

# 能動視覚のためのフロー分布の統計を利用した オプティカルフロー推定法

## Optical Flow Estimation for Active Vision Using Flow Spatial Statistics

芳賀起史, 岡谷貴之, 出口光一郎

Takeshi Haga, Takayuki Okatani,  
Koichiro Deguchi

東北大学大学院情報科学研究科

Graduate School of Information Sciences, Tohoku University.

キーワード: オプティカルフロー (optical flow), 能動視覚 (active vision), 事前知識 (prior knowledge)

連絡先: 〒980-8579 宮城県仙台市青葉区荒巻字青葉6-6-01 東北大学大学院  
情報科学研究科 システム情報科学専攻 出口・岡谷研究室

芳賀起史, Tel.: (022)795-7017, Fax.: (022)795-7017, E-mail: haga@fractal.is.tohoku.ac.jp

### 1. はじめに

オプティカルフローとは, 各時刻での画像上の各点でのシーンの見た目の速度を表したベクトル場である. カメラの運動, 撮影対象の運動によって発生し, その大きさは運動の速度と, シーンの奥行きによって決まるため, 画像を用いた空間の認識, カメラ運動の推定に利用できる.

オプティカルフローは, 移動するロボットや車両に搭載されたカメラを用いた画像処理にも応用できる. 運動するカメラで取得した画像から推定したオプティカルフローは, 撮影対象の認識, 追跡のほか, 障害物の検出といった進行方向の状況認識, 相対的な距離の推定などに利用でき, 画像による自律移動体の制御に幅広く利用することが可能である (Fig. 1, 2).

通常のオプティカルフロー推定法には, いくつ




Fig. 1 能動視覚での対象の認識




Fig. 2 自律走行車での画像を用いた進路の検出  
や距離の推定

かの問題点がある，オプティカルフロー推定は画像の明るさの変化にもとづいて行われるため，明るさの変化が小さい領域では誤差が生じやすい．また，局所領域での明るさやオプティカルフローの変化が小さいことを拘束条件として用いるために，物体の境界など変化が大きくなる部分では誤差が生じる．

このような問題点に対しRothらは，学習によってオプティカルフローの事前確率のパラメータを決めるFields-of-Expertsモデルを提案し，フローベクトルの分布を事前知識として導入することによって，精度が向上することを示した<sup>1)</sup>．この手法での拘束条件は，物体の境界などでのオプティカルフローの変化を考慮したモデルから導かれるため，以前の推定法に対して物体の境界での誤差が少なくなる．

自律移動体に取り付けられたカメラでのオプティカルフローを考えると，加えて，推定の際に運動や空間的な事前知識が利用できる．本研究では，Fields-of-Expertsモデルにもとづいた推定法<sup>1)</sup>に，運動の事前知識と自然画像での空間的な事前知識を取り入れたオプティカルフロー推定法を考える．

運動の事前知識としては，カメラの制御に用いた運動の知識を利用することができる．カメラの運動方向が既知の場合，対象が静止している領域に生じるオプティカルフローの方向は運動によって決まるため，画像上での空間分布はカメラの運動方向とは逆向きの方向の要素が多い偏った分布となる．

空間的な事前知識としては，能動カメラから得られる画像の特徴に関する知識を利用することができる．屋外環境における風景を撮影したような画像は一般に自然画像と呼ばれる．ロボットや車両に搭載されたカメラで撮影された自然画像は，画像面と地面が垂直に近い関係で設置されることが多いため，画像の上の領域に空や遠くの景色，下の領域に地面や近くの物体が投影されることが

多くなる．

以上で述べたような，事前知識を利用することによって，能動視覚に特化したオプティカルフロー推定法を実現し，シミュレーション実験によって手法の有効性を検証する．

## 2. 原理

### 2.1 オプティカルフローの推定の原理

明るさに微小な変化が生じた2枚の画像を考える．時刻 $t$ に1枚目の画像の位置 $(x, y)$ に投影されていた点が，時刻 $t + \Delta t$ に2枚目の画像の位置 $(x + \Delta x, y + \Delta y)$ に投影されたとき，点の明るさ $I$ が変化していないと仮定すると，

$$I(x, y, t) = I(x + \Delta x, y + \Delta y, t + \Delta t), \quad (1)$$

と表せる．右辺を1次の項までテイラー展開すると，

$$I(x, y, t) = I(x, y, t) + \frac{\partial I}{\partial x} \Delta x + \frac{\partial I}{\partial y} \Delta y + \frac{\partial I}{\partial t} \Delta t. \quad (2)$$

このとき，水平方向，垂直方向の移動量を $u, v$ ， $\partial I / \partial x = I_x$ ， $\partial I / \partial y = I_y$ ， $\partial I / \partial t = I_t$ とにおいて式を整理すると，ある時刻での位置 $x, y$ の明るさと速度は

$$I_x u + I_y v + I_t = 0, \quad (3)$$

と表せる．式(3)には $u, v$ という2つの未知数がある，これを一意に求めることはできない．オプティカルフロー $u, v$ の推定を行うためには， $u, v$ に対する何らかの拘束条件が必要である．

式(3)に局所領域での明るさの変化は小さいという拘束を取り入れてオプティカルフロー推定を行う方法は，Lucas-Kanadeの方法として知られており，

$$E_{LK}(u, v) = K_\sigma * (I_x u + I_y v + I_t)^2, \quad (4)$$

を最小にする $u, v$ を求めることによって推定を行う．ここで， $K_\sigma$ は，範囲 $\sigma$ に適用される2次元ガ

ウス関数であり，式(4)の畳み込み演算は，近傍領域での明るさの変化が最小となるような $(u, v)$ を求めることを意味するため，この手法はノイズの影響を受けにくい．

また，式(3)にフローベクトルの変化は少ないという拘束を取り入れてオプティカルフロー推定を行う方法は，Horn-Schunckの方法として知られており，

$$E_{\text{HS}}(u, v) = \int_{\Omega} ((I_x u + I_y v + I_t)^2 + \alpha(|\nabla u|^2 + |\nabla v|^2)) dx dy, \quad (5)$$

を最小化することによって推定を行う．ここで $\Omega$ は画像全体の領域， $\alpha$ は近傍とのフローベクトルの変化をどの程度許容するかを調整するための重みを表す．この手法は，各画素ごとに推定を行うため密なフローベクトル場を得ることができる．

Lucas-Kanadeの方法とHorn-Schunckの方法を組み合わせた方法として，Combined Local-Global(CLG)法がある．CLG法は画像の明るさに関して局所的な拘束を使用した式(4)と，画像全体での最小化問題である式(5)を組み合わせたもので，

$$E_{\text{CLG}}(u, v) = \int_{\Omega} (\rho_D(\sqrt{K_{\sigma} * (I_x u + I_y v + I_t)^2}) + \lambda \rho_S(|\nabla u| + |\nabla v|)) dx dy, \quad (6)$$

を最小にする $w$ を求めることによって，オプティカルフローの推定を行う方法である．ここで， $\lambda$ はフローベクトルの変化をどの程度重視するかを決める重みである． $\rho_D, \rho_S$ は，明るさ $I$ についての外れ値の影響を抑えるための関数であり， $\rho(x) = \log(1 + \frac{1}{2}(\frac{x}{\sigma})^2)$ などを用いる<sup>2)</sup>．

二つの拘束式を組み合わせることによって，ノイズの影響を受けにくく，密なフローベクトル場を得ることができる．以降での式の扱いを簡単にするため

$$w = (u, v, 1) \quad (7)$$

$$K_{\sigma}(I) = K_{\sigma} * ((I_x, I_y, I_t)^{\top} (I_x, I_y, I_t)), \quad (8)$$

と表記すると，式(9)は以下のように表せる．

$$E_{\text{CLG}}(w) = \int_{\Omega} (\rho_D(\sqrt{w^{\top} K_{\sigma}(I) w}) + \lambda \rho_S(|\nabla w|)) dw. \quad (9)$$

## 2.2 オプティカルフローの事前確率モデル

CLG法でのオプティカルフロー推定では，式(3)の第2項では，フローベクトルの変化が少ないという拘束条件を用いた．しかし，画像では様にフローベクトルの変化が少ないわけではない．画像上でのフローベクトルの変化を考えると，物体の表面などでは奥行きが一定か，もしくは奥行きの変化が少ない部分がほとんどであるため，多くの領域では変化が少ないが，異なる物体の境界などでは奥行きや運動の違いによってフローベクトルに変化が生じる．画像中の奥行きや運動にはさまざまなものがあるので，多数の画像を用意して一般的な画像でのフローベクトルの変化の分布を調べると，裾の広い分布になることが知られている．

オプティカルフローの分布に注目した方法として，Fields-of-Experts(FoE)モデルを用いたオプティカルフロー推定法がある．この手法は，近傍領域内でのフローベクトルの各要素の分布が裾の広い分布になることを仮定して，正しいフローベクトルが入力されたときの分布のパラメータを学習することによって，事前確率を定めて推定に使用する方法である．

FoEモデルでは，各画素のフローベクトルの確率は，大きさ $m \times m$ の局所領域のフローベクトルによって決まると仮定する．位置 $k$ の画素と，それを中心とする近傍領域のフローベクトルのある方向成分を並べたベクトル $\mathbf{x}_{(k)}$ ，分布を表す関数 $\psi$ を用いて，

$$p(\mathbf{x}) = \frac{1}{Z} \prod_{k=1}^K \psi(\mathbf{x}_{(k)}), \quad (10)$$

と表すことができる．

大きさ  $m \times m$  の近傍領域においてフローベクトルが  $N$  個の 1 次元  $t$  分布の積で表される分布に従うと仮定すると、事前確率を

$$p(\mathbf{x}) = \frac{1}{Z} \prod_{k=1}^K \prod_{i=1}^N \left( 1 + \frac{1}{2} (\mathbf{J}_i^\top \mathbf{x}_{(k)})^2 \right)^{-\alpha_i}, \quad (11)$$

と表すことができる。ここで、 $(\mathbf{x} \in \mathbf{u}, \mathbf{v})$  である。分布のパラメータ  $\mathbf{J}_i, \alpha_i$  は、学習によって決定する。

FoEモデルにおいて、画像を小領域に分けて扱うのはある画素フローベクトルを小領域内の要素のみによって決定されると仮定することによって、入力画像の大きさに依存せず、平行移動に対しても不変なモデルを実現するためである。

分布のパラメータ  $\mathbf{J}_i, \alpha_i$  は式(11)のエネルギー関数

$$\begin{aligned} E_{\text{FoE}}(x) &= -\log p(\mathbf{x}) \\ &= -\sum_{k=1}^K \sum_{i=1}^N \log \left( 1 + \frac{1}{2} (\mathbf{J}_i^\top \mathbf{x}_{(k)})^2 \right) \end{aligned} \quad (12)$$

にもとづいて学習する。

学習はcontrastive divergence法によって行い、

$$\Theta = \Theta + \eta \left( \left\langle \frac{\partial E_{\text{FoE}}}{\partial \Theta} \right\rangle_p - \left\langle \frac{\partial E_{\text{FoE}}}{\partial \Theta} \right\rangle_0 \right), \quad (13)$$

として  $\Theta$  を更新することによって求める。このとき  $\Theta = (\mathbf{J}_i, \alpha_i)$  であり、 $\langle \cdot \rangle_p$  は、 $p$  回目に分布のパラメータ  $\Theta$  にもとづいて発生させた入力値  $\mathbf{x}$  での平均を表す<sup>3)</sup>。  $\eta$  は更新の速さを調節するための重みである。

## 2.3 事前確率モデルに基づくオプティカルフロー推定

学習したパラメータを用いてオプティカルフロー推定を行うために、CLG法の式(9)の第2項を式(12)で置き換える。

$$\begin{aligned} E(\mathbf{w}) &= E_D + \lambda E_{\text{FoE}} \\ &= \int_{\Omega} \rho_D \left( \sqrt{\mathbf{w}^\top K_\sigma(I) \mathbf{w}} \right) \\ &\quad - \lambda \sum_{k=1}^K \sum_{i=1}^N \log \left( 1 + \frac{1}{2} (\mathbf{J}_i^\top \mathbf{w}_{(k)})^2 \right) \end{aligned} \quad (14)$$

拘束を置き換えたことによって単に周囲のフロー成分の変化が少ないという拘束ではなく、周囲のフロー成分の分布によって事前確率が大きくなるような  $\mathbf{w}$  を求めることができる。ここで、 $\lambda$  は学習による項の影響の大きさを調節するための重みである。

実際のオプティカルフロー推定の方法は、式(14)を最小化するのが困難であるため、エネルギー関数の勾配を用いた局所最適化

$$\nabla E \mathbf{w} = 0, \quad (15)$$

によって求める。

式(14)の1項目  $E_D$  の位置  $i$  における勾配は、

$$\frac{\partial}{\partial u_i} E_D(\mathbf{w}) = \tilde{\rho}_D \left( \sqrt{\mathbf{w}_i \mathbf{K}_i \mathbf{w}_i^\top} \right) (\mathbf{K}_{1i} \mathbf{w}_i), \quad (16)$$

$$\frac{\partial}{\partial v_i} E_D(\mathbf{w}) = \tilde{\rho}_D \left( \sqrt{\mathbf{w}_i \mathbf{K}_i \mathbf{w}_i^\top} \right) (\mathbf{K}_{2i} \mathbf{w}_i), \quad (17)$$

ここで  $\tilde{\rho}(x)_D = \rho'(x)_D / x$ 、 $\mathbf{K}_{ji}$  は、位置  $i$  での行列  $\mathbf{K}_\sigma(I)$  の  $j$  行目を取り出したベクトルを表す。

また  $E_{\text{FoE}}(\mathbf{x})$  の各要素の勾配を求め  $\mathbf{x}$  を分離したものの<sup>1)</sup>を

$$\nabla E_{\text{FoE}}(\mathbf{x}) = \mathbf{A}_{\text{FoE}}(\mathbf{x}) \mathbf{x}, \quad (18)$$

と表記する。

式(16)と、式(18)を係数  $\mathbf{w}$  について並べ式(15)へ代入すると、

$$[\mathbf{A}_D + \mathbf{A}_{\text{FoE}}(\mathbf{w})] \mathbf{w} = 0. \quad (19)$$

$\mathbf{A}_D$  の定数項を移項すると、

$$[\tilde{\mathbf{A}}_D + \mathbf{A}_{\text{FoE}}(\mathbf{w})] \mathbf{w} = \mathbf{b}. \quad (20)$$

$\mathbf{w}$  は1組の画像間でのフローのすべての成分を並べたベクトルなので、 $A$  は入力画素数分の行と列をもつ疎行列である。

式(20)は  $A_{\text{FoE}}(\mathbf{w})$  の項に非線形な要素を含むが、適当な初期値  $\mathbf{w}^{(0)}$  から初めて、

$$[\tilde{\mathbf{A}}_D + \mathbf{A}_{\text{FoE}}(\mathbf{w}^{k-1})] \mathbf{w}^k = \mathbf{b}. \quad (21)$$

として、方程式を繰り返し解いて、 $w$ の値を更新していくことによって画像全体のフローベクトルを求める。

### 3. 運動の事前知識と空間分割による学習領域の限定

Fields-of-Expertsモデルを用いたフロー推定で提案されているのは、ランダムなカメラ運動、画像のランダムな領域のフローベクトルをもとに学習を行う方法である。これに対し能動カメラでのオプティカルフロー推定を考えた場合、事前知識としてカメラの運動パラメータが使用できる。また、入力する画像が自然画像であれば、画像の中段から上が遠景で、下が近景といったように領域ごとの距離に特徴があり、フローベクトルの分布が空間的に偏っていることが利用できる可能性がある。

本研究では、学習時にカメラ運動に関する事前知識と画像中の領域に関する事前知識を使用して、入力とするフローベクトルを分類する。また、推定時には、カメラ運動または領域によって使用する事前分布を切り替える。それぞれの事前知識にもとづいた分類がフローベクトルの推定精度にどのように影響するかを示すために、

- 入力画像を撮影したときのカメラ運動と同じ種類のカメラ運動から学習した分布のパラメータを用いて推定を行う。
- 入力画像での領域と同じ領域から学習した分布のパラメータを用いて推定を行う。

という2種類の方法についてそれぞれ実験を行った。運動による種類分けの例をFig. 3, 領域を分ける場合の例をFig. 4に示す。

事前知識から得られる運動方向を利用することによって、学習に利用する運動方向を限定することは、関係のない運動でのフローが学習対象から除外されることにより、特定の運動に特化したパ




Fig. 3 運動によって入力データを分けて学習する場合の分類の例




Fig. 4 領域によって入力データを分けて学習する場合の分類の例

ラメータを決定することにつながり、より確実な推定を実現することができると期待される。また、学習に利用する領域を限定することは自然画像でのフローベクトルの分布の偏りを考慮することにあたり、能動カメラによって得られる画像からの推定を行う場合には有用である。

### 4. 実験

運動ごとに分けて学習を行ったパラメータ、画像を4つの領域に分割してそれぞれの領域ごとに学習を行ったパラメータを用いて、オプティカルフロー推定実験を行った。

推定したオプティカルフローの評価には、フローベクトルの角度誤差<sup>4)</sup>

$$(\text{角度誤差}) = \text{acos}(\mathbf{v}_e \cdot \mathbf{v}_c), \quad (22)$$

の画像全体での平均値を使用した。ここで、 $v_e$ は推定したフローベクトルの要素、 $v_c$ は正しいフロー

ベクトルである． $\mathbf{v}$ は，フローベクトルの水平方向成分 $u$ ，垂直方向成分 $v$ を用いて，

$$\mathbf{v} = \frac{(u, v, 1)^T}{u^2 + v^2 + 1}, \quad (23)$$

と表されるベクトルである．

#### 4.1 学習用データの作成と学習

事前確率に基づくオプティカルフロー推定において，学習に用いるオプティカルフローデータはノイズを含まない正確なものであることが望ましい．また，推定したオプティカルフローの評価を行うために実験用の画像に対して，観測される正しいフローベクトルの方向を得る必要がある．しかし，オプティカルフローは画像上の見た目の移動ベクトルなので，直接計測することは不可能である．

本実験では，3次元空間での物体の配置とカメラ運動を入力として，カメラで撮影した画像と画像上に生じるオプティカルフローを生成するシミュレーション環境を作成し，学習用のオプティカルフローおよび実験用の入力画像を合成することによって得たデータを，正しいオプティカルフローのデータとして使用した．

シミュレーション環境には複数の物体を配置し，背景や他の物体との境界でフローの変化が生じるようにした．物体の面は画像面に対して傾けて配置して奥行き異なるフローが生じるようにした (Fig.5) ．




Fig. 5 生成したフローベクトルの例

大きさ $240 \times 240$ ピクセルのフローベクトル場30フレームから，大きさ $3 \times 3$ ピクセルの小領域をラ

ンダムに6400個取り出して学習の入力画像とした．フローの水平方向成分，垂直方向成分に対してそれぞれに対して8個のパラメータを式(13)の学習により決定した．反復回数は2000回，更新時の重みは $\eta = 0.001$ とした．

#### 4.2 運動方向によって学習データを分ける場合

運動ごとに分けてパラメータの学習を行いオプティカルフローを推定する実験を行った．実験には，空間的に特徴のあるカメラ運動として(1)画像面に平行な方向への並進，(2)カメラの光軸方向への前進，(3)(1)と(2)をランダムに混ぜて行う運動の3パターンを扱うこととした．

それぞれの運動パターンから生じるフローベクトルについて，(1)の運動は画像面方向への運動なので一定の方向を向いたフローベクトルが発生し，(2)の運動は画像面に垂直な方向への運動なので運動によって発生するフローベクトルは放射状で一定の変化を持つという特徴がある．

オプティカルフロー推定は(1)と(2)の運動から生じるフローベクトルの特徴を考慮して，左方向への並進，前進の2パターンの画像系列について行った．推定する画像列のフレーム数は10フレーム，画像サイズは $40 \times 40$ ピクセルである．

推定には式(21)を用い，推定時の重みは $\lambda = 0.01$ ，方程式の反復回数は10回に固定した．

推定したオプティカルフローの一例をFig. 6，Fig. 9，対応する真値をFig. 7，Fig. 10，画像系列全体での角度誤差をTable 1，Table 2に示す．

Table 1 学習データごとの角度誤差(左並進)

学習データ	平均角度誤差	標準偏差
(1)横移動	5.734°	1.077°
(2)前進	5.919°	1.008°
(3)ランダム	5.901°	1.013°




Fig. 6 左方向並進の画像での推定値 Fig. 7 左方向並進の画像の真値

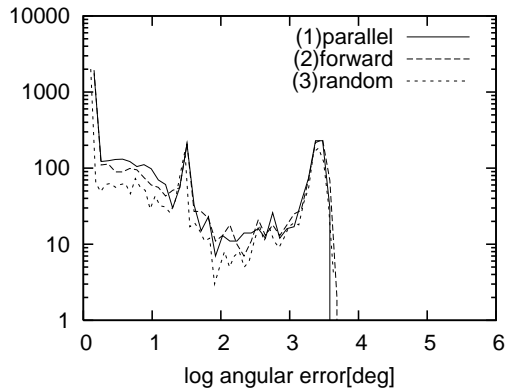


Fig. 8 角度誤差のヒストグラム(左並進)




Fig. 9 前進画像での推定値 Fig. 10 前進画像での真値

Table 2 運動ごとに分けて学習したときの角度誤差(前進)

学習データ	平均角度誤差	標準偏差
(1)横移動	1.803°	0.525°
(2)前進	1.668°	0.288°
(3)ランダム	1.909°	0.667°

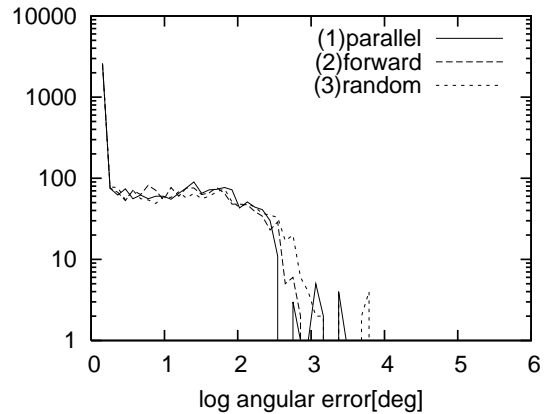


Fig. 11 角度誤差のヒストグラム(前進)

推定結果を比較すると、カメラの運動方向と同じ方向のフローから学習した分布を用いて推定したフローが角度誤差が少ない。これは、学習に使用した運動から得られるフローベクトルの空間分布と、推定時の運動から得られるフローベクトルの空間分布が最も近いと考えられる。

#### 4.3 領域ごとにフローベクトルを学習した場合

画像を分割し、分割した領域ごとにパラメータの学習を行いオプティカルフローを推定する実験を行った。この実験では、屋外で撮影した自然画像のように、画像の中央より上と下の部分でフローの分布が大きく異なる状況を再現するため、学習の入力画像にはFig. 5の左の図のように、画像の中央よりやや上の部分まで近くに物体があるようなシーンを用いた。画像の領域をを4等分し、各領域について個別に分布のパラメータを学習した。

入力画像にはFig. 12のシーンにおいてカメラが右方向に並進したときの画像系列を使用した。学習時の条件、推定時の反復回数は4.2の実験と同じである。学習に使用する小領域は並進と前進がランダムに入った入力画像のランダムな位置から取り出した。

学習に使用した領域ごとに、分布のパラメータ




Fig. 12 実験に使用したシーン

を切り替えて推定を行った。比較対象として、4.2の実験で使用した、ランダムな運動から学習した学習データを使用して、同じ入力画像からオプティカルフロー推定を行い角度誤差の変化を調べた。画像系列全体での角度誤差をTable 3に示す。

Table 3 領域ごとにパラメータを切り替えて学習した場合と切り替えずに学習した場合の角度誤差

	平均角度誤差	標準偏差
分割なし	2.758°	0.6156°
領域分割	2.119°	0.7496°

結果を見ると、角度誤差が減少しているのがわかる。画像上でのフローベクトルの空間分布に注目して画像を領域分割してそれぞれの領域に近い分布から学習したパラメータを使用して推定することによってフローの角度誤差が減少したと考えられる。

## 5. おわりに

学習によってフローベクトルの事前分布を定めるFields-of-Expertsモデルにもとづくオプティカルフロー推定法において、運動ごと、領域ごとに分けて事前分布のパラメータを求めることによってオプティカルフローの角度誤差が減少することが確認できた。

運動については、フローの空間分布に特徴のある運動を選んで比較実験を行ったが、入力画像が任意のカメラ運動によって撮影された場合、事前

知識とする運動をどのように選択するかが重要になってくると考えられる。限られた種類の学習データを切り替えて任意のカメラ運動に対応できるような方法を実現する必要がある。また、画像の分割を行う実験では、単純なシーンを使用し、単に画像を4等分することによって領域ごとにフローを学習していた。しかし、自然画像での応用を考えた場合、領域を分割して学習することの目的は、対象の奥行きや運動によって事前分布を切り替えて推定を行うことである。シーンに応じて分割する領域を変更するような仕組みを考えることも今後の課題である。

## 参考文献

- 1) Stefan Roth and Michael J. Black : On the Spatial Statistics of Optical Flow, ICCV '05: Proceedings of the Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1, 2005
- 2) Bruhn, A. and Weickert, J. and Schnörr, C. : Lucas/Kanade Meets Horn/Schunck: Combining Local and Global Optic Flow Methods, International Journal of Computer Vision, 61-3, 211/231, 2005
- 3) Max Welling, Geoffrey E. Hinton, Simon Osindero : Learning Sparse Topographic Representations with Products of Student-t Distributions, Advances in Neural Information Processing Systems, 15, 1359/1366, 2003
- 4) Barron, J.L., Fleet, D.J., and Beauchemin, S. : Performance of optical flow techniques, International Journal of Computer Vision, 12-1, 43/77, 1994