

# 局所形状の独自性に着目した物体認識に有効な 3-D 特徴点の自動抽出

永瀬 誠信<sup>1,a)</sup> 秋月 秀一<sup>1</sup> 橋本 学<sup>1,b)</sup>

**概要:** 本稿では、特徴点を用いるモデルベースの3次元物体認識において、認識に有効な特徴点を自動抽出する手法、およびこれに基づく高信頼・高速な積み物体認識手法を提案する。物体モデルとしては、多数の3次元点群で表現される一般的なモデルを利用する。提案手法は、全ての3次元点の中から、モデル内の他の点との類似性が低い(=独自性が高い)特徴点のみを抽出する。独自性の高い点を用いることから誤対応が低減し、さらに全点数の1%程度のごく少数の点だけを用いることから、高速化も実現できる。点ごとの独自性の評価にあたっては、各注目点周りの局所的な形状情報を、近傍の法線ベクトルの方向分布としてヒストグラム表現し、これをモデル内の全点にわたって相互比較することによって、他の部位と異なる局所形状を持つ点ほど高独自性と考え、このようにして得られた独自性の高い特徴点のみを入力画像中の全ての計測点と照合し、物体の位置・姿勢パラメータを最尤推定する。実距離画像を用いた実験の結果、従来手法である Spin Image 法に対して認識成功率が51.6%から93.8%に大きく向上し、同時に処理速度も約9倍高速化できた。また、近年着目されているPCL(Point Cloud Library)に登録されている Correspondence Grouping 法に対しても、認識成功率が13.5%向上、処理速度が約10倍高速化できたことを確認した。

**キーワード:** 物体認識, 3次元特徴点マッチング, ロボットビジョン, ポイントクラウドデータ, ビンピッキング

## Extraction of 3-D Feature Point for Effect in Object Recognition based on Local Shape Distinctiveness

NAGASE MASANOBU<sup>1,a)</sup> AKIZUKI SHUICHI<sup>1</sup> HASHIMOTO MANABU<sup>1,b)</sup>

**Keywords:** object recognition, 3-D feature point matching, robot vision, point cloud data, bin-picking

### 1. はじめに

工場などの生産ラインでは、人件費削減を目的にロボットによる自動化が求められている。近年、消費者のニーズの多様化に応えるために、セル生産の重要性が高まっている。なかでも、ビンピッキングシステムは重要な技術であり、物体の3次元的な位置姿勢を高信頼かつ高速に認識す

ることが求められている。

3次元物体認識の代表的な手法としてアピアランスベースの物体認識手法がある。この手法には、パラメトリック固有空間を用いてデータ量を圧縮する手法 [1] やアンサンブル分類木を用いて高速化を図る手法 [2] がある。これらの手法は、認識時に物体の3-D形状モデル(以下、物体モデルと呼ぶ)の幾何学的な変換を必要としないという利点があるが、学習する姿勢パラメータの分解能が認識時の姿勢推定精度を決定づけることから、学習する姿勢分解能の増加による処理コストの増加が問題となる。

一方、事前に対象物の物体モデルを用意し、入力データ

<sup>1</sup> 中京大学大学院 情報科学研究科  
Graduate School of Information Science and Technology,  
Chukyo University, Nagoya, Aichi 466-8666, Japan

a) nagase@isl.sist.chukyo-u.ac.jp

b) mana@isl.sist.chukyo-u.ac.jp

と照合するモデルベースの物体認識手法がある。この手法は、アピランススペースのような膨大な画像データベースの作成や記憶が不要であるという利点がある。

物体モデル内の点群の位置関係をヒストグラムとして表現する手法として、Spin Image 法 [3] や 3D Shape Context 法 [4] がある。Spin Image 法は、物体モデル内の注目点における法線ベクトルを基準とし、その周辺点との相対的な位置関係を 2 次元の投影面に投票した位置姿勢に不変な特徴量を入力距離画像と照合する手法であり、3D Shape Context 法は注目点の周辺領域を複数に分割し、その領域に含まれる点群の密度情報をヒストグラムとして表現する手法である。これらの手法は視点に依存しない照合が可能であるが、照合に用いる点を物体モデル全点やランダムに選択するため類似する局所形状を有する点を選択されやすく、誤照合が増加する。また、照合に用いる点数が多いため、処理コストの増加が問題となる。

モデルベースの他のアプローチとして特徴点のみを用いる高速な手法があり、物体表面の法線情報と Shape Index [5] によって記述された Local Surface Patch [6] と呼ばれる局所特徴量を照合に用いる手法や、距離データのある視点方向から見た仮説的な距離画像である距離アスペクト画像 (DAI) を作成して照合する手法 [7], [8] がある。これらの手法は、曲率の大きな形状の代表点のみを特徴点として用いるが、必ずしも認識に有効とは限らない。つまり、物体モデル内で曲率の大きな形状を有する特徴点が多く存在する場合には誤照合が増加する。

さらに、物体モデル内の点群の位置関係ではなく、距離情報を保持したエッジを利用する手法 [9], [10] がある。物体モデルの局所的な情報のみを照合に用いるため高速な認識が可能であるが、ばら積みシーンでは、物体同士を重ねるによって発生する疑似エッジが原因となり誤照合が増加する。

近年、物体表面の法線情報を利用して特徴を記述し、基準座標系 (Reference Frame) を用いて照合する SHOT [11] 特徴量や物体モデルのテクスチャ情報を追加した CSHOT [12] 特徴量を用いるモデルベース物体認識手法が提案された。これらの手法は各特徴点に対して Reference Frame を作成するため、特徴点 1 点同士の対応のみで姿勢推定が可能である。しかしながら、ばら積みシーンでは、Reference Frame の作成時に複数の物体領域を含んでしまうため、正しい位置姿勢パラメータを求めることができない。

以上のように、従来の 3 次元物体認識手法は、信頼性や高速性に問題があった。そこで本研究では、処理効率の観点から、3 次元座標を有するポイントクラウドデータ (以下、3 次元点群と呼ぶ) を利用した特徴点マッチングをベースに、認識の高信頼性と高速性を両立するモデルベースの物体認識システムの構築を目的とする。

本研究で扱う物体モデルは 3 次元点群からなり、注目点

周辺の局所形状を表現する属性値を付加した特徴点から構成されている。属性値は各特徴点まわりの法線方向分布ヒストグラムで記述され、ヒストグラム同士の相違度を計算することで、各特徴点の独自性を算出し、独自性の高いものから優先的に照合に用いる。このような独自性の高い少数の特徴点のみを入力距離画像との照合に用いることで誤照合の低減と処理の高速化を図る。

本手法では、物体モデルの 1 点の特徴量を、その周辺の点群情報を用いて表現することにより、入力データに生じた誤差を許容でき、安定した特徴記述を可能にしている。また、特徴量を法線方向分布のヒストグラムとして記述することにより、物体の位置姿勢変化の影響を受けにくくなるという利点がある。姿勢パラメータの算出には、投票処理を利用した照合を用いることで物体モデルと入力距離画像の整合性の高い姿勢パラメータの算出を可能とする。

以下、第 2 章では本研究における基本アイデアについて述べ、第 3 章では提案アルゴリズムの概要と特徴点の独自性の算出方法について説明する。第 4 章では物体モデルから選択された特徴点分布の分析とばら積みされた多種類の対象物に対する認識性能評価について述べ、第 5 章にて本研究の成果をまとめる。

## 2. 基本アイデア

本研究では、物体認識の高信頼性と高速性を両立するために、以下に示す 2 つの基本アイデアを導入する。

1 つ目のアイデアは、物体モデル各特徴点の独自性を数値化することである。注目特徴点周辺の局所形状が他の特徴点の周辺形状と類似していなければ独自性が高い特徴点である。物体モデル内で独自性の高い特徴点ほど、入力距離画像内において一意に対応する確率が高まるため、誤照合の低減が可能である。

2 つ目のアイデアは、照合に用いる特徴点を厳選することである。算出した各特徴点の独自性の値が高い少数の特徴点を選択することによりデータ量の削減に繋がり、高速な物体認識が可能となる。

図 1 に物体モデルの独自性が高い特徴点と低い特徴点の例を示す。




図 1 独自性が高い特徴点と低い特徴点

Fig. 1 Distinctive feature points and non-distinctive feature points.

○印で示した特徴点は、直線的に大きな曲率が続く形状部分であり、物体モデルを特徴づけているため独自性が高い。また、×印で示した特徴点は、物体モデルの大部分を占めるなめらかな形状の一部であるため独自性が低い。本研究では、このような独自性の高い特徴点を少数抽出して認識に用いる。

### 3. 提案手法

#### 3.1 提案アルゴリズム

提案アルゴリズムの流れを図2に示す。

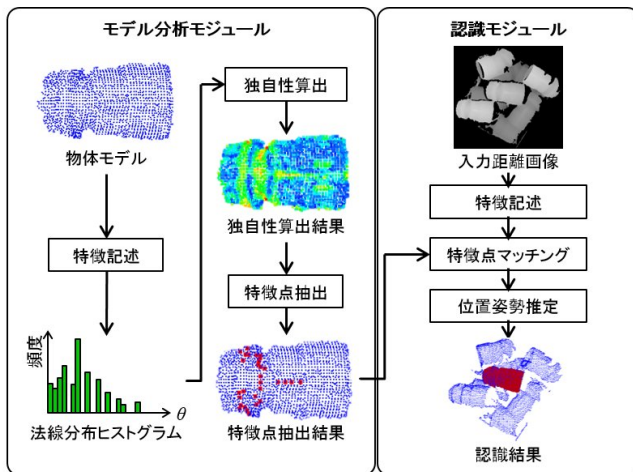


図2 提案アルゴリズムの流れ

Fig. 2 Flow of the proposed algorithm.

提案アルゴリズムは、モデル分析モジュールと認識モジュールから構成される。

モデル分析モジュールでは、注目特徴点とその周辺の特徴点の法線ベクトルを用いたヒストグラムで特徴を記述することで、各特徴点の属性値を算出する。そして、注目特徴点とそれ以外のすべての特徴点の法線方向分布ヒストグラム同士の相違度を比較することにより、各特徴点の独自性を数値化し、独自性の高い点から優先的に照合に用いる特徴点として抽出する。

認識モジュールでは、レンジセンサで撮影した距離画像を用いて、モデル分析モジュールと同様に各点の特徴を記述し、抽出した独自性の高い特徴点の法線方向分布ヒストグラムと照合する。最後に物体モデルと入力距離画像の対応点の組を用いて対象物の位置姿勢を推定する。

#### 3.2 法線方向分布ヒストグラム

図3を用いて各特徴点の特徴記述表現である、法線方向分布ヒストグラムの作成方法を説明する。

まず、物体モデルの注目点  $n$  を中心とする半径  $r$  の球領域を設定し、 $n$  と球領域内に含まれる点群  $m_t$  の法線ベクトル  $\mathbf{N}_n$  と  $\mathbf{N}_{m_t}$  のなす角度  $\theta$  を求める。次に、縦軸を頻度値、横軸を角度  $\theta$  とする法線方向分布ヒストグラムを

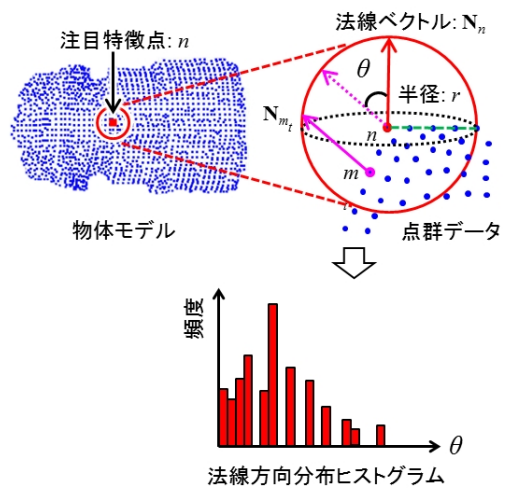


図3 法線方向分布ヒストグラムの作成方法

Fig. 3 Method for creating normal distribution histogram.

作成する。これは注目特徴点周辺の局所形状を表現している。注目特徴点の特徴量を球領域内に含まれる点群情報を用いて記述することにより、多少の誤差がデータに生じても許容することが可能である。また、ヒストグラム形式にすることにより、物体モデルの姿勢変化によらず不変な頻度分布となり、同一の周辺形状を保持する点は同じ特徴量となる。物体モデルを構成するすべての点でこの処理を適用し、法線方向分布ヒストグラムを作成する。

#### 3.3 独自性指標の算出

物体モデル点の独自性算出方法について説明する。まず、式(1)に示す Bhattacharyya 係数を用いて、物体モデルの注目特徴点と注目特徴点以外の法線方向分布ヒストグラム同士の相違度  $B$  を算出する。

$$B(P, Q) = 1 - \sum_{u=1}^U \sqrt{P_u Q_u} \quad (1)$$

$P, Q$  は法線方向分布ヒストグラム、 $U$  はヒストグラムのビン数、 $u$  は注目ビンである。相違度  $B$  は1に近いほどヒストグラム同士の相関が低いことを表現している。次に、式(2)より注目特徴点の独自性指標  $S_n$  を算出する。

$$S_n = \frac{1}{T} \sum_{t=1}^T B(p_n, q_t) \quad (2)$$

ここで、 $p, q$  は法線方向分布ヒストグラム、 $T$  は物体モデル点数、 $n$  は注目特徴点、 $t$  はその他の物体モデル点である。独自性指標  $S_n$  は0から1までの値を算出し、1に近いほど注目特徴点の独自性が高いことを示している。

#### 3.4 投票処理による特徴点マッチング

特徴点を用いたマッチングによる物体モデルと入力距離画像の対応点抽出手法について説明する。まず、物体

モデルから抽出した独自性の高い特徴点と入力距離画像から算出した法線方向分布ヒストグラム同士の類似度を Bhattacharyya 係数により計算し、物体モデルと入力距離画像の対応点を決定する。次に、図 4 に示すように物体モデル間の特徴点  $m_1, m_2$ 、入力距離画像間の点  $s_1, s_2$  をそれぞれグルーピングする。そして、式 (3) を満たすような物体モデルと入力距離画像の対応点組を用いて、物体モデルの位置姿勢パラメータを算出する。

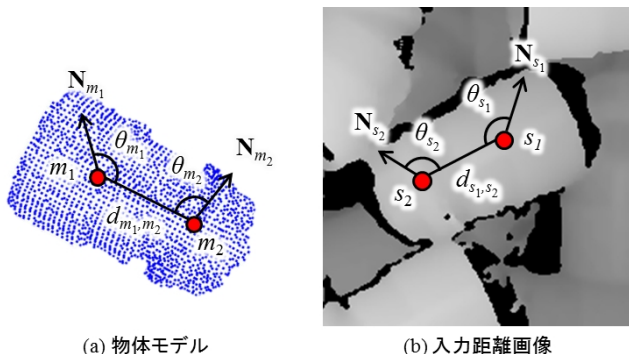


図 4 物体モデルと入力距離画像の幾何学的関係

Fig. 4 Geometric consistency of an object model and the range image.

$$(|d_{s_1, s_2} - d_{m_1, m_2}| < th_d) \cap (|\theta_{s_1} - \theta_{m_1}| < th_t) \cap (|\theta_{s_2} - \theta_{m_2}| < th_t) \quad (3)$$

$d_{m_1, m_2}, d_{s_1, s_2}$  は物体モデルと距離画像中の 2 点間のユークリッド距離、 $\theta_{m_1}, \theta_{m_2}, \theta_{s_1}, \theta_{s_2}$  は 2 点間の距離と注目点の法線ベクトルのなす角度、 $th_d, th_t$  はそれぞれ 2 点間の距離と角度のしきい値である。

物体モデルの注目点  $m_1$  にはあらかじめ物体モデル重心へ伸びるベクトルを関連づけておき、算出された位置姿勢パラメータを適用する。そして入力距離画像に投票空間を設定し、ベクトルの先端の座標に姿勢パラメータを投票する。図 5 に投票処理によるマッチングの様式図を示す。

多くの投票がある座標は、多くの対応点により支持されたことを意味するため、対象物が存在する可能性が高い候補とみなすことができる。姿勢変換した物体モデルと入力距離画像の整合性を式 (4)(5) により確認し、最も整合性の高い位置姿勢パラメータを最終的な物体モデルの位置姿勢とする。

$$R_i = \frac{1}{T} \sum_{t=1}^T D(m_t) \quad (4)$$

$$D(m_t) = \begin{cases} c & \text{if } f(m_t(x), m_t(y))=0 \\ |m_t(z) - f(i, j)| & \text{otherwise} \end{cases} \quad (5)$$

$R_i$  は  $i$  番目の物体モデルと入力距離画像の整合性であ

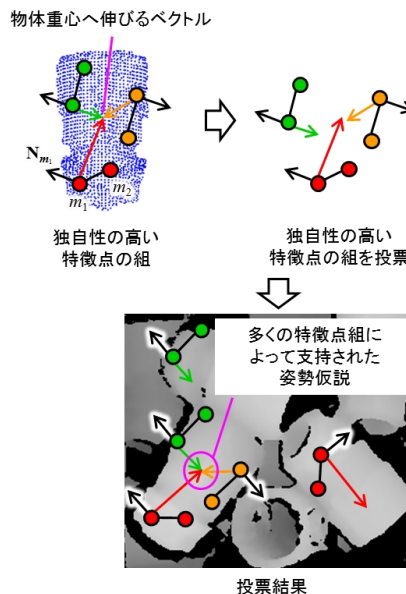


図 5 独自性の高い特徴点を用いたマッチング

Fig. 5 Overview of pose recognition scheme using distinctive feature points extracted from object model.

り、この値が低いほど整合性が高くなる。 $m_t(x), m_t(y), m_t(z)$  は物体モデル上の 3 次元座標を表し、 $T$  点で構成される物体モデルの  $t$  番目のデータ点を示す。また、関数  $f$  は距離画像中の画素値を示す。 $D(m_t)$  は物体モデル点と対応する入力距離画像との整合性を示している。上段の条件式は姿勢変換した物体モデルに対応する入力距離画像の画素がデータ欠落している場合の処理である。なおペナルティ  $c$  は実験的に決定する。

## 4. 実験結果と考察

### 4.1 独自性分布の評価実験と特徴点選択

本節では、物体モデルを用いて各特徴点の独自性を算出した結果と抽出された特徴点の分布を示す。図 6(a) に示す多面体の物体モデルを用いて、モデル各特徴点の独自性を算出した。図 6(b) に物体モデル各特徴点の独自性算出結果を表示し、図 6(c) に横軸を独自性指標、縦軸を頻度値とした独自性分布を示す。今回、実験に用いた多面体モデルのように直角する面が多い場合、法線方向分布ヒストグラムを作成した際に法線ベクトル同士のなす角が 0 度や 90 度付近に偏る傾向がある。そのため、微小な差も検出できるようにヒストグラムの分解能を 2 度ピッチと細かく設定した。また、この物体モデルは、1mm ピッチで作成されており、特徴記述する球領域内に 1 点の頂点が含まれるように半径  $r$  を 5mm とした。

多面体モデルにおいて、平面付近より稜線付近、稜線付近より頂点付近の独自性が高く算出されたことを確認した。また、合計 14 点ある頂点の中でも、凹部分の点を中心とする形状は 2 点のみであり、多面体モデルを特徴づけてい



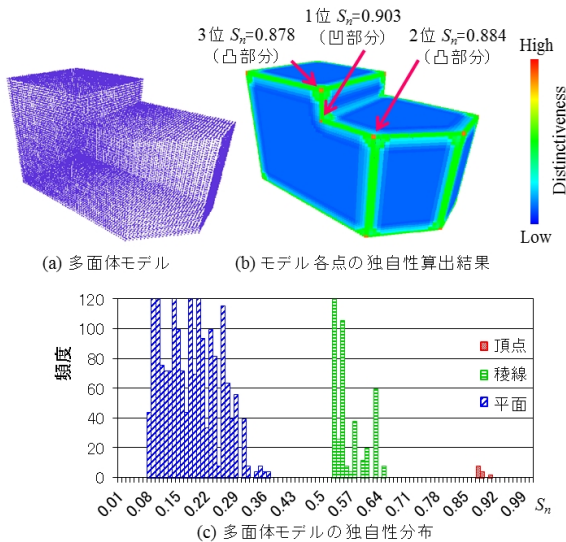


図 6 独自性算出結果

Fig. 6 Distinctiveness calculation result.

る。そのため、凹部分の頂点の独自性が最も高く算出された。一般的に頂点の独自性が高いのは明らかであるが、提案手法を用いることにより、特徴点周りの局所形状が他の特徴点周りの局所形状と類似していない特徴点から順に高い独自性を算出していることを確認した。

提案手法とランダムに特徴点を選択する手法(ランダム法)、曲率の大きな点から順に特徴点を選択する手法(曲率法)を用いて特徴点の分布を比較した。図 7(a), (b) は実験に用いた物体モデル外観と物体モデル各特徴点の独自性を算出した結果である。この物体モデルはレンジセンサで撮影した 0.4mm ピッチの物体モデルであり、算出した法線ベクトルは誤差が含まれている可能性がある。そのためヒストグラムの分解能を 5 度ピッチと粗く設定した。また、局所領域を表現するため半径  $r$  を 2mm とした。図 8(a), (b), (c) は、ランダム法と曲率法、および提案手法によって選択された特徴点の分布であり、それぞれ 30 点の特徴点を選択した例を示す。




図 7 工業部品による独自性算出結果

Fig. 7 Distinctiveness calculation result by the industrial parts.

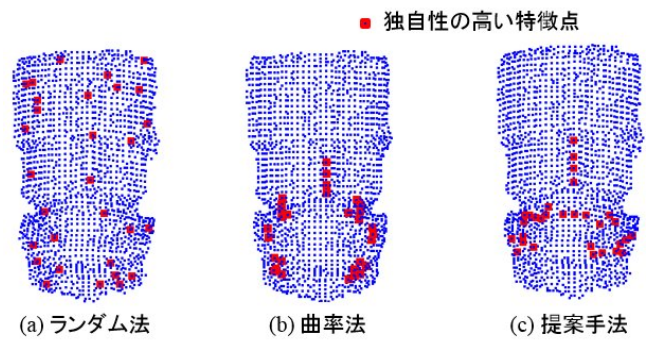


図 8 独自性の高い特徴点の分布

Fig. 8 Distribution of the selected distinctive feature points.

ランダム法によって選択された特徴点は、物体モデルの大部分を占めるなめらかな形状部分の特徴点も選択されていることを確認した。また、曲率法によって選択された特徴点は、曲率の大きさのみを考慮しているため、曲率の大きな窪んだ形状部分の点が特徴点として選択されていることを確認した。曲率の大きな窪んだ形状部分の特徴点は対象物が姿勢変化した場合に、隠れてしまいやすく正しく照合できないと考えられる。しかしながら、提案手法によって選択された特徴点は、物体モデルを特徴づける大きな曲率部が直線的に続く部分の点や中心部の平面的な形状部分の点などが選択されていることを確認した。

## 4.2 認識性能評価実験

### 4.2.1 ばら積み物体に対する認識結果

提案手法の有効性を確認するために、ばら積みされた対象物を用いて下記に示す 4 種類の従来手法と認識性能を比較した。(1) Spin Image 法 [3], (2) Point Cloud Library [13] の認識モジュールに掲載されている Correspondence Grouping 法 [14], (3) ランダム法, (4) 曲率法。各物体がばら積みされたシーンを撮影した入力距離画像の例を図 9 に示す。それぞれ、凹凸の多い物体 A, 同一形状の繰り返しが存在する物体 B, 凹凸の少ない物体 C, 曲率の大きな部分と小さな部分を含む物体 D である。実験には、各物体約 130 枚の距離画像を用いた。なお、処理の高速化を図るため、本研究では表 1 に示すようにあらかじめ物体モデルをダウンサンプリングしたものから独自性の高い特徴点を抽出する。表 2 にランダム法、曲率法、提案手法で選択された特徴点の分布を示す。

表 3 に認識成功率  $P_r$  [%] と処理時間  $T$  [sec], 特徴点数  $N$  [point] を示す。なお、処理の高速化を図るため、特徴点数  $N$  は物体モデルの約 1% から 5% となるように決定した。本研究では、姿勢推定したパラメータを物体モデルに適用し、入力した距離画像と重畳させた時の位置合わせ誤差が 1.5mm 以内の場合に認識成功とした。図 10(a), (c), (e), (g) は入力シーンの画像外観であり、図 10(b), (d), (f), (h) に認識結果の位置姿勢パラメータを適用した物体




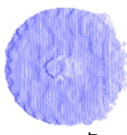
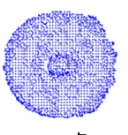

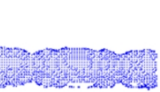

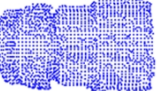


図 9 距離画像データベース  
Fig. 9 Range image database.

表 1 物体モデルとダウンサンプリング結果

Table 1 Object model and down sampling results

	ダウンサンプリング 前のモデル点数	ダウンサンプリング 後のモデル点数
物体A	 7026点	 1374点
物体B	 10398点	 2023点
物体C	 8284点	 1659点
物体D	 8508点	 1757点

モデルを入力シーンに重畳した結果を示す。実験は CPU : Intel®CORE™i7-3.40GHz, システムメモリ : 8GB で構成されるシステムでおこなった。

#### 4.2.2 従来手法との認識性能比較と考察

提案手法は、従来の Spin Image 法に対して、物体モデルの 1% から 5% 程度のごく少数の特徴点数で、4 種類の A から D の物体に対する平均認識成功率が、51.6% から

表 2 各手法による独自性の高い特徴点の抽出結果

Table 2 Extraction results of distinctive feature points by each method.

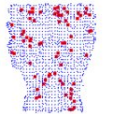
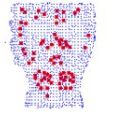
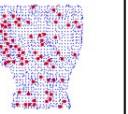
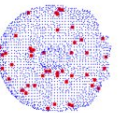
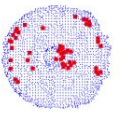

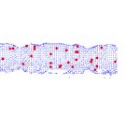
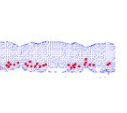
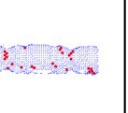
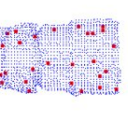
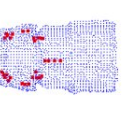
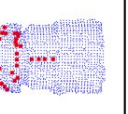
	ランダム法	曲率法	提案手法
物体A (特徴点70点)			
物体B (特徴点50点)			
物体C (特徴点30点)			
物体D (特徴点30点)			

表 3 認識成功率と処理時間

Table 3 Recognition success rate and processing time.

		物体 A	物体 B	物体 C	物体 D	平均
Spin	$P_r$	49.6	50.8	35.2	70.6	51.6
	$T$	24.95	55.34	31.21	20.68	33.05
Image 法 [3]	$P_r$	74.4	96.2	65.6	84.9	80.3
	$T$	45.41	52.85	29.26	26.10	38.41
ランダム法	$N$	70	50	30	30	-
	$P_r$	89.1	96.9	85.2	69.8	85.3
	$T$	5.87	4.77	2.06	1.74	3.61
曲率法	$N$	70	50	30	30	-
	$P_r$	86.8	76.9	18.0	54.8	59.1
	$T$	6.01	4.94	2.21	1.97	3.78
提案手法	$N$	70	50	30	30	-
	$P_r$	89.1	97.7	94.5	93.7	93.8
	$T$	5.83	4.76	2.05	1.76	3.60

93.8%に向上したことを確認した。処理時間に関しては約 9 倍以上の高速化となった。Spin Image 法は物体モデル全点を用いて照合しているのに対し、提案手法は独自性の高い、ごく少数の厳選された特徴点のみを照合に用いていることがその要因である。また、Spin Image 法は注目点の法線ベクトル方向と、それに直交する軸を基準とした 2 次元空間に物体モデル点の相対的な位置を投票した画像を照合に用いる手法である。そのため注目点から遠い点ほど法線ベクトルの揺らぎに敏感であり、安定した特徴記述ができず、認識成功率が低かった。提案手法も法線ベクトルを使用しているが、点群を利用した法線ベクトル同士のなす






図 10 認識結果例

Fig. 10 Example recognition results.

角度を軸としたヒストグラムで表現しているため、法線ベクトルに多少の揺らぎがある場合にも安定した特徴記述ができた。また、Spin Image 法は入力距離画像からランダムに点を選択して、Spin Image を作成し物体モデル全点と照合する。ランダムに選択した点が物体モデル内の同じ点と対応していなければ正しく照合することができない。そのことも認識成功率が低かった理由の一つである。Correspondence Grouping 法の認識成功率が低かった理由としては、モデル点をダウンサンプルした時の点を認識に用いていることが原因である。また、正しい姿勢パラメータを算出するには半径の大きな Reference Frame を作成する必要があり、その処理に時間がかかっている。ランダム法が提案手法より認識成功率が低かった理由としては、特徴点をランダムに選択しているため物体モデル内で同じよ

うな形状部分を保持する特徴点を選択されており、入力距離画像との照合の際に誤照合が増加したためである。曲率法に関しては、曲率の大きな点のみを特徴点として選択しているため、入力距離画像中に曲率の大きな点が多く存在する場合に認識成功率が低下した。また曲率法で選択した特徴点は窪んだ曲率部の点も選択しているため、入力距離画像中の対象物の姿勢によっては対応点が隠れてしまう。そのため認識成功率が低かった。

以上より、Spin Image 法、PCL の Correspondence Grouping 法、ランダム法、曲率法に対して、提案手法は平均認識成功率が向上し、処理時間に関しても同等以上であることを確認した。また、提案手法はどのような形状の対象物に対しても安定した認識成功率を実現していることを確認した。

なお、図 11 に認識に失敗した例を示す。本研究では、姿勢パラメータを適用した物体モデルと入力距離画像との誤差を計算し、一番小さい誤差の位置姿勢パラメータを認識結果としている。図 11 のような平面的な物体の場合では、姿勢変換したモデルが 2 つの対象物上に重畳された場合でも、位置合わせ誤差が小さくなり、それが原因で認識に失敗した。この問題に対しては、認識に用いる特徴点数やパラメータを調整することで改善されると考えられる。





図 11 認識失敗例


Fig. 11 Recognition failure cases.

#### 4.2.3 姿勢推定の精度評価

本研究では、位置姿勢推定後の物体モデルに ICP アルゴリズム [15] を適用することにより、位置合わせの精度向上を図った。図 12 に ICP アルゴリズム適用前と適用後の物体モデルを示す。図 12(a) は微小の位置ずれを起こしているのに対して、ICP 適用後の図 12(b) は位置ずれなしで位置合わせできていることを確認した。また図 13 に ICP アルゴリズム適用前と適用後の位置合わせ誤差の平均を示す。実際に実験に用いたレンジセンサの分解能は約 0.40mm である。ICP アルゴリズム適用前の位置合わせ誤差は約 0.82[mm/point] であったのに対し、適用後は約 0.51[mm/point] であった。この結果はレンジセンサの分解能と同等であることから、精度よく位置合わせできたことを確認した。



(a) ICPアルゴリズム適用前



(b) ICPアルゴリズム適用後

図 12 ICP アルゴリズム適用結果

Fig. 12 Before and after of accurate alignment by the ICP.

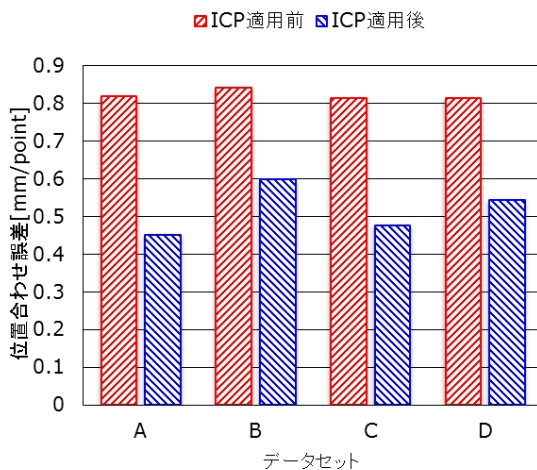


図 13 4 種類の物体に対する位置合わせ誤差

Fig. 13 Average alignment error of four data sets.

## 5. おわりに

本研究では、物体モデルの局所形状に着目することで、照合に有効な独自性の高いごく少数の特徴点を抽出する手法を提案し、高信頼性と高速性を両立する物体認識システムを構築した。提案手法は、従来手法である Spin Image 法に対し、認識成功率が 51.6% から 93.8% に向上し、約 9 倍以上の処理の高速化を実現した。また、PCL の Correspondence Grouping 法に対しても 10 倍の処理速度で認識成功率が 13.5% 向上したことを確認した。ランダム法、曲率法に対しても認識成功率が向上し、提案手法によって抽出した独自性の高い特徴点が認識に有効であることを確認した。提

案手法の後段処理に ICP アルゴリズムを適用することで位置合わせ平均誤差が約 0.51 [mm/point] で位置合わせでき、レンジセンサの分解能が 0.40mm であることを考慮すると高精度で位置合わせできていることを確認した。

今後は、さらなる処理の高速化、各種パラメータの最適化、提案手法を実装したピンピッキングシステムを構築する予定である。

## 参考文献

- [1] 村瀬洋, シュリーナイヤー: 2 次元照合による 3 次元物体認識-パラメトリック固有空間法-, 信学論 (D-II), Vol.J77-D-II, No.11, pp.2179-2187 (1994).
- [2] 吉井裕人, 奥野泰弘, 御手洗裕輔, 猿田貴之, 森克彦, 真継優和: アンサンブル分類木を用いたバラ積み部品の概略位置姿勢検出, 画像の認識・理解シンポジウム (MIRU), IS2-4, pp.778-785 (2010).
- [3] Johnson E. A and Hebert M.: Using Spin Images for Efficient Object Recognition in Cluttered 3D Scenes, Trans. IEEE Pattern Analysis and Machine Intelligence, Vol.21, No.5, pp.433-449 (1999).
- [4] Frome A., Huber D., Kolluri R., Bulow T., Malik J.: Recognizing Object in Range Data Using Regional Point Descriptors, European Conference on Computer Vision, Vol.3023, pp.224-237 (2004).
- [5] Dorai C. and Jain K.A.: COSMOS-A Representation Scheme for 3D Free-form Objects, Trans. IEEE Pattern Analysis and Machine Intelligence, Vol.19, No.10, pp.1115-1130 (1997).
- [6] Chen H. and Bhanu B.: 3D Free-form Object Recognition in Range Images Using Local Surface Patches, Pattern Recognition Letters, Vol.28, pp.1252-1262 (2007).
- [7] 武口智行, 金子俊一: 距離アスペクト画像照合による高効率なロバスト探索, 電学論 (C), Vol.124, No.3, pp.637-646 (2004).
- [8] 北明靖雄, 奥田晴久, 橋本学, 金子俊一: 距離アスペクト画像照合と階層化 ICP 照合による 3 次元物体認識, 電学論 (C), Vol.127, No.4, pp.615-622 (2007).
- [9] 角保志, 富田文明: ステレオビジョンによる 3 次元物体の認識, 信学論 (D-II), Vol.J80-D-II, No.5, pp.1105-1112 (1997).
- [10] Steder B., Rusu B.R, Konolige K. and Burgard W.: Point Feature Extraction on 3D Range Scans Taking into Account Object Boundaries, IEEE International Conference on Robotics and Automation, pp.2601-2608 (2011).
- [11] Tombari F., Salti S. and Stefano D.L.: Unique Signatures of Histograms for Local Surface Description, European Conference on Computer Vision, Vol.6313, pp.356-369 (2010).
- [12] Tombari F., Salti S. and Stefano D.L.: A Combined Texture-Shape Descriptor for Enhanced 3D Feature Matching, IEEE International Conference on Image Processing, pp.809-812 (2011).
- [13] Rusu B.R. and Cousins S.: 3D is here: Point Cloud Library (PCL), IEEE International Conference on Robotics and Automation, pp.1-4 (2011).
- [14] Tombari F. and Stefano D.L.: Object Recognition in 3D Scenes with Occlusions and Clutter by Hough Voting, IEEE Proc. on 4th Pacific-Rim Symposium on Image and Video Technology, pp.349-355 (2010).
- [15] Besl J.P. and McKay D.N.: A Method for Registration of 3-D Shapes, Vol14, No.2, pp.239-256 (1992).