SIFT と Graph Cuts を用いた物体認識及びセグメンテーション

須賀 晃† 福田 恵太† 滝口 哲也†† 有木 康雄††

†神戸大学大学院工学研究科〒657-8501 兵庫県神戸市灘区六甲台町1-1

計 神戸大学自然科学系先端融合研究環〒657-8501 兵庫県神戸市灘区六甲台町1-1

E-mail: [†]{akira1234,fukuda}@me.cs.scitec.kobe-u.ac.jp, [†]†{takigu,ariki}@kobe-u.ac.jp

あらまし 本稿では、Scale-Invariant Feature Transform(SIFT) と Graph Cuts を用いた物体の認識・セグメンテー ション法を提案する. SIFT 特徴は回転・スケール変化・照明変化に不変な特徴として、物体認識などによく用いられ てる. しかしながら、従来の SIFT 特徴を用いた物体認識手法では、物体領域の詳細な切り出しまで行うことができ なかった. 一方、物体領域のセグメンテーションの手法としては、Graph Cuts が提案されており、比較的精度の高い 領域抽出が可能とされているが、人間が手動で seed を与えなければならないという問題が残っている. 本手法では、 SIFT と Graph Cuts を組み合わせることにより、各々の問題を解決する. 具体的には、SIFT 特徴の投票処理により 物体の存在を認識し、認識に用いた SIFT 特徴をそのまま Graph Cuts の seed として用いることで、さらに物体のセ グメンテーションを行う. これにより、認識とセグメンテーションの両方を全て自動で行うことが可能となる. 実験 の結果、オクルージョンを含む複雑な背景下においても対象物体を認識し、自動でその領域まで切り出すことが可能 となり、本手法の有効性が確認できた.

キーワード 物体認識,画像セグメンテーション, SIFT, Graph Cuts

Object Recognition and Segmentation Using SIFT and Graph Cuts

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

[†] Graduate School of Engineering, Kobe University 1–1, Rokkodai, Nada, Kobe, Japan

†† Organization of Advanced Science and Technology, Kobe University 1–1, Rokkodai, Nada, Kobe, Japan E-mail: †{akira1234,fukuda}@me.cs.scitec.kobe-u.ac.jp, ††{takigu,ariki}@kobe-u.ac.jp

Abstract This paper shows the method of object recognition and segmentation using Scale-Invariant Feature Transform(SIFT) and Graph Cuts. SIFT feature is invariant for rotations, scale changes, and illumination changes and it is often used for object recognition. However, in previous object recognition work using SIFT, the detailed object region was not segmented. On the other hand, Graph Cuts is proposed as a segmentation method with comparatively high accuracy. But there is a problem that it is necessary to give seeds manually. By combing SIFT and Graph Cuts, in our method, each problem is solved. Concretely, the existence of objects is recognized first by vote processing. Successively, the object region is cut out by Graph Cuts using SIFT keypoints as seeds. Thanks to this combination, both recognition and segmentation are performed automatically. Experimental results show that this technique is applicable under cluttered backgrounds including occlusion and it demonstrates the effectiveness of our approach.

Key words Object recognition, Image segmentation, SIFT, Graph Cuts

1. はじめに

物体認識は、計算機の認知能力を実現させるための重要な研 究分野の一つである.近年では、AR(Augmented Reality)と いった技術も注目されており、現実の環境に物体のより豊富な 情報を付加提示することで、道路内の情報提供や、医療技術支 援を行うという現実的な環境の支援の研究も進んでおり,有用 性の高い研究と言える.また,認識だけでなく物体領域の切 り出しをすることで,ロボットが物体を持ち運ぶことが容易に なれば,留守中にロボットが家の中の物を自動的に整理すると いったように,人間生活環境におけるロボットの活躍にも貢献 できる. 従来の物体認識手法の主な問題点としては、物体の回転やス ケール変化、オクルージョン等への対応や、物体領域の切り出 し方法などが挙げられ、これらが物体認識を困難にしている原 因であった. Scale-Invariant Feature Transform(SIFT)は、こ れらの問題に頑健な特徴量として Lowe によって提案された[1]. また、SIFT を用いた物体認識も提案されている[2].しかしこ れらの研究では物体の切り出しまでは行っていなかった.

一方,物体の切り出しに関しては,セグメンテーション問題 をエネルギー最小化問題として解く Graph Cuts が提案されて いる. Graph Cuts では領域と境界の両方の情報を用いたセグ メンテーションが可能で,画像処理の多くの分野で応用されて いる.しかし, seed を手動で与えなければならないという問題 があった.そこで,本研究では SIFT による物体認識で得られ た特徴点を,Graph Cuts の seed として用いることで,Graph Cuts を自動化し,物体の検出から切り出しまでを全て自動で 行う方法を提案する.

2. 関連研究

物体認識に関する研究には長い歴史がある.その中で,画 像間の対応を取るために,局所特徴が注目されるようになっ た.Harris らは,コーナーを検出し,それを特徴点とする Harris Corner Detector を提案した[3].また,Schmid らは Harris Corner Detector で得られた特徴点の画素値や微分値から特徴 量を求め,画像の回転に頑健な局所特徴量を記述した[4].さら に,Lowe はスケールスペースを用いることで,画像のスケー ル変化にも対応させた特徴量である Scale-Invariant Feature Transform(SIFT)を提案した.

また,画像のセグメンテーションに関する研究としては, Snakes [5] や Level Set Method [6], Graph Cuts [7] が提案さ れている. Snakes や Level Set Method では境界線に対するエ ネルギー関数から局所最小解を求めるのに対し, Graph Cuts では各領域からのエネルギー関数を定義するため,大域最小解 を得ることが出来る. Boykov らは, Min-Cut/Max-Flow algorithm を用いてエネルギー最小化を行い Graph Cuts を行う 手法 [8] を提案している.

3. SIFT と Graph Cuts

3.1 SIFT

3.1.1 特徵点検出

SIFT は、スケール変化による不変性を得るため、対象とする 点の特徴をより表現できるスケールの範囲を自動的に決定する. 画像中の特徴点の検出には、まず、スケールの異なるガウシア ンフィルタを用いて画像を平滑化する.平滑化画像 *L*(*x*, *y*, *σ*) は以下の式により求められる.

$$L(x, y, \sigma) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) * I(x, y)$$
(1)

次に,各平滑化画像の差分画像である DoG 画像を求める. DoG 画像 $D(x, y, \sigma)$ は以下の式で求められる.

$$D(x, y, \sigma) = L(x, y, k\sigma) - L(x, y, \sigma)$$
(2)

k は増加率を表す. この DoG 処理をk 倍ずつ大きくした異 なるスケール間で行うことで,図1に示すように複数の DoG 画像が得られる.

次に,得られた DoG 画像から極値を検出し,特徴点とスケー ルを決定する.極値は,図1のように DoG 画像3枚一組とし, 注目画素(図中の×印)の DoG 値を,隣接する上下のスケール を含めた26 近傍の画素(図中の青丸)と比較することで検出す る.ここで検出された極値が特徴点の候補点となる.SIFT は, 特徴点検出と同時にスケールが決まるため,異なるサイズの画 像でも空間的に同範囲の領域から特徴量を記述することができ る.そのため,スケール変化に不変な特徴量となる.



図 1 特徴点検出

3.1.2 特徴量記述

まず、検出された各特徴点に対して、代表となるオリエン テーションを求める.特徴点が検出された平滑化画像の各画素 において、勾配強度 m(x,y) とその勾配方向 $\theta(x,y)$ を以下の 式より求める.

$$m(x,y) = \sqrt{f_x(x,y)^2 + f_y(x,y)^2}$$
(3)

$$\theta(x,y) = \tan^{-1} \frac{f_y(x,y)}{f_x(x,y)} \tag{4}$$

$$\begin{cases} f_x(x,y) = L(x+1,y) - L(x-1,y) \\ f_y(x,y) = L(x,y+1) - L(x,y-1) \end{cases}$$
(5)

以上により得られた勾配強度 m(x,y) と勾配方向 $\theta(x,y)$ を 用いて,重み付き勾配方向ヒストグラムを以下の式により作成 する.

$$h_{\theta'} = \sum_{x} \sum_{y} w(x, y) \cdot \delta[\theta', \theta(x, y)]$$
(6)

$$v(x,y) = G(x,y,\sigma) \cdot m(x,y) \tag{7}$$

ここで、 h_{θ} は全方向を 36 方向に量子化したヒストグラムで ある. w(x,y) は画素 (x,y) の重みである. この 36 方向のヒス トグラムの最大値の 80 %以上のオリエンテーションを、その 特徴点の代表オリエンテーションとして割り当てる.

次に,特徴点の周辺領域を,割り当てられた代表オリエン テーションを基準とした軸に回転させる.これにより常に代表 オリエンテーションを基準として特徴量が算出されるため,回 転に対する不変性が得られる.そして,この特徴点周辺領域を 16 ブロックに分割し,各ブロック毎に8方向の輝度勾配ヒスト グラムを作成する.これにより,図2のような4ブロック×4 ブロック×8方向の128次元の特徴量が得られる.



3.2 Graph Cuts

3.2.1 エネルギー関数

まず,画像 Pにおいて各ピクセルを $p \in P$ としたとき, pの近傍のピクセルを $q \in N$ と定義する.また、ラベルを $A = (A_1, ..., A_p, ..., A_{|p|})$ と定義する. このラベルは、物体か 背景かを示すラベルで,各A_pに対して物体 ("obj")か背景 ("bkg")のラベルが与えられる. Graph Cuts で用いるエネル ギー関数は次のように定義する.

$$E(A) = \lambda \cdot R(A) + B(A) \tag{8}$$

ここで、 $\lambda (\geq 0)$ は、R(A)と、B(A)の比率のパラメータで、 R(A) は領域情報の関数, B(A) は境界情報の関数である. そ れぞれの情報の関数は式(9)のように定義する.

$$\begin{cases} R(A) = \sum_{p \in P} R_p(A_p) \\ B(A) = \sum_{\{p,q\} \in N} B_{\{p,q\}} \cdot \delta(A_p, A_q) \end{cases}$$
(9)

ここで, $A_p \neq A_q$ ならば $\delta(A_p, A_q)$ は 1, そうでなければ 0 である. R(・) 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,g} 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.

3.2.2 グラフの作成

画像からグラフを図3のように作成する. グラフは有向グ ラフであり、画像の各ピクセルに対応したノードと、sink と source 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 と呼び, 各ノードからターミ ナル $(sink(T) \ge souce(S))$ を結ぶエッジを t-link と呼ぶ.



次に,全てのエッジに対して重みを与える.n-linkとt-link のエッジに与える重みを表1に示す. O は物体, B は背景を意 味し, $p \in O, p \in B$ は予め物体もしくは背景のラベルが与え

られたピクセル (seed) のことである. n-link に与えられる重み は、近傍画素との類似度が高いほど大きくなる. t-link につい ては、物体らしさが高いほど物体ターミナルとのエッジに大き な重みが、背景らしさが高いほど背景ターミナルとのエッジに 大きな重みが与えられる. エッジの重みの大きさは、繋がれた ノード間の結びつきが強いことを示している.

表 1 エッジのコスト

AI STONANT						
edge		$\cos t$	for			
n-link	$\{p,q\}$	$B_{\{p,q\}}$	$\{p,q\}\in N$			
		$\lambda \cdot R_p("bkg")$	$p\in P, p\notin O\cup B$			
	$\{p, S\}$	K	$p \in O$			
t-link		0	$p \in B$			
		$\lambda \cdot R_p("obj")$	$p\in P, p\notin O\cup B$			
	$\{p,T\}$	0	$p \in O$			
		K	$p \in B$			

ここで,表中の $R_p("obj")$, $R_p("bkg")$, $B_{\{p,q\}}$,Kはそれ ぞれ以下の式 (10), (11), (12) で定義する.

$$\begin{cases} R_p("obj") = -lnPr(C_p \mid O) \\ R_p("bkg") = -lnPr(C_p \mid B) \end{cases}$$
(10)

$$B_{\{p,q\}} \propto exp\left(-\frac{(I_p - I_q)^2}{2\sigma^2}\right) \cdot \frac{1}{dist(p,q)}$$
(11)

$$K = 1 + \max_{p \in P} \sum_{q:\{p,q\} \in N} B_{\{p,q\}}$$
(12)

ここで、 C_p はピクセル p での RGB 値、 I_p は輝度値である. また, $Pr(C_p \mid O)$, $Pr(C_p \mid B)$ は seed としてラベルが与えら れたもの以外のピクセルに対する物体と背景の尤度であり、物 体 (O) と背景 (B) の色情報 C_p を GMM (Gaussian Mixture Model) に適用することで尤度を推定する. dist(p,q) は近傍と の距離を表している.

3.2.3 グラフのカット

前項で作成されたグラフに対して,最小カットを求める.こ れにより、結びつきの強いエッジの繋がりが残り、結びつきの 弱いエッジがカットされる.式 (13)は、カット C が通る S 側 から T 側へ向かうエッジの重み we の和を表し,この最小化問 題を解く. なお式(8)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である.

$$\mid C \mid = \sum_{e \in C} w_e \tag{13}$$

Min cut/Max flow algorithm を用いて、コスト総和が最小 となるようにグラフをカットすることで、物体と背景のグラフ に分割する.カットの後に、ターミナルSと繋がっているピク セルは物体,同様にターミナル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.

4. 認識とセグメンテーション

本章では, SIFT と Graph Cuts を用いた認識とセグメンテー ションの方法について述べる.提案手法の流れを図4に示す.



図 4 提案システムの流れ

4.1 認 識

まず,認識方法について述べる.認識は,マッチング処理, 投票処理,クラスタリング処理の3段階からなっており,本節 では各処理について順に述べる.

4.1.1 マッチング処理

はじめに,予め45° ずつの角度でモデルとなる各物体を撮影 しておき,そこからSIFT 特徴を抽出し,データベースを作成 しておく.ここで,45°という撮影角度は,5章で述べる実験 により決定した.次に,与えられた入力画像に対してSIFT 特 徴の抽出を行う.得られた特徴に対して,データベース中のモ デルの全特徴点とマッチングを行い,物体部分の対応点を得る. 以下に,具体的なマッチングの流れを示す.

あるモデル画像には *M* 個の特徴点が獲得されているとして, 与えられた入力画像から *N* 個の特徴点が抽出されたとすると, モデル画像と入力画像の特徴点は次のようになる.

$$S_{model} = \{s^m\} \qquad (m = 1, \cdots, M) \tag{14}$$

 $W_{input} = \{w^n\} \qquad (n = 1, \cdots, N) \tag{15}$

$$s^{m} = (s_{1}^{m}, s_{2}^{m}, \cdots, s_{128}^{m})^{T}$$
(16)

$$w^{n} = (w_{1}^{n}, w_{2}^{n}, \cdots, w_{128}^{n})^{T}$$
(17)

モデル画像中の m 番目の特徴点と,入力画像中の n 番目の 特徴点のユークリッド距離が最小となる特徴点 n'を以下の式 により求める.

$$n' = \underset{n \in N}{\arg\min} \sqrt{\sum_{i}^{128} (s_i^m - w_i^n)^2}$$
(18)

この処理を全モデルの全特徴点に対して行うことで,類似度 の高い特徴点を対応点として獲得出来る.

4.1.2 投票処理

前項でマッチングしたモデル画像と入力画像の対応点を用い て,入力画像中の各特徴点から,物体の中心候補点をそれぞれ 求める.この中心候補点を投票していくことで,対象物体が存 在すれば各特徴点から算出した中心候補点は同じ位置に集まる ため,多くの投票が集まればそこに物体が存在していると判定 できる.以下に,その中心候補点の計算法と投票処理について 述べる.

まず,モデル画像中で物体の中心点(基準点)をとる.その 基準点と各特徴点 (x_{model}, y_{model})の位置関係を算出し,特徴 点ごとに基準点からの位置ベクトル ($\Delta x, \Delta y$)を計算しておく (図 5).



図5 位置ベクトルの算出

次に,モデル画像中の特徴点と基準点の位置ベクトルを用いて,その特徴点とマッチングのとれた入力画像中の特徴点に対する中心候補点を求める.画像の左下に原点を取ると,入力画像中の物体の中心候補点(*X*,*Y*)は,各特徴点の座標,スケール,位置ベクトルから次の式で求められる.

ここで, σ_{input,model}, は入力画像及びモデル画像中の特徴 点のスケール, θ_{input,model} はオリエンテーションである.以 上の処理をマッチングした全ての特徴点に対して行い,入力画 像中の中心候補点に投票を行う.この投票作業を行うと,入力 画像中に対象物体が存在するならば,求められる中心候補点は 同じ位置に集まるため,その位置に多くの投票が集まることに なる [9]. 従って,多くの投票が集まればその位置を中心として 対象物体が存在していると認識できる.そこで,投票された候 補点の集合ごとにその得票数を求めるために,次に候補点のク ラスタリングを行う.

4.1.3 クラスタリング処理

投票された中心候補点をクラスタリングし,各クラスタご とに得票数を求める.候補点のクラスタリングにはウォード法 (Ward's method)を用いる.本手法では閾値を設け,クラスタ 間距離が閾値に達したところで処理をやめ,その時のクラスタ をクラスタリング結果として得る.そして,各クラスタにおい て閾値以上の投票が得られれば,その位置を中心として対象物 体が存在すると判定する.これらの閾値については,実験的に 定めた.

4.2 セグメンテーション

本節では,SIFT 特徴を用いた自動セグメンテーションの方 法について述べる.

4.2.1 seed の作成

Graph Cuts によるセグメンテーションのための seed を作成 する.

物体の seed には、モデルとマッチングの取れた SIFT 特徴点 そのものを用いる.但し、マッチングの段階ではミスマッチも 多く、正確に物体上の点が取れていないものが多数存在し、物 体 seed として使うとセグメンテーション時にエラーが大きく なることが懸念される.そこで、セグメンテーションに入る前 に、投票処理の際に認識したクラスタに投票した特徴点のみを 用いることで、seed の選定を行う.表2は、この選定処理前と 選定処理後での物体 seed の精度比較を示している.この数値 は、予め正解の物体領域マスクを手動で作成し、自動で得られ た seed がどれだけ物体マスク上に取れているかを示しており、 選定処理を行うことで高い精度で物体上に seed が取れること が分かる.

表 2	物体	seed	の精度

選定処理前 [%]	選定処理後 [%]
78.4	99.9

この選定処理によって得られる特徴点を物体 seed として用 いる.背景 seed は、この選定された特徴点を用いてモデル画 像をアフィン変換し、その領域の外側全ての領域を用いる.実 際に自動で作成された seed を図 6 に示す.図中の赤い点が物 体 seed,青い領域が背景 seed となっている.





(a) 入力画像

(b) 自動生成された seed 図 6 seed の作成

4.2.2 結果出力

前項で作成した seed を用いて, Graph Cuts により画像のセ グメンテーションを行う.切り出しは,物体が認識されると, 認識された物体全てにおいてそれぞれ個別に seed を自動生成 して行う.そして,セグメンテーションされた画像と認識結果 を合わせて,最終的な結果としてその画像を出力する.

5. 実 験

5.1 実験概要

20 個のモデル物体に対して,100枚のテスト画像を用意し, 認識とセグメンテーションの実験を行った.モデル物体は本 やコップなど日常生活でよく見られる物体で,それぞれ45° ずつの角度から撮影し,1物体につき8枚のモデル画像を用 意した.この撮影角度は Columbia University Image Library (COIL-100)[10]を用いた以下の実験結果に基づき決定した.図 7は,撮影角度を変化させた時のマッチング率と認識率を示し ている.マッチング率は,画像間で対応の取れる特徴点数の割 合で,正面画像(撮影角度0°)の場合を基準としている.撮影 角度が変化すると,マッチング率は早い段階で低下してしまう ものの,認識率は45°までは高い値を保っていることが分かる. これは,投票処理による認識手法により,必ずしも全ての特徴 点がマッチングしなくても物体を認識できるためである.この 実験結果により,モデルの撮影角度を45°ずつに設定した.テ スト画像は,物体が様々なサイズ・角度で写っており,オクルー ジョンも含んでいる.撮影にはWebカメラ「Qcam Pro 9000 (Logicool)」を使用し,画像サイズは 640x480 ピクセルとなっ ている.



以上の実験条件で実験を行い,認識における再現率 (recall) と適合率 (precision)を求めて評価を行う.ここで,再現率と は,検索要求を満たす全対象物体に対して,検索要求を満たす 検索結果の割合であり,全ての正解のうちどれだけカバーでき たかを示す割合である.また,適合率とは,全検索結果に対し て,検索要求を満たす検索結果の割合であり,システムの正解 数を示す割合である.

また,セグメンテーションの精度については,以下のような エラー率を求めて評価を行う.予め,物体領域のマスクデータ を正解データとして用意し,それに対して誤検出率を以下の式 から算出する.

$$\operatorname{error}[\%] = \left(\frac{物体領域の誤検出ピクセル数}{ \pounds ピクセル数} + \frac{背景領域の誤検出ピクセル数}{ \pounds ピクセル数} \right) \times 100 \quad (20)$$

5.2 実験結果

100枚のテスト画像を用いた認識・セグメンテーション実験の結果を以下に示す.まず,認識精度の結果を表3に示す.

表 3 認	識 精 度
再現率 [%]	適合率 [%]
82.1	100

次に, セグメンテーションの精度を示す. (20) 式によってセ グメンテーションのエラー率を算出したところ, 表4のように なった.

表 4 セグメンテーション精度

物体領域エラー [%]	背景領域エラー [%]	全体エラー [%]			
3.73	6.21	9.94			

最後に、セグメンテーション結果の例を図8に示す.



(e) テスト画像 5図 8 セグメンテーション結果

6.考察

認識精度については,再現率と適合率により評価を行い,共 に高い値が得られた.これは,投票処理による認識を行うこと で,オクルージョンが含まれる場合でも,見えている部分にお いて対応が取れさえすれば,そこから基準点へ投票することで 認識できるためである.また,基準点へ投票することで,誤っ てマッチングした特徴点はここで除外されるため,誤認識が起 こりにくいということも挙げられる.一部の認識できなかった ものについては,SIFT によって得られる特徴点がもともと少 ない物体や,光の反射や物体の変形によって特徴量が変化した ためにマッチングが取れなかった物体において,得票数が閾値 に達しなかったこと原因であると考えられる.

セグメンテーション精度については、全体としてエラー率が 9.94% という良い結果となった.しかし、物体によっては SIFT によって取れる特徴が偏っていたために、作成された seed に も偏りが生じ、正しくセグメンテーション出来ないものも見ら れた.これについては、SIFT 以外の特徴量を用いるなどして、 なるべく偏りのない seed を作成する方法を検討していく必要 があると思われる.

全体としては、人間が手動で seed を与えることなく自動で Graph Cuts を行うことでき、局所特徴を用いた認識手法で、 物体領域の詳細な切り出しまで行うことが可能となった.計算 時間については、モデル数が増加するとそれに伴ってマッチン グの計算時間も増加することが考えられるため,マッチング計 算の高速化を考えている.

7. まとめ

本稿では、SIFT と Graph Cuts による物体認識及びセグメ ンテーションの手法について述べた.物体上に得られた SIFT 特徴を,Graph Cuts の物体 seed として用いることで,認識と 同時に物体領域を切り出す手法を提案した.Graph Cuts は従 来,人間が手動で seed を与えなければならなかったが,提案 手法では,認識に使用した SIFT 特徴から自動的に seed を作 成することで,認識とセグメンテーションを自動で行うことが 可能となった.実験では,100枚のテスト画像を用いて認識と セグメンテーションの検証を行い,オクルージョンを含む状況 下においても,対象物体の認識と切り出しができることが確認 できた.今後は,SIFT 特徴があまり取れない物体や,偏りの ある物体に対しても,安定したセグメンテーションができる方 法を検討すると共に,計算時間の短縮化についても検討してい く予定である.

献

文

- D. G. Lowe, "Distinctive image features from scale-invariant keypoints," Journal of Computer Vision, 60, 2, pp.91-110, 2004.
- [2] D. G. Lowe, "Object recognition from local sclae-invariant features," International Conference on Computer Vision, Corfu, Greece, pp.1150-1157, 1999.
- [3] C. Harris and M. Stephens, "A combined corner and edge detector, "Proc. of Fourth Alvey Vision Conference, pp.147-151.
- [4] C. Schmid and P. Mohr, "Local grayvalue invariants for image retrieval," Proc. of IEEE Trans. Pattern Analysis and Machine Intelligence(PAMI), vol.19, no.5, pp.530-534, 2007.
- [5] M. Kass, A. Witkin, and D. Terzopoulos, "Snakes: Active contour models," International Journal of Computer Vision, Vol.1, No.4, pp.321-331, 1988.
- [6] J. A. Sethian, "Level Set Methods and Fast Marching Methods: Evolving Interfaces in Computational Geometry Fluid Mechanics, "Computer Vision, and Materials Science. Cambridge University Press, 1999.
- [7] Y. Boykov, M. P. Jolly, "Interactive graph cuts for optimal boundary & region segmentation of objects in N-D images," IEEE International Conference on Computer Vision and Pattern Recognition, volume 2, pp.731-738, 2004.
- [8] Y. Boykov, V. Kolmogorov, "An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimizatio in Computer Vision," In IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004.
- [9] 高木雅成,藤吉弘亘,"SIFT 特徴量を用いた交通道路標識認識,"画像センシングシンポジウム,LD2-06,2007.
- [10] "Columbia University Image Library (COIL-100)," http://www1.cs.columbia.edu/CAVE//software/softlib/coil-100.php