

二次元フーリエ変換を利用した物体の姿勢推定

小野 友也^{†1} 岩井 儀雄^{†1} 石黒 浩^{†1}

近年、拡張現実感やロボットナビゲーションといった分野の研究が盛んに行われている。これらの研究において、カメラと対象物体の相対的な位置・姿勢を推定することは重要な課題である。本論文では、二次元フーリエ変換を利用した姿勢推定法を提案する。二次元フーリエ変換を利用して画像にマーカを埋め込むことでマーカ画像を生成する。このマーカ画像をカメラ等により撮像し、姿勢変化による空間周波数上の変化を観測することにより現在の姿勢を推定する。また、シミュレーション実験と実環境実験により本手法の有効性を確認した。

Posture Estimation by Using 2-D Fourier Transform

YUYA ONO,^{†1} YOSHIO IWAI^{†1} and HIROSHI ISHIGURO^{†1}

Recently, research fields of augmented reality and robot navigation are actively investigated. Estimating a relative posture between an object and a camera is an important task in these fields. In this paper, we propose a novel method for posture estimation by using 2-D Fourier Transform. The markers are embedded in an object's texture in the high frequency domain. We observe the change of spatial frequency of the object texture to estimate a current posture of the object. We conduct experiments to show the effectiveness of our method.

1. はじめに

近年、拡張現実感やロボットナビゲーションなどといった分野の研究が盛んに行われている。拡張現実感分野では、実画像に対して幾何的に正しい位置にCGを重畳し、ユー

ザに有用な情報を表示することで、直感的なインタフェースを実現することを目的とする研究¹⁾が数多く行われている。また、ロボットナビゲーションにおいても視覚センサであるカメラの情報は非常に重要であり、カメラ画像から現在の位置や移動経路を推定する研究²⁾が行われている。これらの研究において、カメラと対象物体の相対的な位置・姿勢の推定は重要な問題である。

これまで、カメラと対象物体の相対的な位置・姿勢の推定問題を解決する手法として様々な手法が提案されている。これらの手法は、特別なセンサを用いる手法^{3),4)}と、カメラなどの入力画像のみを利用するビジョンベースの手法⁵⁾⁻¹³⁾とに大別することができる。

特別なセンサを用いる手法は、GPS・ジャイロセンサ・磁気センサなどの特殊なセンサを使用し、姿勢推定精度の向上を図っている。神原³⁾は、GPSと小型慣性航法装置(INS)を組み合わせたシステムを構築している。このシステムは、GPSの欠点である計測周期の低さとINSの欠点である計測誤差の蓄積を互いに補完することで屋外での高精度な計測を可能にしている。松田⁴⁾は、自然特徴点と画像テンプレートの対応をデータベース化したものと姿勢センサにより得られる角速度情報を併用することで、カメラの高速な回転が生じた場合においても位置及び姿勢をロバストに推定する手法を提案している。一般にセンサを用いた手法は、組み合わせ次第で精度向上とその用途の幅を広げることが可能であるが、特別なセンサを組み込むためにシステムが煩雑になるという問題点がある。

ビジョンベースの手法は、カメラ等により得られた画像に対して特徴点抽出やエッジ抽出などの処理を施し、これらの情報を用いることで姿勢推定を行う。大江⁵⁾は、移動を伴って撮像された全方位動画から検出された自然特徴点を事前にデータベース化し、これを用いてカメラの位置・姿勢を推定している。また、Lepetit⁶⁾は対象の三次元モデルと特徴点の情報を用いて、三次元モデルと入力画像の対応関係からカメラの位置・姿勢を推定する手法を提案している。しかし、これらの方法は事前に対象となる物体や環境の三次元情報を知っている必要があるため、未知の環境下で用いることは難しい。

また、対象にマーカをつけることで、物体の姿勢を推定する方法^{7),8)}も提案されている。加藤⁷⁾は、矩形のマーカ画像のアピランスからリアルタイムに姿勢推定を行うシステムを提案している。さらに、この研究成果を利用して、羽原⁸⁾は屋内環境でユーザの位置情報を提示するシステムを提案している。マーカを用いた手法は特別な装置を必要としないが、人工的な画像を環境中に貼り付ける必要があるため景観を損なってしまうという問題がある。この問題を解決するため、再帰性反射材などを利用して不可視マーカ作成することで、景観を損なわない推定を実現している研究^{9),10)}もある。これらの研究は景観を損なう

^{†1} 大阪大学大学院基礎工学研究科
Graduate School of Engineering Science, Osaka University

ことはないが、再帰性反射材などの特別な素材を利用するのでコストなどの問題点がある。

また、特別な素材を利用せず、景観を配慮した姿勢推定法を提案した研究^{11)–13)}も存在する。ポスタのデザインを工夫し、環境にとけ込むマーカを恣意的に生成することで姿勢推定を行う研究^{11),12)}がある。これらの研究は、ポスタのデザインに拘束を設けることでポスタの矩形領域のアピアランスにより姿勢推定を可能にしている。また、コード化された情報をもつ特別な模様の描かれた壁紙を利用し、そのアピアランスから姿勢推定を行う研究¹³⁾もある。これらの手法は景観に配慮しているものの壁紙やポスタに厳しい拘束を強いる必要がある、導入の際の自由度を下げるという欠点がある。

そこで、本研究では、人に感知されにくいマーカを画像に埋め込むことで、景観を損なわずに導入できる姿勢推定法を提案する。具体的には、人間に感知されにくい画像の高周波領域にマーカを埋め込み、周波数空間上でのマーカの変化をカメラでとらえることにより姿勢推定を行う。

2. 問題設定

本研究では、二次元フーリエ変換を利用してマーカを埋め込んだ画像を利用して姿勢推定を行う。この節では、本研究における姿勢推定の問題設定について述べる。まず、カメラ座標系の x, y, z 軸である X_c, Y_c, Z_c 、及び、マーカ画像の重心 O_m と水平方向、鉛直方向の軸である X_m, Y_m と法線方向の軸 Z_m を図1のように設定する。カメラ座標系から見たマーカ画像面の姿勢は、並進移動行列 T と X_m, Y_m, Z_m 軸を回転軸とする回転角 $\theta_x, \theta_y, \theta_z$ により表現できる。ただし、回転運動は $X_m \rightarrow Y_m \rightarrow Z_m$ 軸まわりの順番で生じるものとし、カメラに対してマーカ画像面が正面を向いている状態を初期状態 ($\theta_x = \theta_y = \theta_z = 0 [deg]$) と定義する。

本研究では、カメラ等により撮像された入力画像が与えられたときに、初期状態からの姿勢の変化を表すパラメータ $\theta_x, \theta_y, \theta_z$ と、カメラとマーカ画像面との初期状態からの相対的な距離 d を推定する問題を取り扱う。入力画像は高周波領域にマーカを埋め込んだマーカ画像とし、マーカ画像の姿勢変化に伴う空間周波数上の変化を観測することで姿勢推定を行う。

3. 周波数マーカとカーネル回帰による姿勢推定法

3.1 マーカの埋め込み

マーカ埋め込みのイメージを図2に示す。一般的な画像を二次元フーリエ変換にかける

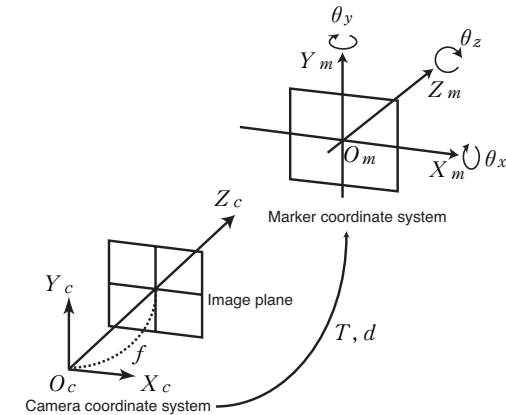


図1 Coordinates and problem settings




図2 Overview of marker embedding

と、そのパワースペクトルにおいて低周波領域にのみ信号が集中する性質がある。そこで、本研究では原画像の見た目に与える影響が少ないと考えられる高周波領域に信号を付加することでマーカを画像に埋め込む。マーカは、周波数スペクトルに対して楕円軌道に沿って一定の間隔で一定量のパワーをスペクトル画像に加えることで埋め込む。その後、二次元離散逆フーリエ変換を施すことによってマーカ画像を得る。このようにして埋め込まれたマーカをパワースペクトル上で観測することにより、姿勢推定を行う。そのため、テキスト解析などの従来研究^{14)–16)}とは異なり、テキストの性質の仮定や事前知識を必要としない。つまり、マーカの埋め込みを行っている印刷物は、印刷物の画像内容やテキスト情報を知っておく必要は無く、全てマーカ画像として扱うことができる。そして、人間の目に知覚されにくい高周波領域を利用しているため、景観を損ないにくいという利点もある。




図 3 Features in the frequency domain




図 4 Process flows of parameter estimation

3.2 特 徴 量

前節で述べたように、マーカーはパワースペクトル上において楕円軌道に沿って埋め込んである。そこで、楕円の形状を表すパラメータとして、楕円の軸の長さを表す α, β 、楕円の傾きを表す θ_1 を考える。ただし、 α, β は、カメラと物体の相対距離に比例して変化するパラメータなので、 $\gamma = \alpha/\beta$ を導入する。また、楕円軌道上の位相変化を表すパラメータ θ_2 を利用する。以上、本研究では、5つの楕円パラメータ $\alpha, \beta, \gamma, \theta_1, \theta_2$ を特徴量として扱う(図3)。

3.3 楕円パラメータの推定

入力画像を得てからパラメータの推定を行うまでの流れを図4に示す。また、図5にフーリエ変換直後の画像、図6に画像処理後の結果を示す。楕円の当てはめは、式(1)を a, b, c, f, g, h について最小化する問題を解くことにより行う。これらの楕円パラメータから、 α, β, θ_1 を計算することができる。

$$Q^2 = (a \cdot x^2 + b \cdot y^2 + c + 2f \cdot x + 2g \cdot y + 2h \cdot xy) \quad (1)$$

また、楕円の位相変化パラメータである θ_2 は、初期状態と相関が最大になる位相角を求めることで計算することが出来る。まず、方位 θ の方向にマーカーが存在する場合に1を、存在しない場合には0を取る方位関数 $s(\theta)$ を考える。初期状態における方位関数を $s_1(\theta)$ 、現在のパワースペクトルにおける方位関数を $s_2(\theta)$ と定義すると、特徴量 θ_2 は次式(2)によ




図 5 Power spectrum




図 6 Estimation result

り推定できる。

$$\theta_2 = \arg \max_{\Delta\theta} \int_0^{2\pi} s_1(\theta + \Delta\theta) \cdot s_2(\theta) d\theta \quad (2)$$

この方位関数により、二つの楕円のスケールが異なる場合においても正しく推定することが可能となる。

3.4 カーネル回帰による姿勢推定

本研究では、姿勢パラメータ $(\theta_x, \theta_y, \theta_z, d)$ と特徴量 $(\alpha, \beta, \gamma, \theta_1, \theta_2)$ の写像関係を学習により近似し、特徴量が得られたときに、その写像を用いて姿勢パラメータの推定を行う。本研究では、Kernel関数を用いたSupport Vector Regression (SVR)¹⁷⁾を用いた。

Kernel関数 K を用いた場合のSVRの式は、特徴次元数を D 、重みを $w_i (i = 1 \dots D)$ 、オフセットを b とすると式(3)のように表される。

$$y = f(\mathbf{x}) = \sum_{i=1}^D w_i K(\mathbf{x}_i, \mathbf{x}) + b \quad (3)$$

カーネル関数 K には、式(4)で表される多項式カーネルを用いた。ここで、カーネル関数を決定づけるパラメータ s, o, d はハイパーパラメータであり、具体的な値は実験的に決定した。

$$K(\mathbf{x}, \mathbf{y}) = (s \cdot \mathbf{x}^T \mathbf{y} + o)^d \quad (4)$$

SVRを用いて所望の姿勢パラメータと特徴量の関係を重み w_i を計算することにより学習し、その結果から式(3)を用いて推定を行う。マーカー画像の平面の向きを表すパラメータ $\theta_x, \theta_y, \theta_z$ が変化すると特徴量 $\alpha, \beta, \gamma, \theta_1, \theta_2$ がそれに伴って変化する。ただし、特徴量 α, β は距離に依存して変化するパラメータであるので、パラメータ $\theta_x, \theta_y, \theta_z$ の学習には特徴量 $\gamma, \theta_1, \theta_2$ を用いる。

表 1 Training data

Training data	range of posture
Set1	$\theta_x \in [0, 60], \theta_y \in [0, 60], \theta_z \in [0, 60]$
Set2	$\theta_x \in [0, 60], \theta_y \in [0, 60], \theta_z \in [-60, 0]$
Set3	$\theta_x \in [0, 60], \theta_y \in [-60, 0], \theta_z \in [0, 60]$
Set4	$\theta_x \in [0, 60], \theta_y \in [-60, 0], \theta_z \in [-60, 0]$

また, k を比例定数とし, 変化前のパラメータと特徴量を d_1, α_1 , 変化後のパラメータと特徴量を d_2, α_2 とすると

$$\frac{\alpha_1}{\alpha_2} = k \cdot \frac{d_1}{d_2} \quad (5)$$

という関係が成り立っており, 初期姿勢からの相対的距離を推定することが出来る.

4. 提案手法の拡張

入力画像に対して二次元フーリエ変換により得られる特徴量 $(\alpha, \beta, \gamma, \theta_1, \theta_2)$ と姿勢パラメータ $(\theta_x, \theta_y, \theta_z)$ の関係を SVR で学習することで, 画像から姿勢と距離のパラメータ $(\theta_x, \theta_y, \theta_z, d)$ を推定することが可能であるが, 同一の回転方向に対してのみで, 逆向きの回転方向の姿勢変化には対応できない. 図 7 に, 異なる回転方向に姿勢変化したときの学習を行ったときの学習誤差と次元の関係を示す. なお, 学習データとして表 1 のような形式をしたデータを用意した. これらの結果から学習誤差が大きく, パラメータ空間を分離できていないことが分かる.

そこで, 前回の姿勢である $(\theta_{x,t-1}, \theta_{y,t-1}, \theta_{z,t-1})$ を新たな特徴量として導入し, 次の姿勢への変分量 $(\Delta\theta_x, \Delta\theta_y, \Delta\theta_z)$ と特徴量 $(\gamma, \theta_1, \theta_2, \theta_{x,t-1}, \theta_{y,t-1}, \theta_{z,t-1})$ との関係を SVR により学習する. このように入力と出力を変更することで, 様々な姿勢変化に対応することができる. この拡張手法の性能と限界に関しては, 前節の提案手法とともに実験の章にて考察する.

5. 評価実験

SVR の重みの計算, 及び本提案手法の有効性を確認するためにシミュレーションと実環境において実験を行った. まず, 3 節で説明した提案手法に対する評価実験を示し, その後, 4 節で説明した拡張手法に対する評価実験を示す.




図 7 Training error

5.1 提案手法の評価実験

5.1.1 ハイパーパラメータの決定と学習

SVR を使って推定を行うためには, あらかじめ重み w_i の計算, 及びカーネル関数のハイパーパラメータ (d, s, o) を決定する必要がある. そこで, マーカ画像とカメラの距離を $3000[mm]$ と想定し, $\theta_x, \theta_y, \theta_z \in \{0, 10, 20, \dots, 50, 60\}$ [deg] の範囲で姿勢を変化させた様子を再現することで学習用の画像を生成した. この学習用画像に対して特徴量の抽出を行い, 姿勢パラメータと特徴量の関係を学習した.

ハイパーパラメータ (d, s, o) のうち, 次元 d 以外の項目は学習誤差に大きな影響を及ぼさないことが実験的に分かったので $s = o = 1$ とした. そして, 次元 d を変化させたときの学習誤差の推移を評価した. その結果を図 8,9 に示す. この結果より, マーカ画像面の向きを表す姿勢パラメータ $\theta_x, \theta_y, \theta_z$ の推定に用いる SVR のカーネル関数は $d = 5$, 距離推定に用いる SVR のカーネル関数は $d = 4$ であれば十分な精度があると考えられる. そこで, 以降の実験では次元を固定して, その時に学習した重み w_i を使うことで SVR による推定を行うこととした.

5.1.2 汎化性能の評価

提案手法の汎化性能を評価するために, 学習に用いていない姿勢画像を複数枚用意し, テストシーケンスを生成した. このテストシーケンスを順番に入力し, 順次姿勢推定処理を行ったときの推定結果を図 10, 11, 12, 13 に示す. また, 姿勢パラメータ $\theta_x, \theta_y, \theta_z$ と距離パラメータ d を推定した際の平均二乗誤差を表 2 に示す. いずれのパラメータの推定も十分な精度が得られていることが分かる.

本提案手法では, 学習と異なる距離でもパラメータ $\theta_x, \theta_y, \theta_z$ を推定するために, 距離に依存しない特徴量 $\gamma, \theta_1, \theta_2$ を用いている. そこで, その影響を調べるために, マーカ画像と




図 8 Training errors of $\theta_x, \theta_y, \theta_z$




図 9 Training error of d




図 10 Estimation results of θ_x




図 11 Estimation results θ_y




図 12 Estimation results of θ_z




図 13 Estimation results of d

カメラの距離を変化させて推定したときの真値との平均二乗誤差を計測した。結果を図 14 に示す。何れのパラメータも平均二乗誤差の分散が 0.1 未満という結果を得ている。この結果から距離に依存することなく姿勢パラメータ $\theta_x, \theta_y, \theta_z$ を推定できることが分かる。

次に、距離ごとの距離パラメータ d の推定誤差を調べた。結果を図 15 に示す。距離が増

表 2 Mean square errors of estimation results

Parameters	Mean square error
θ_x	1.8 [deg]
θ_y	1.5 [deg]
θ_z	0.7 [deg]
d	0.9×10^4 [mm]




図 14 Estimation errors with varying the distance




図 15 Estimation errors with varying the distance

えるにつれて推定結果の平均二乗誤差が大きくなること分かる。これは距離が増えるにつれて、距離推定に利用している比例定数 k の値が仮定している 1.0 から離れていくからではないかと考えられる。しかし、2000 [mm] において ± 50 [mm] 程度、4000 [mm] において ± 100 [mm] 程度の誤差であり、拡張現実感などの CG オブジェクトを表示する用途などでは問題ないと考えられる。

5.1.3 実環境実験

本提案手法の有効性を確認するために壁紙を想定したマーカ画像として図 16 のような B1 サイズのパネルを用意し、実環境で実験を行った。パネルには、モーションキャプチャ用のマーカが取り付けられており、モーションキャプチャで得られた姿勢パラメータの値を真値として利用する。カメラから約 3000 [mm] 離れた位置でパネルを操作して姿勢を変化させた様子をシグマ社製のカメラ（仕様は表 3 を参照）を用いて撮像し、これを入力画像として、本提案手法により姿勢推定を行った。モーションキャプチャによる真値と本提案手法による推定値を比較した結果を図 17, 18, 19 に示す。また、マーカ画像を壁に貼付け、カメラを壁に対して正面になるように設置して、距離推定を行った結果を図 20 に示す。推定結果の平均二乗誤差を表 4 に示す。




図 16 Wall paper used in this experiment

表 3 Camera specification

device	FOVEON X3 (CMOS)
size	20.7 × 13.8 [mm]
focal length	200 [mm]
image size	2640 × 1760 [pixels]




図 17 Estimation results of θ_x




図 18 Estimation results of θ_y

姿勢パラメータ $\theta_x, \theta_y, \theta_z$ は ± 3.3 [deg] 程度の誤差で推定できており、想定している距離においては十分な精度であると考えられる。次に、距離パラメータ d の推定誤差は $\pm 2.3 \times 10^2$ [mm] 程度となっている。また、距離が小さくなるにつれて推定誤差が大きくなる傾向が見られる。距離が近いほどパワースペクトルにおいてマーカーが分解能の小さな低周波領域にシフトすることが原因と考えられる。つまり、低周波領域では高周波領域に比べて姿勢の変化によるマーカーの変化が小さくなるためである。

5.2 拡張手法の評価実験

5.2.1 シミュレーション実験

Train.1 ~ *Train.4* のデータを用いて学習を行い、学習した軌跡を利用して推定を行った場合の推定誤差を表 5 に示す。何れの結果も学習した軌跡に対して、推定が可能となっていることが分かる。




図 19 Estimation results of θ_z




図 20 Estimation results of distance

表 4 Evaluation of estimation results in real images

parameter	mean square error
θ_x	11.0 [deg]
θ_y	9.2 [deg]
θ_z	0.6 [deg]
d	5.1×10^4 [mm]

表 5 Estimation error

parameter	mean square error [deg]
θ_x	16.0
θ_y	17.6
θ_z	1.1

次に任意の回転方向に対して推定を行うために $\theta_x, \theta_y \in [-60, 60], \theta_z \in [-180, 180]$ の範囲で姿勢が変化する軌跡を SVR により学習した。推定結果の一例を図 21, 22, 23 に示す。この時は、 $\theta_x, \theta_y, \theta_z$ の推定結果は平均二乗誤差がそれぞれ 9.5, 6.9, 5.2 [deg] であり、十分な精度がでていると考えられる。しかし、図 24, 25, 26 のように推定結果の一部の正負の符号が反転している結果も見られた。これは、図 27, 28 に示すように回転の向きが違うにもかかわらず、回転の大きさが等しくアピアランスの差異が小さい画像が存在するため、特徴量 $\gamma, \theta_1, \theta_2$ では判別が難しいためである。

5.2.2 実環境実験

先に述べた実環境と同様な環境で、*Train.1* ~ *Train.4* のデータを使って学習した結果を用いて姿勢推定実験を行った。図 29 に推定の様子を示す。推定した $x-y$ 平面と法線の




図 21 estimation results of θ_x




図 22 estimation results of θ_y




図 23 estimation results of θ_z




図 24 estimation results of θ_y




図 25 estimation results of θ_y




図 26 estimation results of θ_z

向きが赤い直線で示されている。正面を向いた状態(図 29(a))から姿勢変化後のマーカ画像面の向きが分かる(図 29(b))。また、真の回転行列 R_{true} と推定によって得られる回転行列 R との誤差をフロベニウス・ノルムを用いて評価した。シミュレーションと実環境でのフロベニウス・ノルムの値を表 6 に示す。

この結果から、シミュレーション実験での回転行列の誤差に対する実環境実験での回転行




図 27 $(\theta_x, \theta_y, \theta_z) = (20, 30, 40)$



図 28 $(\theta_x, \theta_y, \theta_z) = (-20, -30, 40)$

表 6 Frobenius norms of estimation results

	$\ R_{true} - R\ _f$
simulation	0.959×10^{-2}
real scene	1.49×10^{-2}

表 7 Prediction values of estimation errors

estimation parameter	mean square error
θ_x	24.8 [deg]
θ_y	27.3 [deg]
θ_z	1.8 [deg]

列の誤差の拡大率 m が、以下の式により求まる。

$$m = \frac{1.49 \times 10^{-2}}{0.959 \times 10^{-2}} \simeq 1.55 \quad (6)$$

ここで、ある軸周りの推定結果の平均二乗誤差を e_{mse} とすると、回転行列に与える誤差の影響は次式で表される。

$$E = (1 - \cos(\sqrt{e_{mse}})) \quad (7)$$

そして、実環境においては回転行列の誤差は m 倍に増大するので角度に現れる誤差 e は次式のようになる。

$$e = \arccos(1 - m \cdot E) \quad (8)$$

以上の計算から、実環境における誤差は表 7 のようになると予測できる。




図 29 examples of posture estimation results

6. まとめと今後の課題

本研究では、人に感知されにくい画像の高周波領域にマーカーを埋め込むことで、景観の損なわずに物体の姿勢を推定する方法を提案した。また、カーネル回帰により特徴量と姿勢パラメータ、相対距離を学習できることを示した。今回は楕円軌道を描くようにマーカーを埋め込んでいるが、必ずしもその必要はなく、パラメータ化可能な軌道、またはパターンでも構わない。すなわち、画像に与える影響を考慮してマーカーの埋め込み方法を工夫することが可能である。今後は、画像の見た目に与える影響を考慮しつつマーカーを埋め込むことができる枠組みを考える必要がある。

参 考 文 献

- 1) Zhou, F., Duh, H. B.-L. and Billinghurst, M.: Trends in Augmented Reality Tracking, Interaction and Display: A Review of Ten Years of ISMAR, *Proc. ISMAR*, pp. 193–202 (2008).
- 2) 松本吉央, 稲葉雅幸, 井上博允: ビューベースアプローチに基づく移動ロボットナビゲーション, *日本ロボット学会誌*, Vol.20, No.5, pp.506–514 (2002).
- 3) 神原誠之, 横矢直和: RTK-GPS と慣性航法装置を併用したハイブリッドセンサによる屋外型拡張現実感, *信学技報. PRMU*, Vol.104, No.572, pp.37–42 (2005).
- 4) 松田幸大, 池田 聖, 佐藤智和, 横矢直和: ランドマークデータベースと姿勢カメラを用いた高速回転にロバストなカメラの位置・姿勢推定, *信学技報*, Vol.106, No.535, pp.5–10 (2007).
- 5) 大江統子, 佐藤智和, 横矢直和: 幾何学的位置合わせのための自然特徴点ランドマ

クデータベースを用いたカメラ位置・姿勢推定, *日本バーチャルリアリティ学会論文誌*, Vol.10, No.3, pp.285–294 (2005).

- 6) Lepetit, V., Vacchetti, L., Thalmann, D. and Fua, P.: Fully Automated and Stable Registration for Augmented Reality Applications, *Proc. 2nd IEEE/ACM Int. Symp. on Mixed and Augmented Reality*, pp.93–102 (2003).
- 7) 加藤博一, Billinghurst, M., 浅野浩一, 橋哲八郎: マーカー追跡に基づく拡張現実感システムとそのキャリブレーション, *日本バーチャルリアリティ学会論文誌*, Vol.4, No.4, pp.607–616 (1999).
- 8) 羽原寿和, 町田貴史, 清川 清, 竹村治雄: ウェアラブル PC のための画像マーカーを用いた広域屋内位置検出機構, *信学技報. IE*, Vol.103, No.643, pp.77–82 (2004).
- 9) 中里祐介, 神原誠之, 横矢直和: 不可視マーカーを用いた位置・姿勢推定のための環境構築とユーザ位置・姿勢推定システム, *日本バーチャルリアリティ学会論文誌*, Vol.13, No.2, pp.257–266 (2008).
- 10) Park, H. and Park, J.-I.: Invisible Marker Tracking for AR, *Proc. 3rd IEEE/ACM Int. Symp. on Mixed and Augmented Reality*, pp.272–273 (2004).
- 11) 西上彰人, 玉田裕貴, 天目隆平, 柴田史久, 木村朝子, 田村秀行: 美観と頑健性を両立させた複合現実感用 半人為的幾何位置合わせマーカーの研究 (第3報) ~ポストへの情報埋め込み方式の実現~, *情処研報. CVIM*, Vol.107, No.427, pp.143–148 (2008).
- 12) 天目隆平, 西上彰人, 柴田史久, 木村朝子, 田村秀行: ポスタを利用した複合現実感用幾何的位置合わせ, *日本バーチャルリアリティ学会論文誌*, Vol.14, No.3, pp.351–360 (2009).
- 13) 齊藤 滋, 谷川智洋, 廣瀬通孝: コード化した模様を内装に施した室内における位置同定システム, *信学技報. MVE*, Vol.106, No.91, pp.1–6 (2006).
- 14) Witkin, A.P.: Recovering Surface Shape and Orientation from Texture, *Artificial Intelligence*, Vol.17, pp.17–45 (1981).
- 15) Toshio, T. and Yasuo, Y.: Estimation of Rotation and Slant Angles of a Textured Plane Using Spectral Moments, *IEICE Trans. on information and systems*, Vol.85, No.3, p.600 (2002).
- 16) Super, B.J. and Bovik, A.C.: Planar surface orientation from texture spatial frequencies, *Pattern Recognition*, Vol.28, No.5, pp.729–743 (1995).
- 17) Smola, A.J., Schölkopf, B. and Olkoph, B.S.: A tutorial on support vector regression, *Statistics and Computing*, Vol.14, No.3, pp.199–222 (2004).