

ベクトルペアマッチングによる高信頼な3次元位置姿勢認識

秋月 秀一

中京大学大学院 情報科学研究科

E-mail: {akizuki}@isl.sist.chukyo-u.ac.jp

Abstract

ばら積みされた工業部品を高信頼に認識する手法を提案する。提案手法はCAD等で作成されたサーフェスモデルを対象としたモデルベース照合手法であり、一つの始点と二つの終点からなる3-Dベクトルペア群を用いて位置姿勢を認識する。このとき、物体モデルの局所形状を事前分析することによって誤照合のリスクの低いベクトルペアを選択する。物体モデル中で含有率(発生確率)の低い局所物理形状は入力シーンにおいても同様に発生確率が低いと考えられる。このような局所物理形状に対応するベクトルペアを選択することで高信頼な認識を実現する。提案手法は4種類の物体に対して、従来のSpin Image法、Correspondence Grouping法に対して認識成功率が平均で約46.1%、17.4%向上し、97.6%を達成した。また、姿勢認識の後段処理にICPアルゴリズムを追加することで平均誤差[0.6mm/point]での照合を実現した。

1 はじめに

多品種を扱うピンピッキングロボットのビジョンシステムにおいて、扱う物体の登録の容易さはリードタイム短縮に関わる重要な要素である。これにはCAD等で作成されるサーフェスモデルを登録し、照合に利用することが考えられる。このアプローチはモデルベースマッチングと呼ばれ、モデルデータを幾何変換し、シーンデータと直接照合をおこなうことで位置姿勢を認識する。

この手法には、物体モデルから視点の変化に不変な局所特徴量を作成し、照合に用いるアプローチ[1][2]がある。これらの手法の多くは不変量として物体モデルのデータ点、またはパッチ間の距離、法線方向、Shape Index値[3]を利用して特徴記述をおこなう。さらに、曲率の大きな形状の代表点を特徴点とし、特徴点のみから特徴記述することで照合を高速化する手法[4][5]もある。また、近年では局所領域内の3次元点群の法線方向分布を記述したSHOT特徴量[6]を用いた投票型照合手法[7]が提案された。

これらの局所特徴量は特徴量としてのアイデンティティを高めるために、一定範囲の記述領域を設定している。このため、少数の特徴点数のみでの照合が可能であるが、物体同士が密に接触するばら積みシーンにおいては、特徴量の記述範囲に物体の接触に起因した外乱データを多く含みやすいため、照合性能の低下が懸念される。

この問題に対して、法線方向を持った点对特徴であるPoint Pair Feature (PPF)を用いた手法[8][9][10]が提案された。PPFは法線方向と点对の位置関係のみで記述された特徴量であるため、一定範囲の記述領域を必要とせず、物体同士の接触による照合性能の低下の影響を受けにくい利点があるが、照合には大量のPPFを用いる必要がある。このため、文献[8]ではハッシングにより認識を効率化しており、文献[9]ではPPFに新たな属性としてVisibility Contextを加えることで、PPFのアイデンティティを高め、PPF間照合の誤対応を低減している。さらに、文献[10]の手法では点对のペアリングを稜線同士や稜線と面との組合せに限定することで認識性能を向上させた。しかしながら、いずれの手法も安定した照合のためには多くのPPFが必要であり、処理コストが高い。

以上のように従来手法ではばら積みシーンに対する照合の高信頼性と低い処理コストの両立は十分でなかった。そこで本研究では、高信頼な位置姿勢認識を少ない処理コストで実現する手法の提案を目的とする。

3点の3次元点の組は位置姿勢決定のための最小単位であることから、3点の3次元特徴点を一つの始点と二つの終点からなる3-Dベクトルペアとして記述し、認識に用いる。これを少数のみ照合に用いることで処理コストの問題を解決する。このとき、誤照合を引き起こしにくいベクトルペアを選択することで認識を高信頼化する。これには物体モデルの局所物理形状の発生確率に基づいて特徴点を選択するアイデアを導入する。物体モデルにおいて含有率(発生確率)の低い局所物理形状は入力シーンにおいても同様に発生確率が低い。このような物理形状に対応する特徴量は誤認識のリスクが低いと考えられる。このため、照合に用いる特徴的ベクトルペアを物体モデルにおいて発生確率の低い局所物理形状の代表点からのみ選択することで、認識の

高速化と高信頼化を両立する。認識時には、物体モデルと入力シーン間の対応点が検出される度に姿勢仮説を生成するため、部分的なオクルージョンにも対応可能である。さらに、認識した位置姿勢をICPアルゴリズム [11] によって修正することで高精度な位置姿勢推定を実現する。

提案手法では、物体モデルとしてCAD等で作成されたサーフェスモデルを利用するので物体の登録が容易な位置姿勢認識システムが実現する。

以下、第2章は3-Dベクトルペアを用いた位置姿勢認識手法について説明し、第3章でサーフェスモデルと距離データの両方を物体モデルとした場合の認識実験結果を述べ、第4章で本研究の成果をまとめる。

2 提案手法

提案手法はサーフェスモデルの離散点群化、離散点群からの特徴的ベクトルペア選択、特徴的ベクトルペアによる位置姿勢認識の3つのモジュールで構成される。本章では提案手法で用いる3-Dベクトルペアの構成を説明した後に各モジュールに関して説明する。

2.1 3-D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3つの3次元点が必要であり、これを一つの始点と二つの終点からなる3-Dベクトルペアとして表現する。提案手法では3-Dベクトルペアが照合の単位である。図1に3-Dベクトルペアの構成を示す。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_{q1} , l_{q2} であり、この間の角度を θ で表す。さらに、3つの端点に形状評価値 s_p , s_{q1} , s_{q2} を持っており、これが3-Dベクトルペアの特徴量である。




図1 3-Dベクトルペア

2.2 サーフェスモデルの離散点群化

レンジファインダで撮影された離散的な3次元点群を模擬するために、CAD等で作成された3角パッチで構成されるサーフェスモデルを離散点群化する。サーフェスモデルの全てのパッチに対して式(1)を満たす3次元点 \mathbf{x} をランダムに発生させる。発生させる3次元点の数はパッチの面積に応じて、離散点群の密度が一定になるように設定する。

$$\mathbf{x} = \alpha\mathbf{a} + \beta\mathbf{b} + \gamma\mathbf{c} \quad (1)$$

\mathbf{a} , \mathbf{b} , \mathbf{c} は3角パッチの各頂点の位置ベクトルを示す。 α , β , γ は重みパラメータであり $\alpha + \beta + \gamma = 1$ を満たすようにランダムに決定される。図2に物体のサーフェスモデルと離散点群化の結果を示す。




図2 サーフェスモデルと離散点群化の結果

2.3 特徴的ベクトルペアの選択

離散点群化した3次元物体モデルから特徴的ベクトルペアを選択する手法を説明する。概要を図3に示す。

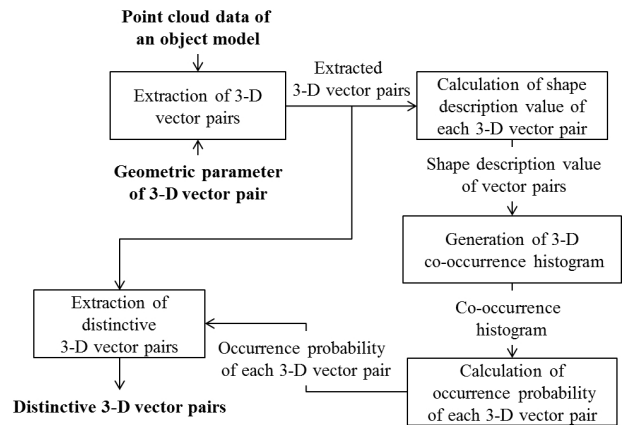


図3 特徴的ベクトルペア選択モジュール

まず、計算の高速化のために離散点群に前処理としてダウンサンプリングをおこなう。また、平面上に存在する点は高精度な位置姿勢推定に不適と考えられるため削除しておく。次に離散点群に対して、式(2)を満たす3つの3次元点をベクトルペア $\{\mathbf{v}_n | 0, \dots, N-1\}$ として抽出する。 l_1 , l_2 , θ は抽出するベクトルペアを規定するパラメータであり、 th_θ , th_l はしきい値である。

$$\begin{cases} |\mathbf{d}_{q1} \cdot \mathbf{d}_{q2} - \theta| \leq th_\theta \\ |l_{q1} - l_1|, |l_{q2} - l_2| \leq th_l \end{cases} \quad (2)$$

さらに、全てのベクトルペアの P , Q_1 , Q_2 における形状評価値 s_p , s_{q1} , s_{q2} を式(3)によって算出する。

$$s_p = \mathbf{n} \cdot \mathbf{n}_p, s_{q1} = \mathbf{n} \cdot \mathbf{n}_{q1}, s_{q2} = \mathbf{n} \cdot \mathbf{n}_{q2}$$

$$\text{where, } \mathbf{n} = \mathbf{d}_{q1} \times \mathbf{d}_{q2} / \|\mathbf{d}_{q1} \mathbf{d}_{q2}\| \quad (3)$$

このとき、 \mathbf{n}_p , \mathbf{n}_{q1} , \mathbf{n}_{q2} は各点の法線ベクトルである。そして、式 (4)(5) を適用することで形状評価値 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。図 4 に 3 次元共起ヒストグラムの生成の様子を示す。

$$h(s_p, s_{q1}, s_{q2}) = \sum_{n=0}^{N-1} \delta(\mathbf{v}_n) \quad (4)$$

$$\begin{cases} \delta = 1 & \text{when } \{\mathbf{v}_n(s_p) = s_p\} \cap \{\mathbf{v}_n(s_{q1}) = s_{q1}\} \\ & \cap \{\mathbf{v}_n(s_{q2}) = s_{q2}\} \\ \delta = 0 & \text{otherwise} \end{cases} \quad (5)$$

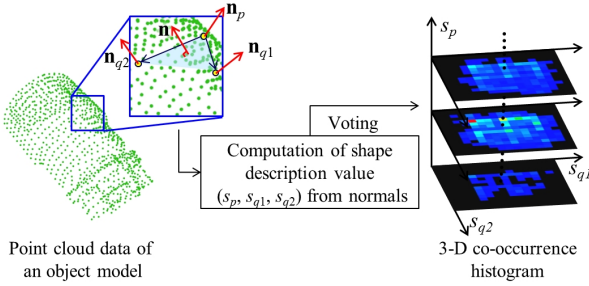


図 4 3 次元共起ヒストグラム生成の様子

この共起ヒストグラムは 3 次元であるが、便宜上図 4 では特定の s_p による 2 次元共起ヒストグラムの重なりにして表示した。また、各ヒストグラムは得票数の少ないものから順に青～緑～赤で色付けしてある。

さらに、共起ヒストグラムの総和が 1 になるように式 (6) 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。 L は共起ヒストグラムの階調数を示す。 $Ph(s_p, s_{q1}, s_{q2})$ は形状評価値 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。

$$Ph(s_p, s_{q1}, s_{q2}) = \frac{h(s_p, s_{q1}, s_{q2})}{\sum_{s_p=0}^{L-1} \sum_{s_{q1}=0}^{L-1} \sum_{s_{q2}=0}^{L-1} h(s_p, s_{q1}, s_{q2})} \quad (6)$$

最後にベクトルペアを発生確率 Ph で昇順に並び替え、発生確率の低い複数のベクトルペアを特徴的ベクトルペア群として認識に用いる。

2.4 特徴的ベクトルペア群による位置姿勢認識

選択した特徴的ベクトルペア群を用いた物体の位置姿勢認識手法を説明する。概要を図 5 に示す。

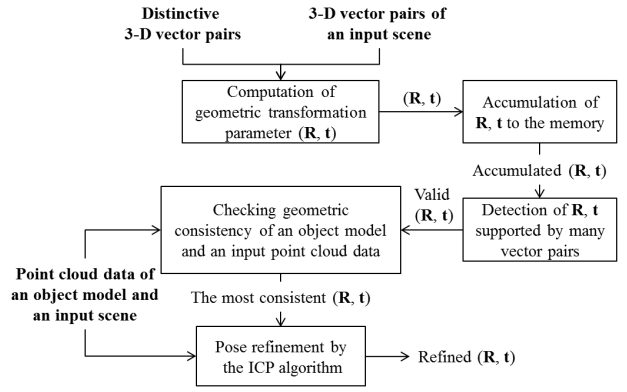


図 5 位置姿勢認識モジュール

まず、レンジファインダから得られた入力離散点群に対して、物体モデルと同様に前処理としてダウンサンプリング、平面除去をおこなう。つぎに、特徴的ベクトルペア群の幾何学的パラメータ l_{q1} , l_{q2} , θ を満たす全てのベクトルペアを入力離散点群から抽出する。そして、抽出されたベクトルペアと特徴的ベクトルペアの類似度を、形状評価値 s_p , s_{q1} , s_{q2} を特徴ベクトルとしたベクトル間の内積値として計算する。類似度の高いベクトルペア同士を位置合わせする姿勢変換パラメータ (\mathbf{R}, \mathbf{t}) を算出し、各姿勢変換パラメータをメモリに記録しておく。この際、姿勢変換パラメータごとにそれを支持するベクトルペアの数も記録しておく。多くの支持を集めた姿勢変換パラメータは対象物が存在する可能性が高い。そこで、支持されたベクトルペア数を横軸、その支持数をもつ姿勢変換パラメータ数を縦軸とした頻度分布を作成し、上位 0.3% の支持数を持つ姿勢変換パラメータを抽出する。これらについて式 (7) を用いて物体モデルと入力離散点群間の整合性を確認することで、最も高い整合性を示す姿勢変換パラメータを決定する。

$$C = \arg \min_{(\mathbf{R}, \mathbf{t})} \left\{ \frac{1}{M} \sum_{m=0}^M \|\mathbf{R} \mathbf{p}_m + \mathbf{t} - \mathbf{q}\| \right\} \quad (7)$$

M は計算に用いた物体モデルの点である。 \mathbf{p}_m は物体モデルの m 番目の点であり、 \mathbf{q} は \mathbf{p}_m の最近傍点である。このとき、計算の高速化のために M は物体モデル全体の 10% 程度に削減しておく。また、姿勢変換した物体モデルの裏側に属する点は入力離散点群では観測されない点であるため、削除した上で整合性を測る。

最後に位置姿勢の推定精度を向上させるために、物体モデルと入力離散点群間の整合性が最も高かった姿勢仮説を初期値として ICP アルゴリズム [11] を適用する。

3 実験結果と考察

3.1 ベクトルペアを規定するパラメータと認識性能の関係

ベクトルペアを規定するパラメータと認識性能の関係を明らかにするために、 l_{q1} , l_{q2} を変化させながら認識をおこなった。実験に用いたモデルデータは図2のサーフェスモデルであり、レンジファインダで実物体を撮影した距離データに対して認識をおこなった。実験に用いた距離データは140例である。姿勢推定精度に等方性を持たせるために $\theta = 90[\text{deg}]$ とし、ベクトルペア数は80とした。結果を図6に示す。図中の横軸は l_{q1} , l_{q2} の長さを示し、縦軸は認識結果の物体モデルと入力距離データとの位置合わせ誤差の平均値である。





図6 l_{q1} , l_{q2} と認識精度の関係

l_{q1} , l_{q2} が短いときは位置合わせ誤差が大きく、長くなるにつれて位置合わせ誤差が小さくなる傾向があった。しかしながら、27mmを越えると位置合わせ誤差が大きくなった。図7に誤差の大きかったパラメータのベクトルペアと誤差の小さかったパラメータのベクトルペアの例を示す。

図7(a)に示すベクトルペアは物体の上端部分と下端部分を同時に選択している。ベクトルペアを構成する点間の距離が大きくなりすぎたことに起因して、全て点が同時に観測しにくくなったことが精度低下の原因と考えられる。このため、 l_{q1} , l_{q2} は3点が同時に観測される範囲で大きい値に設定することで信頼性の高い照合が実現することが分かった。最も誤差の少なかったパラメータは図7(b)に示す $l_{q1} = 24[\text{mm}]$, $l_{q2} = 15[\text{mm}]$ であり、位置合わせ誤差平均値は $1.22[\text{mm/point}]$ であった。この時の認識成功率は90.7%であり、処理時間は約3.48[sec]であった。また、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



(a) $l_1 = 30[\text{mm}]$, $l_2 = 30[\text{mm}]$

(b) $l_1 = 24[\text{mm}]$, $l_2 = 15[\text{mm}]$

図7 位置合わせ誤差の大きかったパラメータのベクトルペア (a) と誤差の少なかったパラメータのベクトルペア (b) の例

た。このときの認識結果例を図8に示す。白点は入力距離データを示し、色つきの点を用いて物体モデルを認識結果の幾何変換パラメータに基づいて姿勢変換させて入力距離データに重ね合わせている。




図8 認識結果例

3.2 距離データを用いた認識性能評価実験

サーフェスモデルが用意されていない物体に対しては、レンジファインダを用いてモデルデータを生成する。本節ではこの方法で取得した物体モデルを用いて認識実験をおこなった。実験には図9に示す4種類の物体を用意し、距離データを約 130×4 セット用意した。




図9 4種類のばら積み物体

図10に提案手法によって選択されたベクトルペア群を示す。多くのベクトルペアは物体内でも曲率の大きな部分に選択されていることがわかる。一方で、いくつかのベクトルペアは図10(a)のように小さい曲率部にも選択された。これは本手法が曲率値をもとにベクトルペアを選択しているのではなく、あくまでその発生頻度をもとにしていることを示している。認識実験には比較手法としてSpin Image法[1], Point Cloud Library[12]

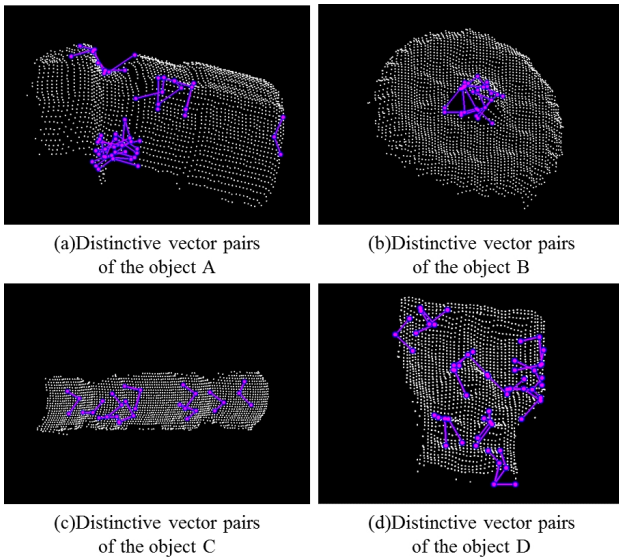


図 10 4 種類の物体における選択された特徴的ベクトルペア

の認識モジュールである Correspondence Grouping 法 [7] を用いた。表 1 に各手法の認識成功率 Pr [%] と処理時間 T [sec] を示す。 N は認識に用いたベクトルペア数である。認識は物体モデルと入力距離データを重ね合わせた際の位置ずれ誤差平均値が 1.5mm 以内の時に成功とした。図 11 に提案手法による各物体の認識例を示す。

表 1 4 種類の物体の認識結果

		A	B	C	D
Spin Image[1]	Pr	70.6	50.8	35.2	49.6
	T	20.68	55.34	31.21	24.95
Correspondence Grouping[6][12]	Pr	84.9	96.2	65.6	74.4
	T	26.10	52.85	29.26	45.41
	N	20	10	10	20
Proposed method	Pr	95.2	100.0	100.0	95.3
	T	0.95	3.17	5.12	2.64

物体 A は提案手法による高速化が最も顕著であった。物体 A は曲率の大きさのバリエーションに富んだ物体である。このため、他の物体に比べて相対的に低い発生確率のベクトルペアを認識に用いることができ、ベクトルペア当たりの入力距離データにおける対応点数を削減された。結果として、高速な処理時間を達成することができた。

物体 B と C は単純形状の繰り返しによって構成される物体であり、ベクトルペアの発生確率が単調である。このため、他の物体に比べて発生確率の低いベクトルペア数が減り、独自性の高いベクトルペアを選択できなかった。このため、認識時には各ベクトルペアと入力距離データとの対応点数が増え、処理時間が増加した。しかし、ベクトルペア間の正しい対応の見逃しが減り、高い認識成功率を記録した。物体 D は平面的な




図 11 提案手法による認識結果例

形状の対象物である。この物体に対しても高い認識率を達成することができた。

従来手法との比較に関しては、Spin Image 法は物体モデルの全点を認識に用いる。提案手法はごく少数の点数のみで照合をおこなうため、Spin Image 法に対して約 11 倍高速認識することができた。また、Correspondence Grouping 法は物体境界において特徴記述範囲に他物体との接触による外乱を含みやすいため、入力距離データにおける特徴量の再現性が悪く、誤認識を誘発した。

図 12 に、本実験における典型的な認識失敗例を示す。物体モデルが平面的なため、物体モデルをばら積みしたときの入力距離データも平面的であった。このため、位置姿勢が正しくないときも物体モデルと入力距離データの幾何学的整合性が高くなってしまったことが原因である。この問題に対しては、整合性を測る際に、物体モデルと入力距離データの法線方向の類似性も用いることで誤認識は解消されると考えられる。




図 12 誤認識例

提案手法は曲率変化に富んだ物体に対して大きく高速化できた。また、どのような形状の物体に対しても安定して高信頼に照合可能であった。

3.3 認識位置姿勢の精度評価

本研究では、推定後の位置姿勢に対して ICP アルゴリズム [11] を適用することにより、位置姿勢の推定精度の向上を図った。図 13 に ICP アルゴリズム適用前の距離データと適用後の距離データを示す。また、図 14 に ICP 適用前と適用後の位置合わせ誤差の平均値を示す。青は提案手法による誤差平均値であり、赤は ICP アルゴリズムの適用後の誤差平均値を示す。実験に用いた距離データの分解能は約 0.4mm である。ICP 前は重ね合わせ誤差が 0.84[mm/point] であったのに対し、ICP 後は 0.6[mm/point] である。この結果は距離データの分解能とほぼ同等であるため、精度よく位置合わせできたことがわかる。




図 13 ICP 適用前と適用後の距離データ




図 14 4 種類の物体に対する位置合わせ誤差

4 おわりに

物体モデルの登録の容易なピンピッキングシステムの開発を目的に、CAD 等で作成された物体モデルを適用可能な認識手法を提案した。提案手法はサーフェスモデルを離散点群化し、点群中で発生確率の低い形状評価値をもつ独自性の高い特徴点を認識に用いる。提案手法は従来の Spin Image 法、Correspondence Grouping 法に対して認識成功率が平均で約 46.1%、17.4%向上した。また、提案手法の位置姿勢認識の後段処理として ICP アルゴリズムを加えることで、平均誤差約 0.6[mm/point] で位置合わせ可能なことを確認した。

参考文献

- [1] A. E. Johnson and M. Hebert, “Using Spin Images for Efficient Object Recognition in Cluttered 3D Scenes,” IEEE Pattern Analysis and Machine Intelligence, vol. 21, no. 5, pp.433–449, 1999.
- [2] G. Hetzel, B. Leibe, P. Levi and B. Schiele, “3D Object Recognition from Range Images using Local Feature Histograms” IEEE Computer Vision and Pattern Recognition, vol.2, pp.394–399, 2001.
- [3] C. Dorai and A. K. Jain, “COSMOS-A Representation Scheme for 3D Free-Form Objects,” IEEE Pattern Analysis and Machine Intelligence, vol.19, no.10, pp.1115–1130, 1997.
- [4] 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.
- [5] H. Chen and B. Bhanu, “3D Free-form Object Recognition in Range Images using Local Surface Patches,” Pattern Recognition Letters, vol.28, pp.1252–1262, 2007.
- [6] F. Tombari, S. Salti and L. D. Stefano, “Unique Signatures of Histograms for Local Surface Description,” European Conference on Computer Vision, pp.356–369, 2010.
- [7] F. Tombari and L. D. Stefano, “Hough Voting for 3D Object Recognition under Occlusion and Clutter,” IPSJ Computer Vision and Applications, vol.4, pp.1–10, 2012.
- [8] B. Drost, M. Ulrich, N. Navab and S. Ilic, “Model Globally, Match Locally: Efficient and Robust 3D Object Recognition,” IEEE Computer Vision and Pattern Recognition, pp.998–1005, 2010.
- [9] E. Kim and G. Medioni, “3D Object Recognition in Range Images using Visibility Context,” IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.3800–3807, 2011.
- [10] C. Choi, Y. Taguchi, O. Tuzel, M. Liu, and S. Ramalingam, “Voting-Based Pose Estimation for Robotic Assembly Using a 3D Sensor,” IEEE International Conference on Robotics and Automation, pp.1724–1731, 2012.
- [11] P. J. Besl and N. D. McKay, “A Method for Registration of 3-D Shapes,” IEEE Pattern Analysis and Machine Intelligence, vol.14, pp.239–256, 1992.
- [12] R. B. Rusu and S. Cousins, “3D is Here: Point Cloud Library (PCL),” IEEE International Conference on Robotics and Automation, pp.1–4, 2011.