

CCDoN 特徴量を用いたばら積み部品の高速・高信頼認識に関する研究

情報科学研究科 情報科学専攻 H11304M 永瀬誠信

指導教員：橋本学

1. はじめに

FA 分野において、3次元センサで撮影したばら積み部品を認識するピンピッキングシステムは、工場の生産ラインの自動化につながる重要な要素技術となっている。この技術においては、同種物体がばら積みされているシーンで、対象物体の6自由度の位置姿勢を高速かつ高信頼に認識することが望まれている。

3次元物体認識手法として、モデルベースの物体認識手法が数多く研究されてきた。この手法は、特徴量の記述方法で大きく次の2種類に分類することができる。1つ目は、特徴点周りの物体モデルの情報を利用して形状情報を記述する領域ベース手法である。この手法は、特徴点周辺の情報を利用して特徴量を作成するため形状情報を詳細に記述できる。そのため、照合時の信頼性が高い。しかしながら、一般的に特徴量の次元が高いため、照合時の処理コストが高くなるという問題点がある。2つ目は、3次元点群から構成される物体モデルの特徴点から2点もしくは3点の組み合わせを生成して、特徴量を記述する点対ベース手法である。この手法は、特徴次元が3から4と低いため、高速な処理が可能である。しかしながら、特徴量を2点や3点の点対のみの幾何関係を用いて特徴量記述しているため、類似した形状では同一の特徴量が算出され、照合時の信頼性が低下するという問題点がある。以上のように、領域ベースの特徴量記述手法、点対ベースの特徴量記述手法はそれぞれ高速性と信頼性に問題があり、それらを同時に実現する手法は提案されてこなかった。

そこで、本研究ではばら積み部品認識の高速性と高信頼性を両立する新たな特徴量を提案することを目的とする。

2. 提案特徴量の考え方

ピンピッキングシステムでは、高速かつ高信頼な認識が求められているため、特徴量の記述方法が重要となる。そこで本研究では、低次元の特徴量で記述することによって処理の高速性を保ちつつ、特徴点周りの形状情報を利用することによって、特徴量の信頼性を高める。これにより、従来同時に実現できていなかった認識の高速性と信頼性を両立する。

本研究で提案する特徴量は2つの異なる領域で算出した曲率値 (Curvature) と Difference of Normals (DoN) 特徴量 [1] を組み合わせた3つの形状評価値から構成される。以下、この特徴量を Combination of Curvatures and Difference of Normals (CCDoN) と呼ぶ。

DoN 特徴量は、大規模な3次元点群をセグメンテーションする手法として Ioannou らによって提案された特徴量である。この特徴量は、3次元点群から構成される点群の注目点に対して、2つの異なる球領域を設定して法線ベクトルを算出し、その2つの法線ベクトル間の差分により特徴量を記述する。DoN 特徴量は、スカラー値で算出されるため、領域ベースの手法でありながら高速な照合が可能である。そのため、本研究では3次元物体認識の特徴量として利用する。しかし、特徴量を法線ベクトル間の差分で表現した相対的な値で記述しているため、同じ相対値をも

つ特徴点との誤照合をおこす可能性があった。

そこで、本研究では DoN 特徴量に他の特徴量を組み合わせることによって、特徴量の信頼性を高め、誤照合の低減を図る。組み合わせる特徴量は姿勢変動に頑健かつ、処理の高速化のために低次元であることが望ましい。そのため、本研究では、DoN 特徴量と同様にスカラー値であり、姿勢変動に頑健な曲率値を組み合わせることによって特徴量の信頼性を高める。これにより、DoN 特徴量のみを用いる照合よりも誤照合の低減が可能となる。さらに、誤った対応点が削減されるため、後段処理である対応点群を用いた姿勢推定を高速化することができる。

3. CCDoN 特徴量の記述

CCDoN 特徴量算出の流れを図1に示す。

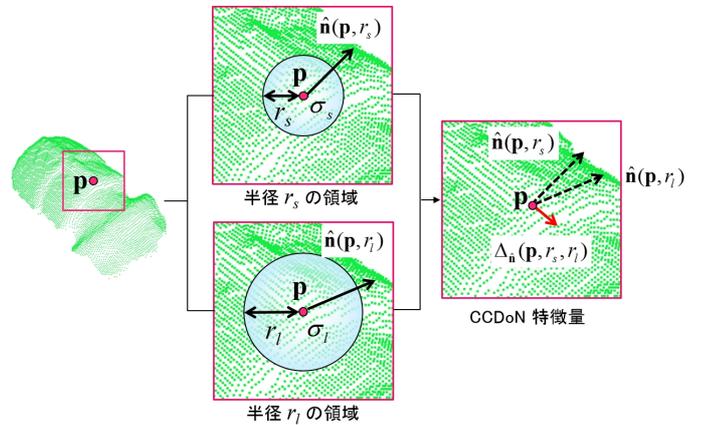


図1 CCDoN 特徴量算出の流れ

まず、各点群に対して2つの異なる半径 ($r_s < r_l$) の球領域を設定し、それぞれの球領域内に含まれる3次元点群を用いて式(1)により共分散行列 \mathbf{C} を作成する。

$$\mathbf{C} = \frac{1}{k} \sum_{i=1}^k (\mathbf{p}_i - \bar{\mathbf{p}})(\mathbf{p}_i - \bar{\mathbf{p}})^T \quad (1)$$

\mathbf{p}_i は3次元点、 $\bar{\mathbf{p}}$ は \mathbf{p}_i の平均値を示す。そして、その共分散行列から固有値 $\lambda_0, \lambda_1, \lambda_2$ (ただし、 $\lambda_0 \leq \lambda_1 \leq \lambda_2$) を算出する。そして、2つの単位法線ベクトル $\hat{\mathbf{n}}(\mathbf{p}, r_s)$, $\hat{\mathbf{n}}(\mathbf{p}, r_l)$ を算出する。 \mathbf{C} の最小固有値 λ_0 の固有ベクトルが法線ベクトルとなる。そして、DoN 特徴量を式(2)によって算出する。

$$\Delta_{\hat{\mathbf{n}}}(\mathbf{p}, r_s, r_l) = \frac{\hat{\mathbf{n}}(\mathbf{p}, r_s) - \hat{\mathbf{n}}(\mathbf{p}, r_l)}{2} \quad (2)$$

曲率は式(1)で算出した共分散行列の固有値 $\lambda_0, \lambda_1, \lambda_2$ を用いて、式(3)により算出される。

$$\sigma = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2} \quad (3)$$

最後に半径 r_s, r_l で算出した曲率 σ_s, σ_l と、DoN 特徴量を組み合わせることによって、CCDoN 特徴量 \mathbf{F} ($\|\Delta_{\hat{\mathbf{n}}}\|$,

σ_s, σ_l) を生成する. CCDoN 特徴量の各値は, 法線間の差分値, 特徴点周りの局所形状, 大域形状を表現している. 3つの異なる値を照合に利用するため, 誤照合の低減につながり, 高速かつ高信頼な照合が可能となる.

4. 実験結果と考察

レンジセンサーで撮影した4種類の物体の実データをそれぞれ約130シーン用いて認識性能を比較した. 比較手法は提案手法に加え以下の5手法である.

- Method 1: Spin Image (SI) [2]
- Method 2: SHOT [3]+Correspondence Grouping [4]
- Method 3: Distinctive Histogram Matching (DHM) [5]
- Method 4: Vector Pair Matching (VPM) [6]
- Method 5: Difference of Normals (DoN) [1]

Method 5は本研究で提案したマッチング方式の枠組みにおいて特徴量を曲率を用いずに DoN 特徴量のみを用いた手法である. 表1に認識成功率 P_r [%] と処理時間 T [sec] を示す. 図2に認識結果を入力データに重畳した結果を示す.

表1 実データに対する認識成功率 [%] と処理時間 [sec]

		物体				平均
		A	B	C	D	
SI [2]	P_r	49.6	50.8	35.2	70.6	51.6
	T	24.95	55.34	31.21	20.68	33.05
SHOT [3]	P_r	74.4	96.2	65.6	84.9	80.3
	T	45.41	52.85	29.26	26.10	38.41
DHM [5]	P_r	89.1	97.7	94.5	93.7	93.8
	T	5.83	4.76	2.05	1.76	3.60
VPM [6]	P_r	94.6	99.2	79.7	92.9	91.6
	T	0.42	0.64	0.64	1.19	0.72
DoN [1]	P_r	97.6	88.4	92.1	96.0	93.5
	T	0.95	0.39	0.43	0.88	0.66
提案手法	P_r	100.0	99.2	96.1	97.6	98.2
	T	0.45	0.25	0.35	0.58	0.41

(CPU : Intel ®CORE™i7-3.40GHz, メモリ : 8GB)

提案手法は, DoN 特徴量と2つの曲率という3つの形状評価値を組み合わせることによって, DoN 特徴量のみを用いる Method 5 に対して平均認識成功率が93.5%から98.2%に向上し, 高信頼な照合を実現した. また, DoN 特徴量に曲率値を組み合わせることによって誤照合の低減が可能となり, 平均処理時間も0.66秒から0.41秒に高速化できた. これにより, DoN 特徴量に曲率値を組み合わせた CCDoN 特徴量が DoN 特徴量よりも認識に有効であることが確認できた.

SI 法は入力データからランダムに特徴点を選択して, Spin Image を作成し, 物体モデル全点と照合する. しかしながら, ランダムに選択した特徴点が物体モデルと正しく対応しなければ照合することができない. また, 画像という高次元の特徴量をもとに照合をおこなうため, 処理コストが高かったと考えられる.

SHOT 法は高次元の実数ベクトルを特徴量とするため, 照合時の処理コストが高い. また, ばら積み部品のような密に物体が接しているシーンでは, 特徴量の記述領域に複数物体の形状情報を含んでしまいやすく, 正しい対応点が得られにくかった. そのため, 認識成功率が他の手法に対して低かった.

DHM 法は, 法線ベクトル同士のなす角度を軸としたヒ

ストグラムを作成して, そのヒストグラム同士を比較して特徴点の独自性を算出し, 独自性の高い特徴点のみを照合に用いることにより, 高信頼な照合を実現している. 同じ領域ベース手法である SHOT 法に対して, 独自性の高い少数の特徴点のみを認識に用いているため, 高速かつ高信頼な照合が可能であった. しかしながら特徴次元が高いことに起因して提案手法よりも認識時の処理コストが高かった.

VPM 法は, 他の領域ベースの手法に対して高速に認識することができた. これは, 領域ベースの手法に対して特徴次元数が低かったためであると考えられる. しかしながら, $N C_3$ の特徴点の組み合わせが必要であるため, 入力シーンデータによっては処理時間がかかる場合もあった.

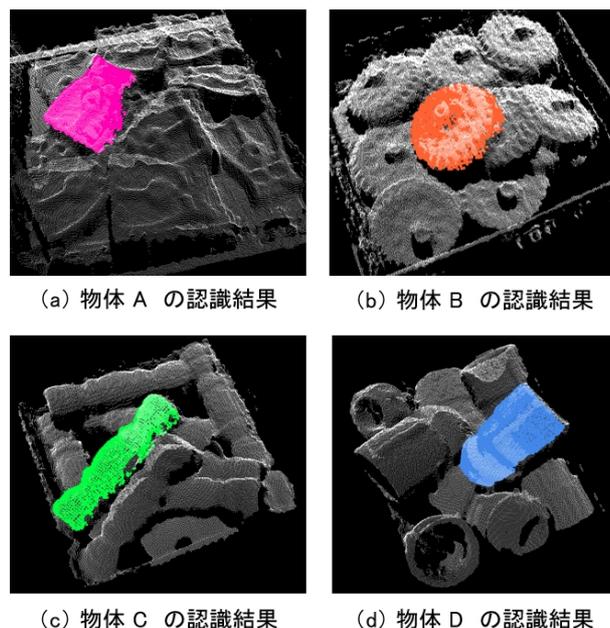


図2 実データに対する認識結果

5. おわりに

本研究では, ばら積み部品認識のための高速性と高信頼性を両立する CCDoN 特徴量を提案した. 4種類の形状が異なる対象物が, それぞればら積みされた約130シーンのデータを用いた従来手法との認識性能評価実験により, CCDoN 特徴量を用いた提案手法は高速かつ高信頼に認識できたことを確認した.

参考文献

- [1] Y. Ioannou, et al., "Difference of Normals as a Multi-Scale Operator in Unorganized Point Clouds", 3DIM-PVT, pp.501-508, (2012).
- [2] A. E. Johnson, et al., "Using Spin Images for Efficient Object Recognition in Cluttered 3D Scenes", PAMI, Vol.21, Issue 5, pp.433-449, (1999).
- [3] F. Tombari, et al., "Unique Signatures of Histograms for Local Surface Description", ECCV, pp.356-369, (2010).
- [4] F. Tombari, et al., "Object Recognition in 3D Scenes with Occlusions and Clutter by Hough Voting", PRSIVT, pp.349-355, (2010).
- [5] 永瀬誠信ら, "誤照合を最小化する3-D特徴点を用いた高信頼な物体認識手法", 精密工学会誌, Vol.79, No.11, pp.1058-1062, (2013).
- [6] 秋月秀一ら, "特徴的3-Dベクトルペアを用いたばら積み部品の高速位置姿勢認識", 電学論C, Vol.133, No.9, pp.1853-1854, (2013).