

2次元サブピクセル同時推定法を拡張した 画像変形 N パラメータ同時推定法

清水 雅夫, 矢野 高宏, 奥富 正敏

東京工業大学 大学院理工学研究科 機械制御システム専攻
東京都目黒区大岡山 2-12-1

{mas, tyano}@ok.ctrl.titech.ac.jp, mxo@ctrl.titech.ac.jp

概要 本論文では, 領域ベースマッチングとサブピクセル推定を拡張して, 画像変形を表す N パラメータを同時かつ高精度に推定する手法を提案する. 多くの画像処理では, 画像間の変位を得るために領域ベースマッチングと類似度値を補間することによるサブピクセル変位推定手法が用いられている. この手法は, わずかな計算量増加に対して効果が大きい, 平行移動以外の画像変形パラメータ推定には対応できなかった.

提案手法は, 実際の N 次元パラメータ空間における画像間の類似度モデルに基づいている. N 次元パラメータ空間において離散的な位置で得られた画像間の類似度値を利用して, 離散分解能よりも遙かに高分解能に類似度最大位置を推定できる. このため, パラメータ最適化などの繰り返し計算によらない直接的な計算によって, 高精度に変形パラメータを推定できる. 合成画像と実画像を用いた実験を行い, 提案手法の効果を確認した.

Precise Simultaneous Estimation of Deformation N-Parameters Extended from Two-Dimensional Simultaneous Estimation

Masao SHIMIZU, Takahiro YANO and Masatoshi OKUTOMI

Graduate School of Science and Engineering, Tokyo Institute of Technology,
2-12-1, O-okayama, Meguro-ku, Tokyo, 152-8550, Japan

Abstract This paper presents a new method to obtain simultaneously precise N parameters of image deformation with non-iterative calculation by extending area-based matching and sub-pixel estimation. Although area-based matching and similarity interpolation for sub-pixel displacement estimation are commonly used in many areas as a fundamental procedure, they are bound to simple translation.

The proposed method is based on a practical similarity model in N-dimensional parameter space. Using similarity measures obtained at discrete positions in the parameter space, our method provides a highly accurate maximum position of similarity in sub-sampling resolution; that position corresponds to image deformation parameters. Experimental results using both synthetic and real images demonstrate that our method can estimate parameters more accurately than previous methods.

1 まえがき

ステレオ画像処理 [5] をはじめとして、コンピュータビジョン [2]、ターゲットトラッキング [4][6]、画像計測 [3]、マシンビジョン、リモートセンシング、画像レジストレーション [1]、時系列画像解析、複数画像からの超解像処理 [7] などの多くの画像処理では、画像間変位を精密に推定することが求められる。

多くの用途では、画像から切り出した 2 次元小領域に対する対応位置を、他方の画像中から 2 次元的に探索する処理を行っている。サブピクセル精度での対応位置を得るアルゴリズムは、古くから数多く提案されている [2] が、大きく分けると、画像補間手法 [11]、類似度補間手法、濃度こう配法に分類できる [1]。このとき、処理の容易さから領域ベースマッチングと類似度補間手法の組み合わせが多く利用されている。この手法は、注目領域の形状やサイズに制限がなく [10]、繰り返し計算を必要としない。

しかし、アプリケーションによっては、さらに自由度の高い、アフィン変形や射影変形における画像変形パラメータを推定する必要がある [8]。たとえば、異なる時間に異なる条件で撮影した画像間の位置あわせ、異なる条件で撮影した複数画像を使った 3 次元情報再構築、移動カメラで撮影した時系列画像を用いた超解像処理、イメージモザイクなどである。また、画像間の対応を射影変換で表現するためには、撮影した画像は次のいずれかの条件を満たす必要がある。(a) 任意の距離にある平面を撮影している、(b) 任意の距離にある 3 次元物体を撮影しているが、カメラの移動が光学中心回りの回転に限られる、(c) 十分に遠方の物体を撮影している。

従来、このような画像変形パラメータを推定するためには、(1) 画像を変形しながら繰り返し計算によってパラメータ最適化を行う、(2) 平行移動だけに限定した画像内小領域間の対応から画像全体の变形パラメータを推定する、(3) 特徴点の対応から変形パラメータを推定する、などの方法が利用されていた。しかし、(1) 計算時間の見積もりが困難である、(2) 変形が大きいつきに結果が不正確になる、(3) 特徴点抽出とその対応付けの精度に依存する、などの問題があった。

本論文では、領域ベースマッチングの柔軟性と少ない計算量に着目し、類似度補間手法を拡張した画像間変形を表す多パラメータ高精度同時推定手法を提案する。提案手法は、実際的な N 次元パラメータ空間における画像間の類似度モデルに基づいている。N 次元パラメータ空間において離散的な位置で得られた画像間の類似度値を利用して、離散分解能よりも遙かに高分解能に類似度最大位置を推定できる。このため、パラメータ最適化などの繰り返し計算によらない直接的な計算によって、高精度に変形パラメータを推定できる。また、既に提案しているサブピクセル推定誤差低減手法 (EEC; Estimation Error Cancel method)[9] と組み合わせることや、類似度評価関数とフィッティング関数との組合せを選択する

[12] ことで、より高精度な多パラメータ同時推定が可能になる。

本論文は、以下のように構成する。2 章では、従来手法による画像変形パラメータ推定手法について述べる。3 章では、2 パラメータ同時推定法 [14] を説明する。この説明は、N パラメータ同時推定法に対する理解の助けとなる。4 章では、提案手法である、N パラメータ同時推定法を提案する。5 章では、合成画像と実画像を使った実験結果によって、提案手法の効果を示す。

2 従来の領域ベースマッチングによる変形パラメータ推定

2.1 2 パラメータ推定

多くの場合、類似度補間手法を用いてサブピクセル推定を行うときには、水平方向と垂直方向を独立と仮定して、各方向を別々に推定していた。例えば、図 1 に示すように、類似度評価値 $R(-1,0)$ 、 $R(0,0)$ 、 $R(1,0)$ (図 1 の □) を使い、次式によって \hat{d}_s (図 1 の ●) を推定した。

$$\hat{d}_s = \frac{R(-1,0) - R(1,0)}{2R(-1,0) - 4R(0,0) + 2R(1,0)} \quad (1)$$




図 1. 従来の 2 パラメータ推定の問題点。

この例では、真の画像間変位は (d_s, d_t) なので (図 1 の ▲)、式 (1) が直線 $t = 0$ 上の類似度最大位置 (図 1 の ●) を正しく推定するとしても、この結果には大きな推定誤差を含む。つまり、次の条件の全てが真のときには、水平方向推定誤差が発生して、 $\hat{d}_s - d_s \neq 0$ となることは明らかである。

- 垂直方向変位 $d_t \neq 0$ 。
- 2 次元類似度が異方性を持つ。
- 異方性を持つ 2 次元類似度の回転角度 $\theta_g \neq 0, \pi/2$ 。

多くの画像がこの条件に当てはまる。また、垂直方向に関しても同様である。

2.2 小領域間の対応を利用した多パラメータ推定

画像間の変形が平行移動だけでは表現できないとき、より高自由度な画像間の変形パラメータを推定する必要がある。時系列画像における隣接フレーム

画像間など、大きな変形がないときには、画像を小領域に分割し、平行移動に限定した各小領域間の対応を求め、対応位置の分布から画像全体の变形パラメータを最小二乗の意味で推定することができる [13].

小領域への分割は、単純に画像全体を分割することもできるが、特徴がある領域を採用することもできる。得られた対応位置に対して、変位量や变形パラメータの大きさをキーに、LMedS などの手法を使って誤対応の影響を低減することができる。画像全体の变形モデルを想定した上で、対応位置の分布から、最小二乗法を使って画像全体の变形パラメータを推定する。

このようなパラメータ推定では、画像の局所的な平行移動を仮定しているため、画像全体の变形が大きときには不正確な推定結果になる。

2.3 多パラメータ最適化による探索

画像間の变形を表す N パラメータの推定は、 N 次元パラメータ空間における N 次元評価関数の最小位置 (または最大位置。以後簡易的に「最小」と表す) を探索する問題と考えることができる。

$I_1(u, v)$ をテンプレート画像、 $I_2(u, v)$ を入力画像とすると、画像变形パラメータベクトル \mathbf{s} に対する画像間非類似度 $R_{SSD}(\mathbf{s})$ を、たとえば次のように計算する。

$$R_{SSD}(\mathbf{s}) = \sum_{(u,v) \in W} \left(I_1(u, v) - \tilde{I}_2(u, v, \mathbf{s}) \right)^2 \quad (2)$$


ただし、 $\tilde{I}_2(u, v, \mathbf{s})$ は、画像变形パラメータベクトル \mathbf{s} によって入力画像を变形したときの、位置 (u, v) における画像 $I_2(u, v)$ の補間画像を表す。

初期推定パラメータベクトル $\mathbf{s}^{<0>}$ に対して、Newton-Raphson 法や Steepest (Gradient) Descent 法 (最急降下法)、Levenberg-Marquadt 法などの数値的解法を用いて、式 (2) を最小化する方向に \mathbf{s} を逐次更新する。初期推定パラメータベクトル $\mathbf{s}^{<0>}$ は、前節で述べた推定や、平行移動だけに限定した变形パラメータを利用する。

このような探索問題では、初期値が適切でないと正しい結果が得られないことがある。また、繰り返し計算を利用するため計算時間の見積りが困難である。このため、アルゴリズムを実装したハードウェアシステムの総合応答時間を正確に見積もることができず、実時間処理の障害となる。繰り返し計算の各段階で画像を補間する必要があるが、この演算量が多いために計算コストが大きい。

3 2パラメータ同時推定法

本章では、画像間の变形を平行移動に限定した 2 パラメータ同時推定法を説明する。2 パラメータ同時推定法は、画像間の類似度モデルに基づいた手法である。最初に、この類似度モデルを説明する。



(a) Dissimilarity in continuous and (b) in discrete domain

図 2. 連続領域類似度と離散領域類似度。

2 画像間の非類似度として、次の SSD を考える。

$$R_{SSD}(s, t) = \sum_{(u,v) \in W} (I_1(u, v) - I_2(u-s, v-t))^2 \quad (3)$$

この類似度を表す 2 次元モデルとして、次の 2 次元ガウス関数を考える。

$$R_g(s, t) = \text{Gauss}((s - d_s) \cos(\theta_g) + (t - d_t) \sin(\theta_g), \sigma) \times \text{Gauss}(-(s - d_s) \sin(\theta_g) + (t - d_t) \cos(\theta_g), k\sigma) \quad (4)$$

$$\text{Gauss}(x, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}}$$

ただし、 (d_s, d_t) は画像間のサブピクセル変位 ($-0.5 \leq d_s \leq +0.5$, $-0.5 \leq d_t \leq +0.5$), σ はガウス関数の標準偏差、 k は異方性係数 ($k > 0$), θ_g は回転角度である。 $0 \leq \theta_g \leq \pi/2$ の範囲を考慮する。この類似度の例を、図 2 に示す。この類似度モデルは、数種類の画像モデルと多くの実画像の実験結果に基づき、画像間の類似度を的確にモデル化していることを確認している。

2 パラメータ同時推定法の目的は、離散化単位 (画素単位) で得られた類似度値を使って、類似度最大位置、すなわち 2 次元サブピクセル変位を高精度に推定することである。このときに、提案手法では式 (4) で表す 2 次元類似度モデルのパラメータ σ , k , θ_g を推定することなく、直接画像間変位 (d_s, d_t) を高精度に推定することができる。

この 2 次元サブピクセル変位を推定するために、水平軸に対して平行な複数の直線上で、画像間の 2 次元類似度値が最大になるサブピクセル位置を求め、それらのサブピクセル位置を最も近似する直線 (水平極値線 HEL) と、垂直軸に対しても同様に垂直極値線 VEL を求め、HEL と VEL の交点を計算することで、2 次元サブピクセル変位を得ることができる。

最初に、離散的に得られている類似度値を使って、HEL を求める。図 3(a) で、直線 $t = 0$ 上での最大類似度を与える位置を $(\hat{d}_{s(t=0)}, 0)$, 変位位置 (s, t) での類似度を $R(s, t)$ とすると、

$$\hat{d}_{s(t=0)} = \frac{R(-1, 0) - R(1, 0)}{2R(-1, 0) - 4R(0, 0) + 2R(1, 0)} \quad (5)$$




図 3. HEL の推定 (a) と, VEL の推定 (b).

同様に, 直線 $t = -1$ 上と直線 $t = 1$ 上での最大類似度を与える位置を, それぞれ $(\hat{d}_{s(t=-1)}, -1)$, $(\hat{d}_{s(t=1)}, 1)$ とすると, それぞれ式 (5) と同様を求めることができる. このとき, 図 3 に示す ± 3 の範囲の類似度を考慮している. これら 3 点の類似度最大位置を最も良く近似する直線が HEL である. 画像パターンや画像に含まれるノイズや画像間の相違などのために, これら 3 点は直線上にない可能性があるため, 最小二乗で近似直線を次のように求める.

$$\begin{aligned} s &= at + b & (6) \\ a &= \frac{1}{2} (\hat{d}_{s(t=1)} - \hat{d}_{s(t=-1)}) \\ b &= \frac{1}{3} (\hat{d}_{s(t=1)} + \hat{d}_{s(t=0)} + \hat{d}_{s(t=-1)}) \end{aligned}$$

同様に, 離散化単位で得られた類似度値を使って, 図 3(b) に示すように VEL を求める.

$$\begin{aligned} t &= As + B & (7) \\ A &= \frac{1}{2} (\hat{d}_{t(s=1)} - \hat{d}_{t(s=-1)}) \\ B &= \frac{1}{3} (\hat{d}_{t(s=1)} + \hat{d}_{t(s=0)} + \hat{d}_{t(s=-1)}) \end{aligned}$$

HEL と VEL の交点, すなわち式 (6), (7) の交点, が, 類似度最大位置 $(\tilde{d}_s, \tilde{d}_t)$ である.

$$\begin{aligned} \tilde{d}_s &= \frac{aB + b}{1 - aA} \\ \tilde{d}_t &= \frac{Ab + B}{1 - aA} & (8) \end{aligned}$$

2 パラメータ同時推定法は, 2 次元パラメータ空間において 2 本の 2 次元超平面 (2 次元空間における直線) を求め, これらの交点を得ることで 2 パラメータを同時に推定する手法と考えることができる. この考え方は, このまま N パラメータに拡張することができる.

4 N パラメータ同時推定法

本章では, N 次元パラメータ空間における画像間類似度を, ガウス関数積の形で表したモデルを使って手法の原理を説明した後, 離散的に得られた画像間類似度を使った実装方法を説明する.

画像間の平行移動に限定したマッチングでは, 画素 (ピクセル) 単位において得られた類似度評価値を使って, 画素単位以上の分解能, すなわちサブピクセル変位を推定した. 提案手法は, サンプリンググリッド (以下 SG と表記する) において離散的に得られた画像間類似度評価値を使って, SG 単位以上の分解能で類似度評価値最大位置を推定する手法である. このため, 提案手法は, サブ SG パラメータを高精度に推定する手法と考えることができる.

4.1 類似度モデルと原理

s_1 から s_N までの N 個のパラメータによって類似度値が決定するときに, 類似度値をガウス関数の N 個の乗算として表現する.

$$R_{gn}(\mathbf{s}, \mathbf{R}, \mathbf{k}, \sigma) = \mathbf{R} \prod_{i=1}^N \text{Gauss}(s_i - d_i, k_i \sigma) \quad (9)$$

ただし, \mathbf{s} は N 次元類似度空間における座標を表す N 次元ベクトル, $\mathbf{d} = (d_1, d_2, \dots, d_N)$ は画像間変形を表す N 次元ベクトル, \mathbf{R} は N 次元空間での回転を表す行列, \mathbf{k} はガウス関数の異方性を表す N 次元ベクトル ($k_1 = 1, k_i > 0$) である.

このとき, 式 (9) の N 次元類似度モデルを $s_i (i = 1, 2, \dots, N)$ で偏微分して 0 とおくことで, N 個の N 次元関係式得ることができる.

$$\frac{\partial}{\partial s_i} R_{gn}(\mathbf{s}, \mathbf{R}, \mathbf{k}, \sigma) = 0 \quad (10)$$

これらの関係式を連立させて解くことで, N 次元類似度のサブ SG 推定値を得ることができる. N 次元類似度モデルは, 必ずしも式 (9) のガウス関数積モデルで正確に近似できるとは限らない. このときには, 式 (10) は超平面ではなく曲面になる. しかし, 次節の実装方法で示すように, 十分な拘束条件を設定することで, 画像に含まれるノイズなどの影響を受けにくい, 超平面を正確に推定することができる.

4.2 実装

本節では, N パラメータのサブ SG 同時推定を実際に行う具体的な方法を説明する. サブ SG 同時推定を行うときに, 前提として SG での類似度最大位置がわかっている必要がある. この位置は, たとえば画像内小領域間の対応を利用して SG 単位初期位置 $\mathbf{r} = (r_1, r_2, \dots, r_N)^T$ として求めることができる. このとき, SG 単位初期位置には誤差を含むが, このことに関しては実験結果で述べる.

s_i パラメータ軸と平行な直線上の類似度値の組 $R(\mathbf{r} + \mathbf{c}_1(i, -1) + \mathbf{c}_2(i, j))$, $R(\mathbf{r} + \mathbf{c}_1(i, 0) + \mathbf{c}_2(i, j))$, $R(\mathbf{r} + \mathbf{c}_1(i, +1) + \mathbf{c}_2(i, j))$ を使って, パラボラフィッティングによってサブ SG 推定した m 個の位置, $\mathbf{c}_1(i, 1)p_i(\mathbf{c}_2(i, j)) + \mathbf{c}_2(i, j) (j = 1, 2, \dots, m)$ は, ある N 次元超平面 Π_i で近似することができる. この超平面 Π_i 上では, 類似度値 R をパラメータ $s_i (i =$




図 4. パラメータ s_1 に関する最小値を通る平面 Π_i

1, 2, \dots, N) について偏微分した結果が 0 になる。ただし,

$$\begin{aligned} p_i(\mathbf{c}_2(i, j)) &= \frac{\rho(-1) - \rho(+1)}{2\rho(-1) - 4\rho(0) + 2\rho(+1)} \quad (11) \\ \rho(-1) &= R(\mathbf{r} + \mathbf{c}_1(i, -1) + \mathbf{c}_2(i, j)) \\ \rho(0) &= R(\mathbf{r} + \mathbf{c}_1(i, 0) + \mathbf{c}_2(i, j)) \\ \rho(+1) &= R(\mathbf{r} + \mathbf{c}_1(i, +1) + \mathbf{c}_2(i, j)) \end{aligned}$$

である (図 4 参照)。

ここで, $\mathbf{c}_1(i, \kappa)$ は, i 番目の要素だけが値 κ (κ のとりうる値は限定しないが, ここでは $\kappa = -1, 0, +1$ を考える) で, 他の要素は全て値 0 であるような N 次元ベクトルである。たとえば, $\mathbf{c}_1(3, 1) = (0, 0, 1, 0, \dots, 0)^\top$ である。

また, $\mathbf{c}_2(i, j)$ は, i 番目の要素が 0 で, 他の各要素は, $-1, 0, 1$ のいずれかの値をとる N 次元ベクトルの中から, 次の条件を満たすベクトルを取り出して並べたベクトルの j 番目 ($j = 1, 2, \dots, m$) である。

$$\sum_{k=1}^N |c_2(i, j)_k| \leq 1 \quad (12)$$

ただし, $c_2(i, j)_k$ は, N 次元ベクトル $\mathbf{c}_2(i, j)$ の k 番目の要素を表す。式 (12) の条件を使うと, $m = 2(N-1) + 1$ となる。

これらの m 個の位置, $\mathbf{c}_1(i, 1)p_i(\mathbf{c}_2(i, j)) + \mathbf{c}_2(i, j)$ は, 超平面 Π_i 上に存在するか, 少なくとも最小二乗の意味で超平面 Π_i を近似する。超平面 Π_i の式を, 次のように表現する。

$$a_{i1}s_1 + a_{i2}s_2 + \dots + a_{iN}s_N + a_{iN+1} = 0 \quad (13)$$

このとき, 次の関係が得られる。

$$\mathbf{M}_i \mathbf{a}_i = 0 \quad (14)$$

$$\begin{aligned} \mathbf{M}_i &= \begin{bmatrix} (\mathbf{c}_1(i, 1)p_i(\mathbf{c}_2(i, 1)) + \mathbf{c}_2(i, 1))^\top 1 \\ (\mathbf{c}_1(i, 1)p_i(\mathbf{c}_2(i, 2)) + \mathbf{c}_2(i, 2))^\top 1 \\ \vdots \\ (\mathbf{c}_1(i, 1)p_i(\mathbf{c}_2(i, m)) + \mathbf{c}_2(i, m))^\top 1 \end{bmatrix} \\ \mathbf{a}_i &= [a_{i1} \ a_{i2} \ \dots \ a_{iN} \ a_{iN+1}]^\top \end{aligned}$$

ただし, \mathbf{M}_i は, m 行 $N+1$ 列の行列, \mathbf{a}_i は要素数 $N+1$ のベクトルである。超平面 Π_i を表す係数 \mathbf{a}_i は, $\mathbf{M}_i^\top \mathbf{M}_i$ の最小固有値に対応する固有ベクトルとして求めることができる。

このようにして求めた N 個の超平面 Π_i の交点として, N パラメータに対するサブ SG 推定値を得ることができる。この交点は, 次のように求めることができる。

$$\begin{bmatrix} \hat{d}_1 \\ \hat{d}_2 \\ \vdots \\ \hat{d}_N \end{bmatrix} = - \begin{bmatrix} a_{11} & \dots & a_{1N} \\ a_{21} & \dots & a_{2N} \\ \vdots & & \vdots \\ a_{N1} & \dots & a_{NN} \end{bmatrix}^{-1} \begin{bmatrix} a_{1N+1} \\ a_{2N+1} \\ \vdots \\ a_{NN+1} \end{bmatrix} \quad (15)$$

4.3 推定誤差低減手法との組合せ

式 (11) では, 3 位置の類似度値を使ってパラボラフィッティングによってサブピクセル位置を推定している。このときに発生する推定誤差は, 既に提案した推定誤差低減手法によってキャンセルすることができる [9]。これらの文献ではサブピクセルに関する手法を述べているが, ここではサブ SG に注目している。単位は [画素] ではなく [SG] となる。また, 本論文の説明では, SSD 類似度に対してパラボラフィッティングを使用したが, SAD 類似度を使うときには等角直線フィッティングを利用した方が推定精度が高くなる [12]。

推定誤差低減手法は, 次のような推定誤差の性質を利用している。

- (1) SG 周期,
- (2) 真の入力変位が 0 の位置に対して点対称な誤差,

- (3) 真の入力変位 $(0, +0.5)$ と $(-0.5, 0)$ [SG] の範囲で $+0.25$ と -0.25 [SG] を中心としてほぼ対称。

この性質から, 0.5 [SG] 移動したサブ SG 推定結果があれば, 通常の推定結果との平均をとることで, サブ SG 推定誤差をキャンセルすることができる。この性質から, 0.5 [SG] 移動したサブ SG 推定結果があれば, 通常の推定結果との平均をとることで, サブ SG 推定誤差をキャンセルすることができる。

そこで, 0.5 [SG] 移動した補間画像を作り, この補間画像を用いて類似度計算とサブ SG 推定をする。この推定結果は, 通常の推定結果と 0.5 [SG] ずれた結果になるが, 前述の性質によって, 逆符号でほぼ同じ大きさの推定誤差を含んでいる。2 つの推定結果を使えば, 推定誤差を効果的にキャンセルすることができる。

4.4 最適 SG 間隔の選定

画像間の平行移動パラメータをマッチングによって推定する場合には、画像のサンプリング間隔 (1[画素]) ごとに計算できる類似度を利用した。このため、類似度は画素間隔で得られ、画素間隔以上の分解能の平行移動量を推定するためには、サブ画素 (サブピクセル) 推定を行う必要があった。

画像間の多次元の変形パラメータを推定する場合、提案手法では基本的にテンプレートを変形させてから領域ベースマッチングを行う。このとき、テンプレートを変形する各パラメータは任意に設定できるので、パラメータの変更間隔 (SG) が大きいほど計算コスト的に有利になる。しかし、パラメータ変更間隔を大きくしすぎると、

(1) サブ SG 推定を行うときのパラボラ近似誤差が大きくなる、

(2) SG で探索するとき類似度最大位置を見逃す恐れがある、

などの問題がある。また、パラメータ変更間隔を小さくしすぎると、探索に要する計算時間が増大するだけでなく、パラボラ近似によるサブ SG 推定において画像に含まれるノイズなどの影響でかえってサブ SG 推定が不安定になる可能性がある。

このため、何らかの基準に基づくパラメータ変更間隔 (SG) を設定する必要があるが、提案手法では、注目領域内の平均変形量が 1[画素] に対応する SG を利用する。

線形な画像変形 \mathbf{P} は、 N 次元のパラメータベクトル $\mathbf{p} = (p_1, p_2, \dots, p_N)$ によって画像上の位置 \mathbf{x} を \mathbf{y} に変換するとする。ただし、 \mathbf{x} は、線形な画像変形 \mathbf{P} に対して画像上の位置を表す適切な表現ベクトルである。

$$\mathbf{y} = \mathbf{P}(\mathbf{p}; \mathbf{x}) \quad (16)$$

同じ位置への変形を表すパラメータを $\mathbf{o} = (0, 0, \dots, 0)$ とする。

$$\mathbf{x} = \mathbf{P}(\mathbf{o}; \mathbf{x}) \quad (17)$$

今、 \mathbf{o} 中の i 番目の要素だけが Δ_i であるようなパラメータベクトル $\mathbf{c}_1(i, \Delta_i)$ による変形を考える。この変形は、 \mathbf{o} からの変化と考えられるので、次のように表すことができる。

$$\begin{aligned} \mathbf{x} + \mathbf{D}_i(\mathbf{x}) &= \mathbf{P}(\mathbf{c}_1(i, \Delta_i); \mathbf{x}) \\ \mathbf{D}_i(\mathbf{x}) &= \mathbf{P}(\mathbf{c}_1(i, \Delta_i); \mathbf{x}) - \mathbf{P}(\mathbf{o}; \mathbf{x}) \end{aligned} \quad (18)$$

ただし、 $\mathbf{D}_i(\mathbf{x})$ は、 Δ_i による \mathbf{x} の変位ベクトルである。

注目領域 W 内の変位ベクトルの大きさ $|\mathbf{D}_i(\mathbf{x})|$ の平均を考え、この平均が 1[画素] になるような Δ_i を U_i と表すことにする。

$$\frac{\sum_{\mathbf{x} \in W} |\mathbf{P}(\mathbf{c}_1(i, U_i); \mathbf{x}) - \mathbf{P}(\mathbf{o}; \mathbf{x})|}{\sum_{\mathbf{x} \in W} 1} = 1 \quad (19)$$




図 5. 合成画像. (a) 先頭フレーム, (b) 最終フレーム.




図 6. 正解パラメータ

具体的な変形 \mathbf{P} と、それに対する U_i については、次節で述べる。

5 実験結果

5.1 合成画像を用いた 8 パラメータ同時推定

図 5 に示す合成画像を用いて、ホモグラフィー行列 \mathbf{H} のパラメータ推定実験を行った。2 平面間の射影変換を表すホモグラフィー行列は、スケールに対する任意性を持つ 3×3 の行列で、8 つのパラメータで変換が決定する。

合成画像は、乱数で選択したサイズと扁平率の 2 次元ガウス関数で決まる画素値をテクスチャとして持つ、 226×226 [画素] サイズの画像である。このようなテクスチャが 3 次元空間内の平面に張り付いていると考え、画像の中心に座標系の原点を設定し、原点を回転中心とする 3 軸回りの回転変形を考えた。100 フレームの時系列画像として、連続的に変形する画像を作成した。図 5(a) が先頭フレーム、(b) が最終フレームの画像である。

先頭フレームの画像を参照画像としたときの、正解ホモグラフィー行列 \mathbf{H} の要素 h_{11} , h_{12} , h_{21} , h_{22} , h_{31} , h_{32} の例を、図 6 に示す。ただし、カメラの内部パラメータはレンズ焦点距離 f と画素間隔 δ だけを含み、 $f/\delta = 400$ とする。また、原点を回転中心とする 3 軸回りの回転は、フレームごとにそれぞれ 0.15, 0.30, 0.05 [degree] である。このホモグラフィー行列の各要素に対する U_i は、ウィンドウサイズを 200×200 とすると h_{11} , h_{12} , h_{21} , h_{22} に対して $U_i = 0.02$, h_{31} , h_{32} に対して $U_i = 0.0022$ である。 h_{13} と h_{23} は画像間の平行移動を表すので、 $U_i = 1$ とした。

この実験では画像変形が小さいため、8 パラメータの初期推定値は、前述の小領域間対応を利用した推定 [13] を利用した。図 7 に、第 10 フレームの画像に対して h_{11} 以外のパラメータを初期推定値に固定したときに、 h_{11} パラメータを $U_{11} = 0.02$ 単位で初




図 7. h_{11} を U_{11} 単位で変化したときの類似度.

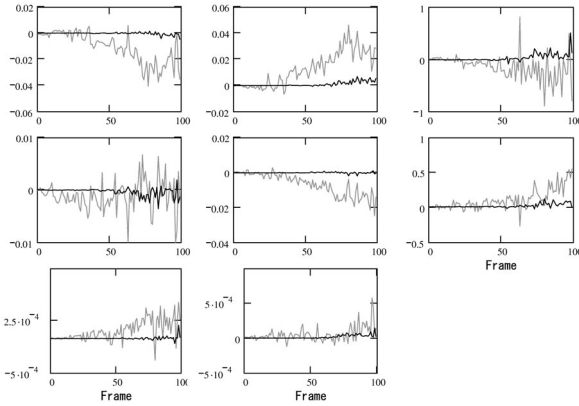


図 8. パラメータ推定誤差. \mathbf{H} 行列と同じ並びで示す. 灰実線は領域分割法, 黒実線は領域分割法の結果を初期値とした提案手法による推定誤差を示す.

期推定値から変化したときの類似度値を示す. この結果は, \mathbf{H} 行列のパラメータ推定において, 式 (11) を用いてパラボラフィッティングによってサブ SG 位置を推定することが可能であることを示している.

図 8 に \mathbf{H} の各要素推定誤差を示す. また, 図 9 に, 推定パラメータを使って変形した画像と初期フレーム画像との RMS 誤差を示す. 提案手法による推定パラメータが正確であることがわかる.

5.2 実画像を用いた 8 パラメータ同時推定

手持ちカメラでテクスチャ付き平面を時系列画像に撮影し, 先頭フレームに対する変形パラメータを推定した. カメラは, PointGray 社製 Dragonfly(monochrome), 画像サイズは 640×480 だが, 画像中央部に 200×200 [画素] の注目領域を設定して, この領域内の変形パラメータを推定した. 図 10 に, 実験に使った実画像を示す. この画像は, 実験に使った時系列画像中で最も変形が大きいフレームペアである.

このホモグラフィック行列の各要素に対する U_i は, 前節と同じである. 変形パラメータの初期値として, 前述の小領域間対応を利用した推定 [13] を利用した. このとき, SG 単位初期位置には誤差を含むが, 式 (11) の推定を行うときに各パラメータ軸に関して SG 単位の再探索を行っている.

図 11 に, 第 10 フレームの画像に対して h_{11} 以外のパラメータを初期推定値に固定したときに, h_{11} パラメータを $U_{11} = 0.02$ 単位で初期推定値から変化したときの類似度を示す. 前節で示した合成画像を




図 9. 推定パラメータおよび正解パラメータで変形した画像との RMS 誤差. 上側グラフ: 領域分割法 (灰実線) と提案手法 (黒実線). 下側グラフ: 正解パラメータ (灰実線) と提案手法 (黒実線). 注意: 上側グラフと下側グラフでは, 縦軸 (RMS 誤差) のスケールが異なる.



図 10. 実験に用いた実画像. 最も変形が大きいフレームペアを示す.

使った実験結果と同様に, \mathbf{H} 行列のパラメータ推定において, 式 (11) を用いてパラボラフィッティングによってサブ SG 位置を推定することが可能であることを示している.

図 12 に \mathbf{H} の各要素の推定値を示す. また, 図 13 に, 推定パラメータを使って変形した画像と初期フレーム画像との RMS 誤差を示す. この実験は, 小領域間対応を利用した変形パラメータ推定で得られた初期値から, 提案手法を利用してより正確な変形パラメータにリファインすることに相当する. 正解パラメータは不明だが, 提案手法によって明らかに安定でなめらかな変形パラメータが推定されている. RMS 誤差も提案手法の方が小さい. 推定した変形パラメータを用いてモーションスタビライゼーションした時系列画像を作成した結果においても, 明らかな違いがあった.

6 むすび

領域ベースマッチングと類似度補間手法によるサブピクセル推定は, 既に 20 年以上も利用されていて, 高速化手法, 高精度化手法, パラメータの多次元化などの多くの拡張が加えられてきた. この手法の組合せは, 注目領域を柔軟に設定できる, 繰り返し計算を必要としない, 計算量が小さい, 実装が容易でハードウェア化も可能, などの優れた特徴を持っている.

提案手法は, 画像間の平行移動量を高精度に推定する手法を拡張して, N パラメータの高精度同時推定を可能にした. 提案手法は, 領域ベースマッチン




図 11. h_{11} を U_{11} 単位で変化したときの類似度.

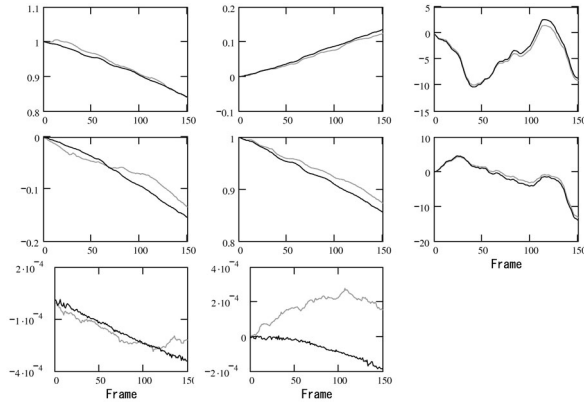


図 12. パラメータ推定値. H 行列と同じ並びで示す. 灰実線は領域分割法, 黒実線は提案手法による推定値を示す.

グと類似度補間手法に基づいているので, 類似度評価関数とサブピクセルフィッティング関数の組み合わせや, 推定誤差の性質とキャンセル方法などの検討結果をそのまま利用できる. 提案した画像変形パラメータ推定法は, 入力画像全体を 1 組の変形パラメータで表現できることを前提としているが, 画像を小領域に分割して, 各小領域に対して提案手法を適用することもできる.

現在, 提案手法を FPGA に実装して実時間処理を目標にした高速画像処理システムに実装する検討を進めている. 我々は, ビジョン分野の研究者や産業機器開発者が広く利用できる, 基礎的なビジョンツールを拡張できたと考えている.

参考文献

- [1] Qi Tian and M. N. Huhns, "Algorithms for Subpixel Registration", Computer Vision, Graphics, and Image Processing, Vol.35, pp.220-223, 1986.
- [2] J. K. Aggarwal and N. Nandhakumar, "On the Computation of Motion from Sequences of Images - a Review", Proceedings of the IEEE, Vol.76, No.8, pp.917-935, August 1988.
- [3] G. A. W. West and T. A. Clarke, "A Survey and Examination of Subpixel Measurement Techniques", Proceedings of the SPIE: Close-Range Photogrammetry Meets Machine Vision, Vol.1395, pp.456-63, Zurich, Switzerland, 1990.
- [4] H. K. Aghajan, C. D. Schaper, and T. Kailath, "Machine Vision Techniques for Subpixel Estimation of Critical Dimensions", Optical Engineering, Vol.32, No.4, pp.828-839, April 1993.




図 13. 推定パラメータで変形した画像との RMS 誤差. 灰実線は領域分割法, 黒実線は提案手法による結果.

- [5] Takeo Kanade and Masatoshi Okutomi, "A Stereo Matching Algorithm with an Adaptive Window: Theory and Experiment", IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol.16, No.9, pp.920-932, September 1994.
- [6] M. R. Shortis, T. A. Clarke, and T. Short, "A Comparison of Some Techniques for the Subpixel Location of Discrete Target Images", Proceedings of the SPIE: Videometrics III, Vol.2350, pp.239-250, Boston, MA, USA, 1994.
- [7] R.C.Hardie, K.J.Barnard, and E.E.Armstrong, "Joint MAP Registration and High Resolution Image Estimation Using a Sequence of Undersampled Images", IEEE Transaction on Image Processing, Vol.6, No.12, pp.1621-1633, December 1997.
- [8] George Wolberg and Siavash Zokai, "Image Registration for Perspective Deformation Recovery", SPIE Conf. on Automatic Target Recognition X, Orlando, Florida, April 2000.
- [9] 清水 雅夫, 奥富 正敏, "画像のマッチングにおける高精度なサブピクセル推定手法", 電子情報通信学会論文誌 D-II, Vol.J84-D-II, No.7, pp.1409-1418, July 2001.
- [10] Masatoshi Okutomi, Yasuhiro Katayama, and Setsuko Oka, "A Simple Stereo Algorithm to Recover Precise Object Boundaries and Smooth Surfaces", International Journal of Computer Vision, Vol.47, Issue 1-3, pp.261-273, 2002.
- [11] Richard Szeliski and Daniel Scharstein, "Symmetric Sub-Pixel Stereo Matching", 7th European Conference on Computer Vision (ECCV 2002), Volume II, pages 525-540, Copenhagen, May 2002.
- [12] 清水 雅夫, 奥富 正敏, "画像のマッチングにおけるサブピクセル推定の意味と性質", 電子情報通信学会論文誌 D-II, Vol.J85-D-II, No.12, pp.1791-1800, December 2002.
- [13] Jyh-Yeong Chang, Wen-Feng Hu, Mu-Huo Cheng, Bo-Sen Chang, "Digital Image Translational and Rotational Motion Stabilization using Optical Flow Technique", IEEE Transactions on Consumer Electronics, Vol.48, Issue 1, pp.108-115, February 2002.
- [14] Masao Shimizu and Masatoshi Okutomi, "Two-Dimensional Simultaneous Sub-Pixel Estimation on Area-Based Image Matching", Proc. Asian Conference on Computer Vision (ACCV2004), Jeju Island, Korea, January 2004.