

# 3D ベクトルペアを用いたばら積み物体の位置姿勢認識に関する研究

情報科学研究科 情報科学専攻 H11201M 秋月秀一

指導教員：橋本学 教授

## 1. はじめに

Factory Automation の高度化のために、ばら積み状態で供給された部品の自動ピッキングシステムの実現への期待が高まっている。ロボットアームでの部品取り出しのためには、位置姿勢を認識する必要があり、3次元計測デバイスによって得られたシーンデータと部品の3D-CADを照合する、いわゆるモデルベース認識手法が有効である。

代表的な手法として、物体モデルの局所領域内の3次元点群の法線方向分布を記述したSHOT特徴量[1]を用いた照合手法[2]がある。しかしながら、特徴量の記述領域は空間的な広がりを持つため、近接する他物体の距離データを外乱として含みやすい。さらに、特徴次元数が高く、対応点探索のコストが高くなるという問題点がある。

高速性が求められるピンピッキング用途においては、低次元な特徴量を採用することが望ましいと考えられる。これには、法線方向を持った2点対で構成されるPoint Pair Feature (PPF)を用いた照合手法[3]がある。PPFは特徴量自体のアイデンティティが低く、誤った対応点が発生しやすいため、安定した位置姿勢認識のためには大量のPPFを用いる必要があり、処理コストは依然として高かった。

本研究の目的は、高信頼な位置姿勢認識を実用的な処理時間で実現することである。提案手法では、物体モデルから選択された少数の特徴点のみを認識に用いることによって処理コストの問題を解決する。ここでの特徴点は、物体モデルにおいて含有率(発生確率)の低い起伏を持つ局所物理形状の代表点である。このような物理形状から記述される特徴量は他の特徴量と類似しないため独自性が高く、誤認識のリスクが低いと考えられる。

本研究ではさらに、対応点探索を高信頼化する特徴点検出手法も提案する。従来手法によって選択された特徴点[1],[4]はオクルージョンによって観測不能となることに起因して、対応点探索が困難となる問題があった。そこで、物体モデルを構成するデータ点の入力シーンにおける観測可能性を事前にシミュレートし、さまざまな視点から安定して観測されうる点から優先的に特徴点を選択する。そして特徴点の可観測性と、特徴ベクトルの独自性を統合することで、位置姿勢認識の信頼をさらに向上する。

## 2. 3D ベクトルペアを用いた位置姿勢認識

### 2.1 3D ベクトルペア

物体の3次元的な位置姿勢の決定には最低三つの3次元点が必要である。これらの三点を共通した一つの始点と、二つの独立した終点からなる3Dベクトルペアとして表現する。提案手法では3Dベクトルペアが照合の単位である。ベクトルペアは点 $P$ と $P$ から変位ベクトル $\mathbf{d}_{q1}$ ,  $\mathbf{d}_{q2}$ 離れた点 $Q_1, Q_2$ で構成される。また、それぞれの変位ベクトルの長さは $l_1, l_2$ であり、この間の角度を $\theta$ で表す。Fig.1に3Dベクトルペアの構成を示す。




図1 Structure of the 3D vector pair.

ベクトルペアは特徴量として、 $f(s_p, s_{q1}, s_{q2})$ を持つ。 $s_p, s_{q1}, s_{q2}$ はそれぞれ $P, Q_1, Q_2$ の法線ベクトル $\mathbf{n}_p, \mathbf{n}_{q1}, \mathbf{n}_{q2}$ と、 $\Delta P Q_1 Q_2$ の法線ベクトル $\mathbf{n}$ を用いて式(1)によって計算される。

$$s_p = \mathbf{n} \cdot \mathbf{n}_p, s_{q1} = \mathbf{n} \cdot \mathbf{n}_{q1}, s_{q2} = \mathbf{n} \cdot \mathbf{n}_{q2} \quad (1)$$

### 2.2 発生確率分析によるベクトルペア選択

$s_p, s_{q1}, s_{q2}$ をインデクスとした3次元共起ヒストグラム $h$ を生成する。ヒストグラムの各ビンは物体モデルにおける特徴量 $f(s_p, s_{q1}, s_{q2})$ の含有量を示す。この処理は、

- (1) 物体モデルからベクトルペアをサンプリング
- (2) 特徴量 $f(s_p, s_{q1}, s_{q2})$ の算出
- (3)  $f(s_p, s_{q1}, s_{q2})$ が示すビンの値をインクリメント

以上の3ステップを物体モデルが含むベクトルペアの数だけ繰り返す。さらに、共起ヒストグラムの総和が1になるように式(2)で正規化することによって、各ベクトルペアの発生確率 $Ph$ を求める。

$$Ph(s_p, s_{q1}, s_{q2}) = \frac{h(s_p, s_{q1}, s_{q2})}{\sum_{s_p=0}^{L-1} \sum_{s_{q1}=0}^{L-1} \sum_{s_{q2}=0}^{L-1} h(s_p, s_{q1}, s_{q2})} \quad (2)$$

$L$ は共起ヒストグラムの階調数を示す。 $Ph(s_p, s_{q1}, s_{q2})$ は特徴量 $f(s_p, s_{q1}, s_{q2})$ をもつベクトルペアの発生確率を示している。発生確率の低いベクトルペアを物体モデルを構成する点の数%~10%程度選択し、データベースに登録し、認識に利用する。

## 3. 可観測性を利用した対応点探索高信頼化

物体モデルの可観測率は、物体モデルの周囲に $K$ 点の観測点をランダムに設置し、各観測点から物体モデルの各点の観測状態を分析することで物体モデル1点ごとに確率として算出する。点 $p$ の可観測率は式(3)によって計算される。

$$Obs(p) = \frac{1}{K} \sum_{k=0}^{K-1} \delta(p, \mathbf{o}_k) \quad (3)$$

$\mathbf{o}_n$ は観測方向ベクトル、 $\delta$ は $\mathbf{o}_n$ を法線とする平面に物体モデルを投影したときに $p$ が観測可能な場合に1を出力する関数である。500点の観測点から生成された物体モデルの可観測率をカラーマップで表示した例をFig.2に示す。

Fig.2(a)(c)は物体モデル外観、(b)(d)は対応する可観測率マップである。可観測率が高くなるにつれて青~赤になるように着色されている。物体の外輪郭部分の可観測率が高く、窪み部分での可観測率が低くなる結果が得られた。

ベクトルペア $\mathbf{v}$ の可観測率 $Obs(\mathbf{v})$ の計算は、物体モデルの可観測率と同様のアプローチで計算する。ある視点からベクトルペアが観測可能な状態は、そのベクトルペアを構成する3点 $P, Q_1, Q_2$ が全て可観測であるときである。すなわち、 $Obs(\mathbf{v})$ は $\delta(P, \mathbf{o}), \delta(Q_1, \mathbf{o}), \delta(Q_2, \mathbf{o})$ の同時生起確率として表現できる。したがって、式(3)を拡張した式(4)によって計算される。

$$Obs(\mathbf{v}) = \frac{1}{K} \sum_{k=0}^{K-1} \delta(P, \mathbf{o}_k) \delta(Q_1, \mathbf{o}_k) \delta(Q_2, \mathbf{o}_k) \quad (4)$$

物体モデルから算出された各ベクトルペアの可観測率

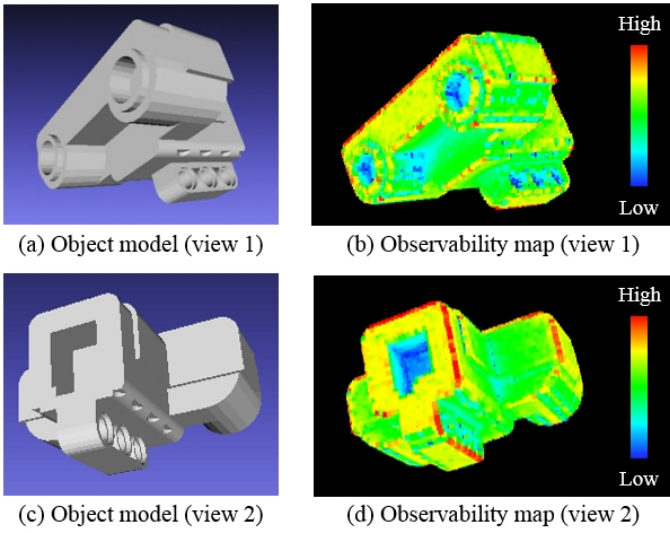


図2 Object model and observability map. (blue: low observability; red: high observability)

$Obs(\mathbf{v})$  と発生確率  $Ph(\mathbf{v})$  を統合することによって、2つの指標を両立したベクトルペアを選択する。統合指標の計算方法を式(5)に示す。

$$I(\mathbf{v}) = \omega_1 Obs(\mathbf{v}) + \omega_2 (1 - Ph(\mathbf{v})) \quad (5)$$

式(5)では、可観測性重視型とするか、独自性重視型とするかを調節できるように、ベクトルペアを2つの指標の重み付き線形和として評価することとした。 $\omega_1, \omega_2$  は統合時の重みパラメータである。

## 4. 実験結果と考察

### 4.1 認識性能の比較

4種類のデータセットを用いて認識性能の比較実験を行った。比較手法は以下の5手法である。

- (1) SHOT [1] + Correspondence Grouping(CG) 法 [2]
- (2) FPFH [4] + RANSAC ベースモデルマッチング [5]
- (3) ベクトルペア (独自性のみ) + ベクトルペアマッチング (以下、VPM と記す。)
- (4) ベクトルペア (可観測性のみ) + VPM
- (5) ベクトルペア (2指標統合) + VPM

VPM 法による認識結果例を Fig.3 に示す。白点は入力3次元点群を示し、色つきの物体モデルを認識結果の剛体変換パラメータに基づいて姿勢変換させて入力3次元点群に重ね合わせた。また、認識率と処理時間の関係を表1に示す。実験は CPU: Intel®CORE™i7, システムメモリ: 4GB で構成されるシステムでおこなった。

表1 Relationship between recognition rate  $Pr$  [%] and processing time  $T$  [sec].

Method		Object A	Object B	Object C	Object D
SHOT	$Pr$	51.3	77.9	33.6	20.3
	$T$	27.78	19.46	33.69	22.48
FPFH	$Pr$	54.9	11.5	73.5	31.0
	$T$	0.67	3.97	1.07	0.91
RANSAC	$Pr$	40.7	31.0	47.8	33.6
	$T$	0.27	1.41	0.39	0.72
Distinctiveness VP	$Pr$	97.3	100.0	94.7	85.0
	$T$	0.47	1.76	1.76	1.99
Observability VP	$Pr$	99.1	95.6	92.0	85.8
	$T$	0.44	1.76	1.42	1.81

SHOT 特徴量 + Correspondence Grouping 法: SHOT 特徴量は 1000 次元以上の実数ベクトルを特徴量とするため

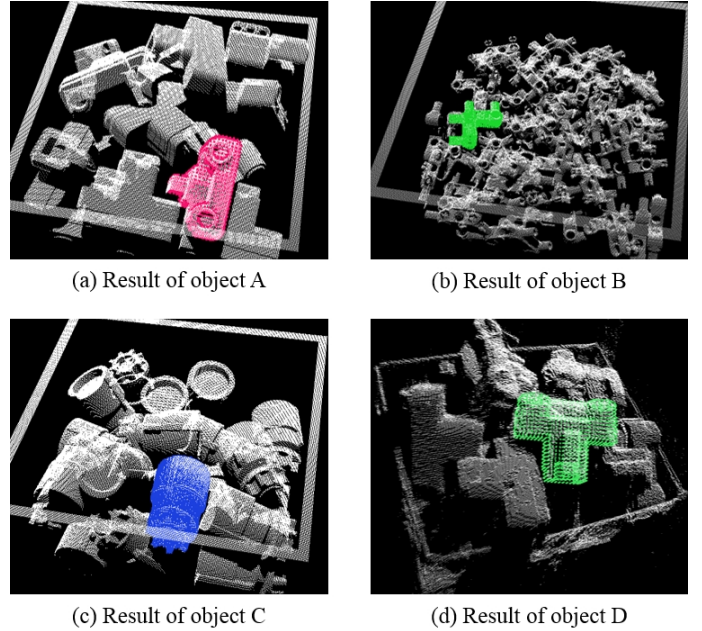


図3 Example recognition results for four datasets (superimposed on input point cloud).

対応点探索の計算コストが高い。加えて、密に物体が配置されたばら積みシーンでは、特徴量の記述領域に複数物体の距離データを含みやすいため、正しい対応点が得られにくかった。結果として、認識率が他の手法に対して低かった。

**FPFH 特徴量 + RANSAC ベースモデルマッチング:** FPFH は 10 次元の特徴量である。また、この照合手法は数点の対応点のみから姿勢仮説を生成し、RANSAC によって精度の高い姿勢仮説を推定結果とするため、高速な認識が可能である。しかしながら、誤差の値を明示的に計算しないため、高い精度での認識結果を得ることができなかった。

**VPM 法:** ベクトルペアは他の特徴量に比べて低次元の特徴量であることと、認識に用いる特徴点数を全体の 10% 程度に厳選したため、他手法に比べて高速に認識することができた。独自性のみ注目してベクトルペアを選択する手法では、物体モデルにおいて含有率の低い局所形状からベクトルペアを選択するため、偽の対応点が削減され、検証が必要な姿勢仮説数を減らすことができた。しかしながら、観測不可能なベクトルペアを多く選択していたため、認識率が低下した。一方で、ベクトルペアの選択基準に可観測性を加えることによって、対応点を安定に検出でき、認識率が向上した。

### 参考文献

- [1] F. Tombari, et al., "Unique Signatures of Histograms for Local Surface Description," in *Proc. 11th European Conference on Computer Vision (ECCV)*, pp 356–369, 2010.
- [2] F. Tombari, et al., "Object recognition in 3D scenes with occlusions and clutter by Hough voting," in *Proc. Fourth Pacific-Rim Symposium on Image and Video Technology*, pp.349–355, 2010.
- [3] B. Drost, et al., "Model Globally, Match Locally: Efficient and Robust 3D Object Recognition," in *Proc. IEEE Computer Vision and Pattern Recognition (CVPR)*, pp.998–1005, 2010.
- [4] R. B. Rusu, et al., "Fast Point Feature Histograms (FPFH) for 3D Registration," in *Proc. IEEE International Conference on Robotics and Automation (ICRA)*, pp.3212–3217, 2009.
- [5] A. G. Buch, et al., "Pose Estimation using Local Structure-Specific Shape and Appearance Context," in *Proc. IEEE International Conference on Robotics and Automation (ICRA)*, pp. 2080–2087, 2013.