

Label Ranking による Semantic Texton Forests のマルチラベルへの拡張

福田 考晃[†] 藤吉 弘亘[†]

[†] 中部大学大学院 工学研究科 〒487-8501 愛知県春日井市松本町 1200

E-mail: †fukuta@vision.cs.chubu.ac.jp, hf@cs.chubu.ac.jp

あらまし 本稿では、マルチラベルに対応したセマンティックセグメンテーションを実現するために、Label Ranking を用いて Semantic Texton Forests をマルチラベルへ拡張する LR-STFs を提案する。LR-STFs は Semantic Texton Forests の学習アルゴリズムを、マルチラベルサンプルを用いた学習タスクである Label Ranking を利用してマルチラベルへ拡張する。LR-STFs を利用して BoF によるヒストグラムに表現を行い、Label Powerset 法を用いてラベルの符号化を行うことでマルチラベルに対応した識別器 LP-RFs を構築する。これによりマルチラベルに対応したセマンティックセグメンテーションを実現することが可能となる。評価実験により、約 70% の精度でセグメンテーションが可能であることを示し、提案手法によるマルチラベルに対応したセマンティックセグメンテーションの有効性を確認した。

キーワード セマンティックセグメンテーション, セマンティックテキストンフォレスト, マルチラベル, ラベルランキング

An Extension of Semantic Texton Forests to Multi-Label Problem Using Label Ranking

Takaaki FUKUTA[†] and Hironobu FUJIYOSHI[†]

[†] Dept. of Computer Science, Chubu University Matsumoto-cho 1200, Kasugai-shi, Aichi, 487-8501 Japan

E-mail: †fukuta@vision.cs.chubu.ac.jp, hf@cs.chubu.ac.jp

Abstract A method for multi-label semantic segmentation is proposed. The proposed method is based on the use of semantic texton forests, which can compute texton features faster than other method. We adapted the training algorithm for semantic texton forests to multi-label problems by using label ranking, which is a multi-label learning task. Our multi-label semantic segmentation method consists of two steps: extracting features from each pixel of an image by using semantic texton forests that have been adapted to multi-label problems by using label ranking, and classifying each pixel by using multi-label classifiers that have been trained using label powersets, where sets of labels are considered as one category. The proposed method can divide regions into not only single label categories but also multi-label categories. Experimental results for an original dataset including multi-label categories show that our method has about 70% segmentation accuracy.

Key words Semantic Segmentation, Semantic Texton Forest, Multi-Label, Label Ranking

1. はじめに

屋内外の風景写真などの画像からシーンを理解するには、色分割だけでなく、同一カテゴリの領域を認識して分割する必要がある。これをセマンティックセグメンテーションと呼ぶ [1]。セマンティックセグメンテーションでは、画像内に存在する複数の物体カテゴリ名だけでなく、物体の位置を獲得することができるという利点があるため、シーンの理解には重要な技術である。

セマンティックセグメンテーションを実現する手法は、ピクセルレベルや小領域レベルで統計的手法によりテクスチャ解析、色解析、Bag-of-features などの特徴量を算出し、Conditional Random Field(以下 CRF) モデルを利用してコンテキストを捉えて領域分割とカテゴリ認識を同時に行う手法が提案されている。[1] [2] [3] [4]。従来のセマンティックセグメンテーションでは、分割した領域に対応するカテゴリが 1 つである。この場合、花畑が撮影された画像のように花と茎が混在している対象領域を、それぞれ花と茎のカテゴリとして分割することになり、非

常に難しい問題となる。一方、領域に対応する複数カテゴリを許容すれば、花畑の領域を花と茎のマルチラベルを持つ領域とすることができ、この問題を解決することができる。

そこで本稿では、マルチラベルに対応したセマンティックセグメンテーション法を提案する。提案手法では各ピクセルから周囲の領域を利用して特徴抽出を行い、識別を行う。まず、特徴抽出においては、マルチラベルからシングルラベルを学習する Label Ranking を取り入れた Semantic Texton Forests(LR-STFs) を提案する。次に識別においては、Label Powerset 法を用いてマルチラベルをひとつのカテゴリとして Random Forests を学習した (LP-RFs) 識別器を提案する。これにより、マルチラベルに対応したセマンティックセグメンテーションを実現する。

2. 関連研究とマルチラベル問題

2.1 関連研究

セマンティックセグメンテーション手法は、一般的にピクセルレベルや小領域レベルからテクスチャ解析や、色解析により特徴量を抽出して識別を行い、コンテキスト情報を利用する。このようなアプローチにおいて従来から、コンテキストの利用法、特徴量の検討、学習サンプルの簡易化の3つの問題に分けて取り組まれている。コンテキストの利用については、CRF が用いられている。He 等は階層構造を取り入れた CRF を用いた手法を提案した [2]。Shotton 等は、CRF により捉える対象を工夫し、形状やテクスチャ、位置情報などのコンテキストを考慮できる手法を提案した [3]。Winn 等はオクルージョンなど物体間のレイアウトに着目した手法を提案した [5]。Tu 等は CRF を用いずにコンテキストを捉える手法 Auto-Context を提案した [6]。

特徴量の検討では様々な特徴量が検討されている。Scroff 等は、カラーヒストグラム、Texton、HOG 特徴量などの物体認識において一般的に用いられる特徴量の中から最適な特徴量の検討を行った [7]。Shotton 等は、Texton 特徴量の算出コストを大幅に軽減するために、Random Forests [8] を用いて画像パッチ内のピクセルを正規化を行わずにテクスチャ解析できる特徴量を学習する Semantic Texton Forests を提案した [1]。

上記の手法は、大量のピクセルレベルの教師信号付きデータが必要であり、その作成にかかるコストは非常に膨大となる。近年では、学習方法の工夫により学習サンプルの簡易化が検討されている。Tighe 等はキーワード付き画像を大量に用意しておき、リトリバル問題とセグメンテーション問題を組み合わせた手法を提案した [4]。また、Vezhnevets 等は Geometric Context と Multiple Instance Learning, Multi-Task Learning を取り入れることで、画像に対してのみラベルが付けられている弱教師あり学習に展開した [9]。

2.2 マルチラベル問題

従来のセマンティックセグメンテーションでは、図 1 に示すような原画像と教師信号となるラベル画像が対となった学習データを必要とする。ラベル画像とは、図 1(b) に示すように、ピクセル毎に属しているカテゴリのラベルが割り当てられたものである。ここで、あるシーンで撮影された 2 枚の画像を図

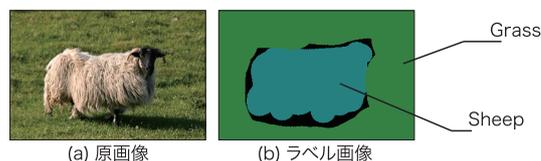


図 1 シングルラベル問題 (MSRC21 データセット [3])

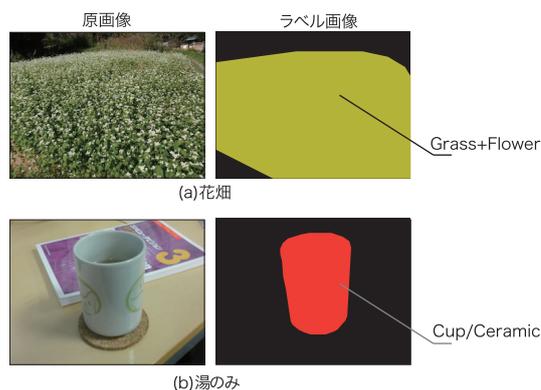


図 2 マルチラベル問題

2(a)(b) に示す。図 2(a) は花畑が撮影された画像である。この画像に対して、「花卉」というカテゴリと「葉」というカテゴリを対象とした場合、花畑はそれらの組み合わせで表現することが可能である。次に、図 2(b) は湯のみが撮影された画像である。これに対し、「コップ」というカテゴリと「陶器」というカテゴリを対象とした場合、それらを組み合わせで陶器製のコップとして湯のみを表現することが可能である。これら 2 つの例は、同一領域に複数のラベルが割り当てられるマルチラベルの例、しかし前者が構成されるパーツを示しているのに対し、後者は素材を示している点で異なる。

本稿では、図 2(a) のようなパーツを表すマルチラベル問題を対象とし、セグメンテーションを行うことを目的とする。2.1 章で述べた従来法には、このマルチラベル問題に対応した手法は無い。そのため、シングルラベルを扱う従来法 Semantic Texton Forests をベースとしてマルチラベルに拡張を行うことで、マルチラベルに対応したセマンティックセグメンテーションを検討する。

3. 提案手法

提案手法は、シングルラベルを扱う従来法である STFs をベースに、マルチラベルに対応したセマンティックセグメンテーションを実現するために 2 点の拡張を行う。まず一つ目は、特徴抽出のための STFs に Label Ranking を用いてマルチラベルを分離できるように学習を行う LR-STFs を構築する。これにより、マルチラベルデータを用いた STFs の学習が可能となる。二つ目は、対象物体のカテゴリを識別するために、Label Powerset を用いてマルチラベルに対応した Random Forests 識別器 LP-RFs を構築する。これにより、対象物体にマルチラベルを考慮することが可能となる。

まず、シングルラベルを扱う STFs について説明を行い、マルチラベルの学習を取り入れた LR-STFs について述べ、その

後にマルチラベルに対応した Random Forests である LP-RFs について述べ、最後にそれらを用いたセマンティックセグメンテーションについて述べる。

3.1 Semantic Texton Forests の学習

STFs は、画像パッチを Random Forests [8] アルゴリズムにより学習することで、決定木構造の識別器を構築し、その構造を利用して特徴表現を行う手法である。STFs の学習では、木の数 T 、特徴選択回数 F 、しきい値選択回数 TH を定義し、学習サンプルからサブセット I_T を作成することでサブセット毎に決定木の構築を行う。決定木の構築は分岐ノードを繰り返し作成することにより行う。分岐ノードの設計は自由であり、STFs では Semantic Texton Forests Features と呼ばれる 4 つのオペレータ、(i) $p_{x,y,b}$, (ii) $p_{x_1,y_1,b_1} + p_{x_2,y_2,b_2}$ (iii) $p_{x_1,y_1,b_1} - p_{x_2,y_2,b_2}$ (iv) $|p_{x_1,y_1,b_1} - p_{x_2,y_2,b_2}|$ により算出される特徴量 f としきい値 t を用いる。この f と t の候補を特徴選択回数 F としきい値選択回数 TH 分の候補をランダムで用意し、それぞれの組み合わせの分岐能力を情報利得 ΔE により評価し、最適なものを利用する。ある分岐ノード n に分かれてきたデータ集合 I_n 、候補 f と t を用いて 1, 式 (2) により I_l と I_r を算出する。

$$I_l = \{i \in I_n | f(v_i) < t\} \quad (1)$$

$$I_r = I_n \setminus I_l \quad (2)$$

この I_l と I_r を用いて、式 (3) により情報利得 ΔE を算出する。

$$\Delta E = -\frac{|I_l|}{|I_n|} E(I_l) - \frac{|I_r|}{|I_n|} E(I_r) \quad (3)$$

ここで、関数 $E(I)$ は情報エントロピーを現しており式 (4) により算出する。

$$E(I) = -\sum_{i=1}^n p(c_i) \log p(c_i) \quad (4)$$

ここで、 $p(c_i)$ はクラス c_i の確率 (相対頻度) を表しており、学習サンプルにつけられている教師信号により求められる。これらの処理を繰り返すことにより分岐ノードを作成してゆき、情報利得が十分大きくなった場合に末端ノード l を作成し、分岐したデータを用いて確率 $P(c|l)$ を計算し、識別に用いる。これにより、各ピクセルに対してシングルラベルの教師信号が付けられたデータの学習が可能となる。

3.2 LR-STFs の学習

Label Ranking とは、マルチラベルの学習データを用いてシングルラベルの順位付けを行う識別器を作成するアプローチである。提案手法では、STFs に Label Ranking を取り入れることでマルチラベルのサンプルを利用した学習を行う LR-STFs を構築する。Label Ranking を利用することにより、マルチラベルをシングルラベルのランキング問題に置き換えられるため、例えば「花+茎」のマルチラベルを「花」がどの程度で「茎」がどの程度という量により表現できるようになる。そのため LR-STFs を用いることで、マルチラベルを捉えるための特徴抽出が可能となる。

LR-STFs の学習アルゴリズムをアルゴリズム 1 に示す。Label Ranking を行うためには、マルチラベルをシングルラベル

アルゴリズム 1 : LR-STFs の学習アルゴリズム

Require: 学習サンプル: I
Require: 木の数: T
Require: 特徴選択回数 F
Require: しきい値選択回数 TH
Require: ラベル選択回数 L
Require: T 個のサブセット作成 $I = (I_1, I_2, \dots, I_T)$.

- 1: **For** $k = 1, \dots$, 木の数 T まで
- 2: サブセット I_k を用いて決定木を作成
- 3: **For** $l = 1, \dots$, 特徴量選択数 F まで
- 4: 分岐関数 f をランダムに選択
- 5: **For** $m = 1, \dots$, しきい値選択数 TH まで
- 6: しきい値 t をランダムに選択
- 7: **For** $n = 1, \dots$, ラベル選択回数 L まで
- 8: ラベル候補をランダムに選択
- 9:
$$C_i = \begin{cases} \text{rand}(C_i) & |C_i| > 2 \\ c_1 & \text{otherwise} \end{cases} \quad (i \in I_n)$$
- 10: f と t を用いてデータを I_l と I_r に分岐
- 11: $I_l = \{i \in I_n | f(v_i) < t\}$
- 12: $I_r = I_n \setminus I_l$
- 13: ラベル候補 C_i を利用して情報利得 ΔE を算出
- 14:
$$\Delta E = -\frac{|I_l|}{|I_n|} E(I_l) - \frac{|I_r|}{|I_n|} E(I_r)$$
- 15: **if** $\Delta E > \Delta E_{old}$ f, t, I_l, I_r, C_i を保存
- 16: **end for**
- 17: **end for**
- 18: **end for**
- 19: **if** $gain = 0$ 末端ノードを作成
- 20: $C_i^{max} = \arg \max_c p(c|i)$ ($i \in I_n$)
- 21: 最終ラベル C_i^{max} を用いて $P(c|l)$ を計算
- 22: **else** I_l, I_r を用いて再帰処理
- 23: **end for**

に分解する処理を何らかの基準により行う必要がある。そこで、我々は STFs の学習法において、最適な分岐ノードの決定を情報利得を基準に行う点に着目し、マルチラベルのシングルラベルへの分解も同様に情報利得を基準に行う。分岐ノードを作成するために特徴量 f としきい値 t の候補をランダムで用意したように、マルチラベルサンプルに付けられているラベルの中から分解する候補のラベルをランダムで用意する。ある分岐に利用するサンプル $i \in I_n$ にマルチラベル $C_i = \{c_1, c_2, \dots, c_n\}$ が付けられているとし、ラベルの候補を C_i とすると、式 (5) により選択する。

$$C_i = \begin{cases} \text{rand}(C_i) & |C_i| > 2 \\ c_1 & \text{otherwise} \end{cases} \quad (C_i \neq \phi) \quad (5)$$

ここで、関数 rand は集合 C_i の中の要素からひとつをランダムで選択する。また c_1 は、シングルラベルを意味し、要素が一つの集合 C_i の要素を意味する。この候補選択を L 回を行い、 L 個の候補の中から、最も情報利得が高くなるラベルの候補をその分岐におけるサンプル $i \in I_n$ のラベルとする。

この処理を繰り返すことにより、サンプル $i \in I_n$ は分岐された回数 S だけラベルが決定され、次のような履歴が作成される $\{C_i^1, C_i^2, \dots, C_i^S\}$ 。これを用いてサンプル i の最終ラベル C_i^{max} を算出する。まず、履歴によりそのサンプルのクラスの確率 $p(c|i)$ を求める。そして、以下の式により最終ラベル C_i^{max} を求める。

$$C_i^{max} = \arg \max_c p(c|i) \quad (6)$$

これらの処理により、サンプル i につけられたマルチラベル C_i は C_i^{max} になり、シングルラベルへの分解を行うことができた。この最終ラベル C_i^{max} を用いて末端ノードのクラスの確率 $P(c|l)$ を算出することで、Label Ranking が可能となる。

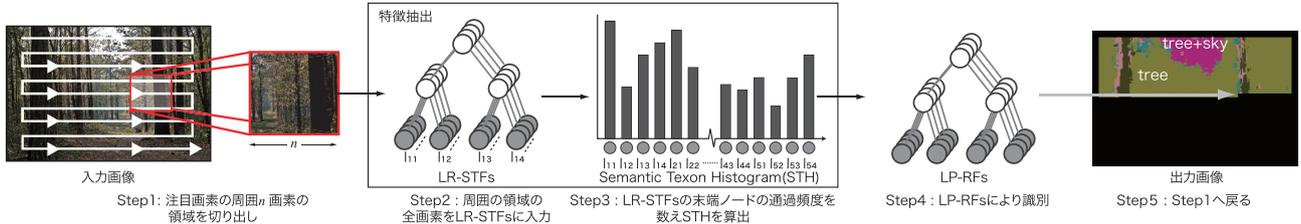


図3 提案手法の流れ

3.3 LP-RFsの構築

LR-STFsにより学習データから Semantic Texton Histogram 特徴を算出し、Label Powerset を用いて Random Forests を学習することでマルチラベルに対応した識別器 LP-RFs を構築する。

3.3.1 Semantic Texton Histogram

Semantic Texton Histogram(以下 STH) は、STFs のノードを visual word とし、対象物体をヒストグラム特徴により表現する手法である。通常の Bag-of-features は k-means 等のクラスタリング手法により visual word を作成するためカテゴリの情報を持たないが、STH は Random Forests により学習を行うため、ノードを visual word とすることで意味を含んだヒストグラム特徴となる。提案手法では、末端ノードにたどり着いた頻度をカウントすることで STH を算出する。

学習画像から特徴抽出を行う際には、ある注目画素をひとつのサンプルとして考え、周囲の $n \times n$ 画素を LR-STFs に入力し、末端ノードの到達頻度を用いて STH を算出する。

3.3.2 Label Powerset

Read 等の提案した Label Powerset 法 [10] は、従来のマルチクラス識別器を構築する手法と組み合わせることで、マルチラベルに対応することが可能となる手法である。この手法は、マルチラベルを符号化することにより新しいラベルを作成し、マルチラベルをシングルラベルとして学習する方法である。あるサンプルに付与されているラベルを c とすると表1に示すように教師信号を符号化する。この処理を行うことによりマルチラベルをシングルラベルとみなすことができ、Random Forests のような従来のマルチクラス識別器を構築するための学習アルゴリズムによりマルチラベルが学習可能となる。

表1 Label Powerset

サンプル	ラベル	処理後のラベル
1	$\{c_1, c_4\}$	$\{c_{1,4}\}$
2	$\{c_3, c_4\}$	$\{c_{3,4}\}$
3	$\{c_1\}$	$\{c_1\}$
4	$\{c_2, c_3, c_4\}$	$\{c_{2,3,4}\}$

3.4 セマンティックセグメンテーション

3.2 で述べた LR-STFs と、3.3 で述べた LP-RFs を用いて未知画像のセマンティックセグメンテーションを行う。提案手法を図3に示し、以下に流れを示す。

Step1 注目画素を中心とした $n \times n$ の画像を切り出す

Step2 切り出された画像の全画素を LR-STFs に入力

Step3 STFs の末端ノードの通過頻度を数えて STH を算出

Step4 算出された STH を LP-RFs により識別

Step5 Step1 に戻る

以上の処理を入力画像の全画素に行うことで、マルチラベルに対応したセマンティックセグメンテーションが可能となる。また、Step1 の画像の切り出しについては、画像の端になると切り出しが不可能になる画素が存在する。それらの画素については特別な処理は行わず認識対象外としており、図3に示した結果画像のような枠がついた結果となる。

4. 実験および考察

提案手法によるマルチラベルに対応したセマンティックセグメンテーションの評価実験を行う。提案手法は LR-STFs と LP-RFs に Random Forests を用いているため、学習パラメータについて述べる。学習パラメータを表2に示す。

以下で本実験で用いる実験データと評価方法について述べた後に提案手法の評価を述べる。

表2 提案手法の学習パラメータ

項目	LR-STFs	LP-RFs
決定木の数	5	5
決定木の深さ	10	10
特徴選択回数	400	100
しきい値選択回数	5	3
ラベル選択回数	2	なし
サブセットの割合	20%	20%

4.1 実験データと評価方法

評価実験には、Flickr(<http://www.flickr.com/>) より無作為にダウンロードした画像をラベリングした実験データを用いる。対象カテゴリは、Face, Body, Tree, Grass, Sky, Flower, Neon の7カテゴリ、Grass + Flower, Sky + Tree のマルチラベル2カテゴリの実質9カテゴリである。実験データは、すべて合わせて1168枚の画像があり、学習用に587枚の画像、評価用に581枚の画像を利用する。

評価はピクセルレベルでの評価を行う。評価方法は、各カテゴリ毎に算出した再現率 (Recall) を平均した値を平均再現率として用いる。セグメンテーション結果から、あるカテゴリにおいてセグメンテーションが正解した領域の面積を True Positive (TP) とする。そして、他のカテゴリと間違えた領域の面積を False Negative (FN) とする。このとき Recall を以下のように定義する。

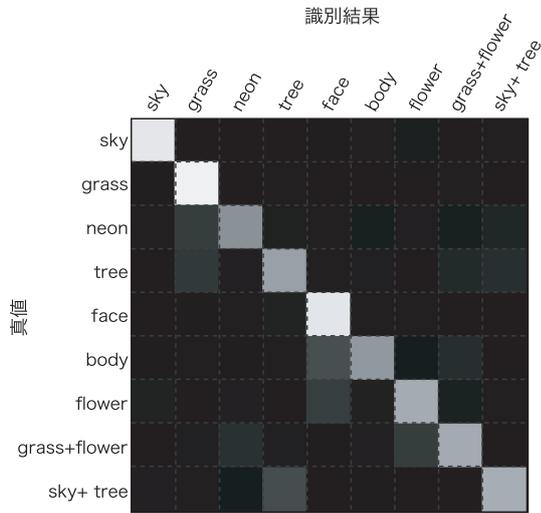


図4 Confusion Matrix

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

4.2 精度評価

実験データセットを用いて、提案手法の学習を行い、提案手法の有効性を確認する。提案手法による Confusion Matrix を図4に示す。また、平均再現率は70.6%である。マルチラベルは、複数のカテゴリが複合したものである。そのため、grass+flowerはflowerとgrassに混同されやすく、sky+treeはskyとtreeに混同されやすいことが分かる。これに対し、grassやskyといったマルチラベルカテゴリ grass + flower と sky+tree に含まれるシングルカテゴリはマルチラベルカテゴリにあまり混同されないことがわかった。これにより、マルチラベルを考慮してもシングルラベルの識別性能には影響が少ないことを確認した。9つのセグメンテーションクラスの内すべてのカテゴリにおいて、対角成分の値が大きくなり、マルチラベルとシングルラベルの識別とセグメンテーションが可能であることを確認した。

識別結果の例を図6に示す。この例には、考察のため従来法であるSTFsによるシングルラベルのセグメンテーション結果を並べて示している。(a)や(d),(h)のシングルラベルの例は従来のSTFsを用いた場合と提案手法を用いた場合の差が無いことが分かり、マルチラベルを取り入れたことによりシングルラベルが識別出来なくなるような効果は見られなかった。(c)の例ではSTFsのみでは捉えられなかった対象neonを、若干膨張してはいるが捉えていることが分かる。(b)(e)(f)(g)のマルチラベルの例では、STFsはマルチラベルを考慮していないため、無理に分割しようとしていることや、対象物体自体を捉えられていないが、提案手法はマルチラベルを考慮することでこれらの対象を上手く捉えられていることが分かる。

4.3 Label Ranking 手法の評価実験

Label Ranking を実現する手法は従来から提案されている。[11]で用いられている手法はLP-RFsに取り入れたLabel Powerset法のように教師信号に工夫を行い、従来の学習アルゴリズムによりLabel Rankingが可能となる。表3にそれら

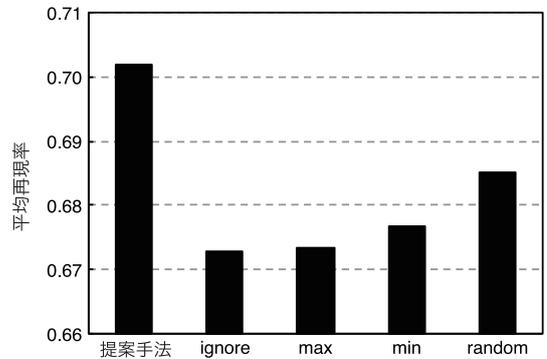


図5 Label Ranking 手法の比較結果

をまとめる。これらと提案手法の比較を行うために、これらの手法を用いて構築したSTFsを用いたセグメンテーション結果と、提案手法であるLR-STFsを用いたセグメンテーション結果の精度比較を行う。

表3 従来のLabel Ranking 手法[11]

サンプル	ラベル	max	min	Random	Ignore
1	{c ₁ , c ₄ }	c ₄	c ₁	c ₁	/
2	{c ₃ , c ₄ }	c ₄	c ₃	c ₄	/
3	{c ₁ }	c ₁	c ₁	c ₁	c ₁
4	{c ₂ , c ₃ , c ₄ }	c ₄	c ₂	c ₃	/

比較結果を図5に示す。結果より従来法で最も精度が高かったRandomと比較して約2%高精度となり提案手法の有効性を示した。これは、学習の前に教師信号に工夫を施す従来法よりも学習中にマルチラベルをシングルラベルに分離する学習アルゴリズムを取り入れたことにより、マルチラベルを捉えやすい特徴表現が可能とであるためだと考えられる。また、Ignoreは最も識別精度が低いという結果が得られた。Ignoreは表3で示したように、マルチラベルを利用しない手法である。そのため、本手法によりマルチラベルに対応したセグメンテーションを行う場合は、STFsの学習にマルチラベルのサンプルを利用することが重要であることを示した。

5. おわりに

提案手法では各ピクセルから周囲の領域を利用して特徴抽出を行い、識別を行うことでセマンティックセグメンテーションを行った。これを実現するために、STFsにマルチラベルからシングルラベルを学習するLabel Rankingを取り入れたLR-STFsを提案した。また、マルチラベルを捉えるためにLabel Powerset法を用いてマルチラベルをひとつのカテゴリとして学習したRandom Forests識別器LP-RFsを利用した。独自に構築したデータセットを用いた評価実験により、約70%の精度でセグメンテーションが可能であることを示した。今後は、マルチラベルカテゴリの組み合わせ数、カテゴリ数を増やした場合についても検討を行う予定である。

文 献

- [1] J. Shotton, M. Johnson, and R. Cipolla, "Semantic texton forests for image categorization and segmentation," *Computer Vision and Pattern Recognition*, 2008.

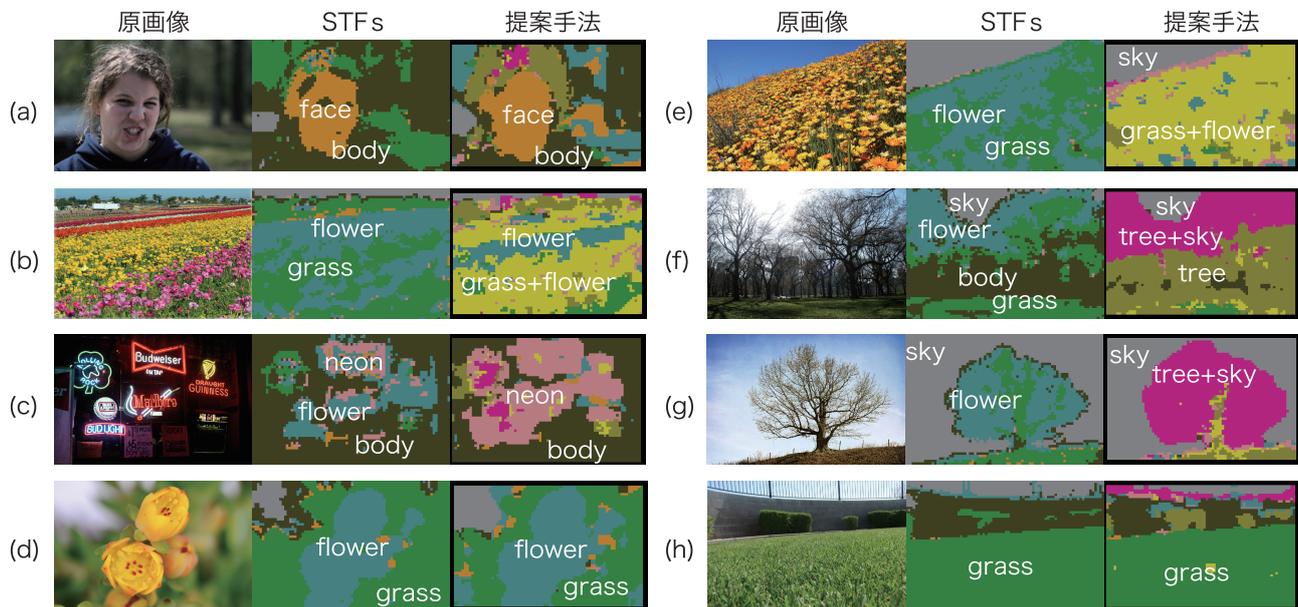


図 6 セグメンテーション結果

- [2] X. He, R.S. Zemel, and M.A. Carreira-Perpinan, "Multi-scale conditional random fields for image labeling," *Computer Vision and Pattern Recognition*, 2004.
- [3] J. Shotton, J. Winn, C. Rother, and A. Criminisi, "Textonboost: Joint appearance, shape and context modeling for multi-class object recognition and segmentation," *European Conference on Computer Vision*, 2006.
- [4] J. Tighe, and S. Lazebnik, "Superparsing: Scalable non-parametric image parsing with superpixels," *European Conference on Computer Vision*, 2010.
- [5] J. Winn, and J. Shotton, "The layout consistent random field for recognizing and segmenting partially occluded objects," *Computer Vision and Pattern Recognition*, 2006.
- [6] Z. Tu, "Auto-context and its application to high-level vision tasks," *Computer Vision and Pattern Recognition*, 2008.
- [7] F. Schroff, A. Criminisi, and A. Zisserman, "Object class segmentation using random forests," *British Machine Vision Conference*, 2008.
- [8] L. Breiman, "Random forests," *Machine learning*, vol.45, no.1, pp.5–32, 2001.
- [9] A. Vezhnevets, and J.M. Buhmann, "Towards weakly supervised semantic segmentation by means of multiple instance and multitask learning," *Computer Vision and Pattern Recognition*, pp.3249-3256, 2010.
- [10] J. Read, "A pruned problem transformation method for multi-label classification," *Proc. New Zealand Computer Science Research Student Conference*, pp.143–150, 2008.
- [11] G. Tsoumakas, I. Katakis, and I. Vlahavas, "Mining multi-label data," *Data Mining and Knowledge Discovery Handbook*, 2010.