景色分布のみを入力とした IDM 法 [12] との比較を行った。IDM 法は、バウンディングボックス (以下 BB) の外側領域から背景色分布を学習し、BB 内側領域を前景背景にセグメンテーションすることを想定している。そこで、文献 [12] の実験設定に沿い、以下の条件で比較実験を行った。(1) 対象データ: GrabCut データベース [3] の 49 枚の画像及び、付属の BB データを用いた。なお、50 枚のうち 1 枚 (cross.jpg) は、BB が画像全体に設定され、

表 1 画像セグメンテーションの平滑化項パラメータ  
Table 1 Parameters of smoothness terms.

手法	パラメータ 1 (Trimap 分布)		パラメータ 2 (真分布)	
	$\lambda$	$\epsilon$	$\lambda$	$\epsilon$
(a)	$10^{-3}$	$8 \times 10^{-4}$	$2 \times 10^{-4}$	$10^{-2}$
(b)	$6 \times 10^{-3}$	$5 \times 10^{-4}$	$4 \times 10^{-4}$	$2 \times 10^{-2}$
(c)	$16 \times 10^{-3}$	$8 \times 10^{-4}$	$10^{-4}$	$5 \times 10^{-2}$
(d)	$4 \times 10^{-3}$	$10^{-3}$	$5 \times 10^{-4}$	$2 \times 10^{-3}$
(e)	50	0	60	2/60

表 2 Lasso-Trimap からの色分布入力による各手法の精度の比較. GrabCut データベース [3] の 50 枚の画像に対する精度と実行時間の比較.

Table 2 Comparison of segmentation accuracy with lasso-trimap distributions. Average accuracy and processing time over 50 images from the GrabCut database [3] are shown.

手法	表 1 パラメータ 1 での結果			表 1 パラメータ 2 での結果		
	EPR (mean±std)	EOR (mean±std)	time [sec]	EPR (mean±std)	EOR (mean±std)	time [sec]
(a) DDM	1.23 ± 0.79%	7.88 ± 6.55%	2.32	1.35 ± 0.82%	8.14 ± 6.13%	2.37
(b) DDM (重み推定なし)	1.96 ± 1.28%	13.18 ± 11.45%	3.05	2.28 ± 1.34%	15.29 ± 11.87%	2.82
(c) F-BMGC [11]	3.51 ± 2.90%	19.41 ± 14.39%	1.75	4.64 ± 2.80%	27.06 ± 16.59%	0.54
(d) B-BMGC [11]	2.03 ± 1.68%	12.65 ± 12.79%	0.84	2.43 ± 1.97%	13.51 ± 10.58%	0.49
(e) Interactive graph cuts [1]	1.53 ± 0.96%	10.43 ± 9.40%	0.23	1.59 ± 1.12%	10.58 ± 9.98%	0.25




図 7 Lasso-Trimap 色分布によるセグメンテーション結果と EPR 及び実行時間. 左から (GT) 対象画像とその Ground Truth ラベル, (a) 提案手法, (b) 重み推定なし, (c) F-BMGC 法, (d) B-BMGC 法, (e) Interactive graph cuts の結果.

Fig. 7 Segmentation results using lasso-trimap distributions with EPR and processing time. From the left to right, (GT) target image with its ground truth label, and the results of (a) the proposed, (b) fixed weighting parameters, (c) F-BMGC, (d) B-BMGC, and (e) interactive graph cuts.

IDM 法が適用できないため除いた。(2) 推定領域: 提案する DDM 法に対しても, BB 外側の領域を常に背景とするハード制約を与えることで, 推定領域を BB 内側に限定した。これは, 補助ラベル  $L^a$  及び  $L^b$  に対して, 常にそのような制約を与えることで実現される。(3) 入力色分布: DDM 法の入力として, 近似的

な背景色分布には, IDM 法と同様に BB の外側領域の色分布を用いた。一方, 近似的な前景色分布には, Lasso-Trimap の前景領域の色分布を用いた。(4) パラメータ: DDM 法の各パラメータは, 特別な調整はせず, 表 1 のパラメータ 1 を用いた。(5) 評価尺度: EPR を“誤り画素数 / BB 内側の画素数”として評価



した. その他, IDM 法については, 文献[12] の記載に準拠するものとする.

結果, 平均 EPR は, IDM 法の 7.1% に対して, 提案する DDM 法は 3.49% と大きく改善した. 参考として, 文献[12] での IDM 法の比較手法 GrabCut [3] は 8.1% である. 特に差が顕著に現れた例を図 8 に示す. IDM 法は, 背景色分布のマッチングをしつつも, 背景の入力色分布とセグメンテーション結果から計算される前景色分布がなるべく異なるように領域を推定する. そのため, 図 8 の最初の二つの例のように, 前景と背景の色が似ている画像では大きく誤ってしまう. 提案手法は, 前景背景二つの入力色分布に対してマッチングを行うことで, 前景と背景の色が似ている場合でも比較的正確なセグメンテーションが得られる.

そして, 図 8 の中で, 最も重要な結果を示しているのが三つ目の例である. これは, BB が画像全体に設定されていたために背景の入力色分布が得られず, IDM 法が適用できなかった例である. 一方, 提案手法に対しては, 背景の入力色分布を  $\mathcal{H}_B(z) = 0$  として DDM 法をそのまま適用したが, ほぼ正解と等しい結果が得られた. このとき, DDM 法では, 初期の面積率の推定  $\eta_F = \arg \min \mathcal{E}_A(\eta)$  において,  $\eta_F = 1$  と推定した. 本来の“面積率”という意味では,  $\eta_F = 0.370$  が正しい値であるが, DDM 法は, 全く信頼性のない背景マッチング項に一切の重みを与えないことで正しい




図 8 IDM 法との比較. 左から, バウンディングボックス (赤) と正解ラベル (青), 提案手法, IDM 法 (画像は [12] から引用).

Fig. 8 Comparison with IDM. From left to right, a bounding box (red) with the ground truth (blue), the results of the proposed DDM, and IDM (images are from [12]).

結果を導いた. このように DDM 法は, 入力色分布  $\mathcal{H}_F$  と  $\mathcal{H}_B$  がもつ相対的な信頼度に応じて, 適切な重み付けを導き, かつ, 片方のマッチング項の重みが零になった場合でも, 正しく動作することがうかがえる.

#### 4.2.4 動画セグメンテーション

176 × 144 サイズ, 382 フレームの動画 carphone に対して 1 フレーム目は手動でセグメンテーションを与え, 残りのフレームは一つ前の結果から前景及び背景色分布を学習してセグメンテーションを行った. 動画セグメンテーションでは, 時系列上の物体の動き情報を用いることが有効だが, 本論文では色分布マッチングの性能を測ることが目的であるため, 時系列の情報は用いないこととした. 提案手法, F-BMGC 法, Interactive graph cuts の結果を図 9 に示す. 提案手法が最も安定した結果を示した一方で, F-BMGC 法はチラつきが多く安定せず, 例えば 60 と 305 フレーム目の首周りなどにエラーが見られた. Interactive graph cuts では, 肩の上などに大きなエラーが目立った. なお, 各パラメータは, 提案手法では  $\lambda = 10^{-2}$ ,  $\epsilon = 2.5 \times 10^{-3}$ ,  $T = 2$ ,  $w^{(t)} = \{10, 2\}$ ,  $\alpha_0 = \beta_0 = 0.85$ ,  $\rho = \gamma = 1.1$ , F-BMGC 法では  $\lambda = 2 \times 10^{-2}$ ,  $\epsilon = 2.5 \times 10^{-3}$ , Interactive graph cuts では  $\lambda = 1$ ,  $\epsilon = 5$  とした.

#### 4.2.5 ローカル/グローバル尺度の比較

この実験は, アピアランスモデルの表現としてロー

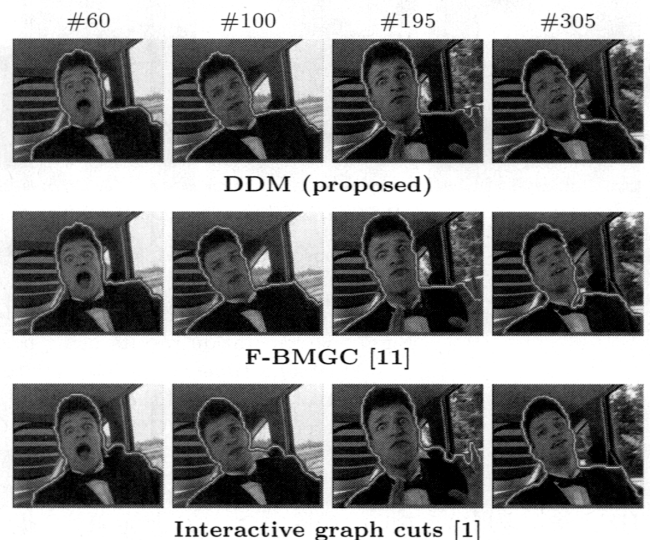


図 9 動画セグメンテーション. 上から提案手法, F-BMGC, Interactive graph cuts の結果を示す. 提案手法が最も安定した結果を示した.

Fig. 9 Video segmentation. From the top, the results of the proposed method, F-BMGC, and Interactive graph cuts are shown. Our method was most stable.

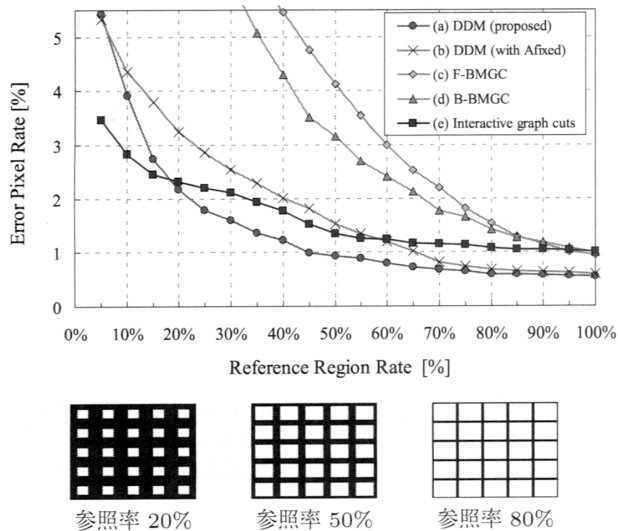


図 10 ローカル/グローバル尺度の比較 (ブロックマスク)  
Fig. 10 Comparison of local and global consistency measures (block mask).

カル尺度とグローバル尺度の優劣を、入力色分布の精度を変化させながら比較するシミュレーションを行った。入力色分布を生成するときには、2通りの方法を用いた。一つはブロックマスクを用いる方法で、図 10 下のように、画像形状と相似な  $5 \times 5$  個の長方形を均等に配置したマスクを施して、色情報を取得する領域を限定することで、意図的に不正確な色分布を生成した。もう一つはカラーノイズを用いる方法で、図 11 下のように、画像のランダムな位置の画素を RGB 空間上で一様に分布したカラーノイズ画素で置き換え、そこから不正確な色分布を生成した。前者は画像全体に対するマスクの面積の比 (参照率) を、後者はノイズ画素の含有率を 5% 刻みに変えることで、色分布を真の分布から極めて不正確な分布まで変化させ、それぞれの入力において各手法の 50 枚の画像に対する平均 EPR を測定した。なお、平滑化項には、真の色分布入力に対して調整した表 1 パラメータ 2 を与えた。

図 10 のブロックマスクを用いた場合の結果では、参照率 100%~20% の高・中精度の入力色分布に対しては (a) 提案手法が他の全ての手法を上回っていることが分かり、それ以上分布が不正確になると (e) Interactive graph cuts が勝るという結果が得られた。これは色分布同士をなるべく正確に一致させるグローバル尺度が、不正確な入力色分布と一致したセグメンテーションを求めようとして精度を落としたためだと考えられる。よって、入力色分布がある程度の精度を有する場合にはグローバル尺度が、分布の精度が乏しい場合にはローカル尺度が有効であるといえる。また、この実

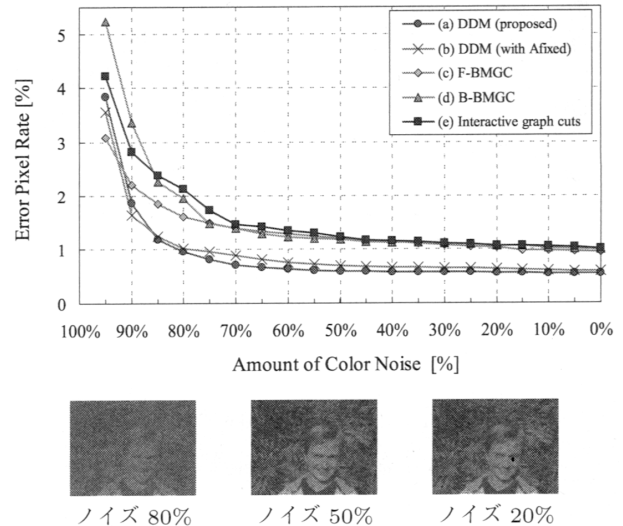


図 11 ローカル/グローバル尺度の比較 (カラーノイズ)  
Fig. 11 Comparison of local and global consistency measures (color noise).

験のように、対象画像の一部から入力色分布を生成した場合、(c), (d) BMGC 法はその参照領域に一致したセグメンテーションを求めようとするため精度を大きく落とす。これは BMGC 法が前景あるいは背景色分布のみの適合性しか考慮しないという根本的な問題による。また (b) 重み推定なしの DDM 法と比較しても、ほぼ全てにおいて提案手法が上回り、重みパラメータ推定の有効性を示している。

一方、図 11 のカラーノイズを用いた場合の結果では、どの手法もおおむねノイズに対する高いロバスト性を示した。中でも (a) 提案手法は、ノイズ 0%~80% の高・中精度の入力色分布に対して最もセグメンテーション精度が高く、また精度の低下も緩やかであった。これはブロックマスクと違い、一様に分布するノイズを加えただけでは、入力色分布の形状が崩れにくいからだと考えられる。したがって、グローバル尺度にとって好ましい入力色分布とは、真の色分布と比べて分布形状が似ていることであるといえる。また、低精度の入力に対して、(a) 提案手法は (b) 重み推定なしの DDM 法や、(c) F-BMGC 法に一部劣る結果となったが、これは大量のノイズを含んだ分布に対しては面積率  $\eta_F$  の推定が安定しなかったためだと推察する。

#### 4.3 複数の前景領域の抽出

例えば、前景の入力色分布  $\mathcal{H}_F$  が、色分布の異なる複数の前景領域の情報を含んでいた場合であっても、提案する DDM 法をそのまま適用することが可能である。実際の例を図 12 に示す。図 12 左は、図 12 右の






図 12 複数の前景領域の抽出. 左: 結果 (赤) と正解 (青), 右: 入力色分布を生成する際に用いた Lasso-Trimap

Fig.12 Extraction of multiple foreground regions. Left: the result of our method (red) with the ground truth (blue). Right: lasso-trimap used for making input distributions.

ような Lasso-Trimap から, 前景と背景の近似的な入力色分布  $\mathcal{H}_F$  及び  $\mathcal{H}_B$  を取得し, 画像全体に対して DDM 法を適用した結果である. 入力色分布  $\mathcal{H}_F$  には, 2 人の人物の異なる色分布が混在しているが, このような場合でも提案手法は有効に動作する. なお, パラメータは表 1 パラメータ 1 を用いた.

## 5. む す び

本研究では, 前景背景の二つの色分布からセグメンテーションを求める際の基本原理の検討を行い, 与えられた入力が必要しも正確でなくても, 前景背景の色分布の同時マッチングを行うことで対応領域を推定する新たな手法, DDM 法を提案した. これは, 前景マッチングと背景マッチングの二つの同時制約から成るグローバル尺度に対して, 適切な重みパラメータの推定と, 有効な最適化アルゴリズムを新たに与えたことにより初めて実現したものである.

実験により, 本手法が従来のグローバル尺度手法及びローカル尺度手法と比べて高精度であり, 応用として動画セグメンテーションへ適用した際にも, 本手法が最も安定していることを示した. 更に, グローバル尺度とローカル尺度の比較シミュレーションにより, 入力色分布の精度に対する両者のロバスト性の優劣を明らかにした.

一方で, 本研究では色分布以外の入力要素はあえて排除したが, より実用性を追求するのであれば, ユーザの入力による前景背景の位置情報や, 動画であれば時系列上の物体の動き情報などといった, 空間的な制約を取り入れることは効果的である.

また, 本論文にて提案したグローバル尺度は, 従来のローカル尺度と組み合わせることも可能である. その場合には, 本論文にて明らかにした両者のロバスト

性の関係を考慮し, 入力色分布が正確な場合はグローバル尺度に比重を置き, 逆に入力色分布が不正確な場合はローカル尺度に比重を置くような, 入力に応じた動的な重み付けを与える必要があるだろう. その際, いかにして入力色分布の精度をはかるかも, 課題の一つとなる.

## 文 献

- [1] Y. Boykov and M.P. Jolly, "Interactive graph cuts for optimal boundary & region segmentation of objects in n-d images," Proc. ICCV, pp.105-112, 2001.
- [2] J. Liu, J. Sun, and H.Y. Shum, "Paint selection," ACM Trans. Graph., vol.28, no.69, pp.1-7, 2009.
- [3] C. Rother, V. Kolmogorov, and A. Blake, "Grab-cut: Interactive foreground extraction using iterated graph cuts," ACM Trans. Graph., vol.23, no.3, pp.309-314, 2004.
- [4] X. Bai, J. Wang, D. Simons, and G. Sapiro, "Video snapcut: Robust video object cutout using localized classifiers," ACM Trans. Graph., vol.28, no.3, pp.70:1-70:11, 2009.
- [5] V.-Q. Pham, K. Takahashi, and T. Naemura, "Real-time video matting based on bilayer segmentation," Proc. ACCV, vol.2, pp.489-501, 2010.
- [6] Y. Li, J. Shun, C.K. Tang, and H.Y. Shum, "Lazy snapping," ACM Trans. Graph., vol.23, no.3, pp.303-308, 2004.
- [7] V. Kolmogorov and R. Zabini, "What energy functions can be minimized via graph cuts?," IEEE Trans. Pattern Anal. Mach. Intell., vol.26, no.2, pp.147-159, 2004.
- [8] Y. Boykov and V. Kolmogorov, "An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision," IEEE Trans. Pattern Anal. Mach. Intell., vol.26, no.9, pp.1124-1137, 2004.
- [9] B.L. Price, B. Morse, and S. Cohen, "Geodesic graph cut for interactive image segmentation," Proc. CVPR, pp.3288-3295, 2010.
- [10] C. Rother, V. Kolmogorov, T. Minka, and A. Blake, "Cosegmentation of image pairs by histogram matching-incorporating a global constraint into mrfs," Proc. CVPR, pp.993-1000, 2006.
- [11] I.B. Ayed, H.M. Chen, K. Punithakumar, I. Ross, and S. Li, "Graph cut segmentation with a global constraint: Recovering region distribution via a bound of the bhattacharyya measure," Proc. CVPR, pp.3288-3295, 2010.
- [12] V.-Q. Pham, K. Takahashi, and T. Naemura, "Foreground-background segmentation using iterated distribution matching," Proc. CVPR, pp.2113-2120, 2011.
- [13] A. Bhattacharyya, "On a measure of divergence between two statistical populations defined by their probability distributions," Bull. Calcutta Math. Soc.,

- vol.35, pp.99–109, 1943.
- [14] F.J. Aherne, N.A. Thacker, and P. Rockett, “The bhattacharyya metric as an absolute similarity measure for frequency coded data,” *Kybernetika*, vol.34, no.4, pp.363–368, 1998.
- [15] I.B. Ayed, S. Li, and I. Ross, “A statistical overlap prior for variational image segmentation,” *Int. J. Comput. Vis.*, vol.85, pp.115–132, 2009.
- [16] T. Zhang and D. Freedman, “Improving performance of distribution tracking through background mismatch,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol.27, no.2, pp.282–287, 2005.
- [17] D. Freedman and T. Zhang, “Active contours for tracking distributions,” *IEEE Trans. Image Process.*, vol.13, no.4, pp.518–526, 2004.
- [18] 谷合竜典, ファン ヴェトクォク, 高橋桂太, 苗村 健, “前景および背景色分布の同時マッチングによる画像セグメンテーション,” 画像の認識・理解シンポジウム (MIRU 2012), OS14-02/IS3-10, 2012.
- [19] T. Taniai, V.-Q. Pham, K. Takahashi, and T. Naemura, “Image segmentation using dual distribution matching,” *Proc. BMVC*, pp.74.1–74.11, 2012.
- [20] D.D. Lee and H.S. Seung, “Algorithms for non-negative matrix factorization,” *Proc. NIPS*, pp.556–562, 2002.

## 付 録

### $\mathcal{E}_A(\eta) \leq \mathcal{D}(\mathbf{L}; \eta)$ の証明

2通りに表した画像全体の色分布  $\Omega(z)$ ,  $\tilde{\Omega}(z; \eta)$  を

$$\Omega(z) = \underbrace{r_F^L \mathcal{P}_F^L(z)}_{f_1} + \underbrace{r_B^L \mathcal{P}_B^L(z)}_{b_1} \quad (\text{A.1})$$

$$\tilde{\Omega}(z; \eta) = \underbrace{\eta \mathcal{H}_F(z)}_{f_2} + \underbrace{(1-\eta) \mathcal{H}_B(z)}_{b_2} \quad (\text{A.2})$$

と表す。このとき

$$\mathcal{E}_A(\eta) = - \sum_{z \in Z} \sqrt{f_1 f_2 + (f_1 b_2 + b_1 f_2) + b_1 b_2} \quad (\text{A.3})$$

$$\leq - \sum_{z \in Z} \sqrt{f_1 f_2 + 2\sqrt{f_1 f_2} \sqrt{b_1 b_2} + b_1 b_2} \quad (\text{A.4})$$

$$= - \sum_{z \in Z} \sqrt{f_1 f_2} - \sum_{z \in Z} \sqrt{b_1 b_2} = \mathcal{D}(\mathbf{L}; \eta) \quad (\text{A.5})$$

より,  $\mathcal{E}_A(\eta) \leq \mathcal{D}(\mathbf{L}; \eta)$  が成立する。式 (A.3) から式 (A.4) は相加平均と相乗平均の関係

$$\frac{\alpha + \beta}{2} \geq \sqrt{\alpha\beta} \quad (\text{holds equal if } \alpha = \beta) \quad (\text{A.6})$$

によるものである。  $\mathcal{E}_A(\eta) = \mathcal{D}(\mathbf{L}; \eta)$  の等号成立条件


は  $f_1 b_2 = b_1 f_2$ , すなわち, 以下の条件が得られる:

$$r_F^L \mathcal{P}_F^L(z) \cdot (1-\eta) \mathcal{H}_B(z) = r_B^L \mathcal{P}_B^L(z) \cdot \eta \mathcal{H}_F(z) \quad (\text{A.7})$$

また  $\eta = \eta_F$  のとき, 式 (10), (11) は上式を満たす


□

(平成 24 年 10 月 10 日受付, 25 年 2 月 10 日再受付)



谷合 竜典

平 21 東京高専・情報工学卒, 平 24 東大・工・電子情報卒。現在, 同大大学院情報理工学系研究科修士課程に在籍。コンピュータビジョン, 画像セグメンテーションなどに興味をもつ。



ファン ヴェトクォク (正員)

平 19 東大・工・電子情報卒。平 24 同大大学院情報理工学系研究科博士課程了。博士 (情報理工学)。日本学術振興会特別研究員を経て, 平 24 より (株) 東芝研究開発センターインタラクティブメディアラボラトリーに所属。コンピュータビジョン, 物体認識, 画像セグメンテーション, 人物追跡に関する研究に従事。



高橋 桂太 (正員)

平 13 東大・工・電子情報卒。平 18 同大大学院情報理工学系研究科博士課程了。博士 (情報理工学)。日本学術振興会特別研究員, 東京大学 IRT 研究機構特任助教, 電気通信大学大学院情報理工学研究科助教などを経て, 現在, 名古屋大学大学院工学研究科准教授。三次元映像処理, イメージベースストレングリングなどの研究に従事。



苗村 健 (正員)

平 4 東大・工・電子卒。平 9 同大大学院工学系研究科博士課程了。博士 (工学)。助手・講師を経て, 平 12 米国スタンフォード大学客員助教授 (日本学術振興会特別研究員), 平 14 東京大学大学院情報学環助教授, 平 16 同情報理工学系研究科電子情報学専攻助教授 (平 17 准教授), 平 25 同教授, 現在に至る。メディア+コンテンツ, 複合現実感, 空間共有通信の研究に従事。