

# 距離データハンドリングのための3次元特徴量

橋本 学

Manabu HASHIMOTO

中京大学 大学院 情報科学研究科      mana@isl.sist.chukyo-u.ac.jp

<要約> 近年、3次元データを取得するためのデバイスや手法の研究が注目されていることから、距離データをハンドリングするアルゴリズムもめざましい進展を遂げている。物体認識、なかでも産業用途を想定した対象物体の検出や位置姿勢同定技術は、国内外の展示会等でも出展が増加しており、産業界からのニーズは着実に増加している。本稿では、3次元特徴量ベースの手法（キーポイントベース手法）を中心とする物体認識技術の変遷を概観するとともに、これまでに研究されてきた主要な3次元特徴量を整理する。また、特徴量の記述と位置姿勢パラメータ推定において重要な意味を持つLRF（Local Reference Frame）に関して考察し、筆者らによる最近の研究事例を紹介する。また、モデルの精緻化と裏腹に、実際の応用現場で起こりがちな「粗なポイントクラウドデータ」の認識に対する有効な特徴量についても、最新の成果を紹介する。  
<キーワード> 物体認識, 距離データ, ポイントクラウドデータ, 3次元特徴量, ロボットビジョン

## 1. はじめに

近年、工場の生産ラインなどの実工業現場では、3次元物体認識技術の進展がめざましい。製造物のハンドリングはもとより、移動ロボットの目標追尾、障害物発見、さらに近年では自動走行車における周辺認識など幅広い応用分野に注目が集まっている。

特に、製造業での活用を目的としたいわゆるマシンビジョンの分野では、最近の3Dプリンタの急速な普及にとまなう3次元モデルの利用拡大が後押しし、3次元モデルを前提とした手法、すなわちモデルベースの物体認識技術が再び注目を集めている。

本稿では、この技術の中核をなすものとして、距離データハンドリングのための3次元特徴量について論じる。まず最初に、マシンビジョンとしての3次元物体認識技術について、粗い認識（物体検出）と精密な認識（位置姿勢の高精度化）、キーポイントベースと非キーポイントベースなど、いくつかの観点で主要な技術開発の変遷を概観する。また、特に近年注目されているキーポイントベース認識における3次元特徴量に関しては、キーポイントの生成原理や利用情報のあり方をもとに主要技術を分類し、各カテゴリを代表する技術については、その内容を簡単に紹介する。さらに、特徴量の算出と位置姿勢推定で重要な意味を持つ局所的な参照座標系

(LRF: Local Reference Frame) の意味と動向についても触れる。

最後に、3次元特徴量および参照座標系の設計や改良に関して、最近筆者の研究室にて取り組んでいる研究事例を紹介する。特に、モデルの精緻化と裏腹に、実際の応用現場で起こりがちな「粗なポイントクラウドデータ」への対応手段としての特徴量についても、最新の研究成果を紹介する。

## 2. 3次元物体認識の分類と主な研究例

### 2.1 マシンビジョンと3次元物体認識

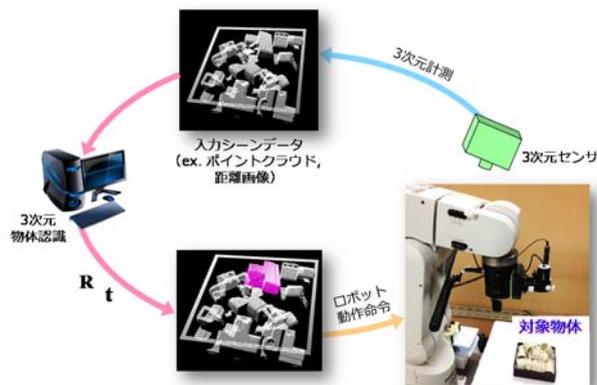


図 1. 3次元ビンピッキングシステムの一例

マシンビジョンのための物体認識の代表的なアプリケーションは、図1に示すような、いわゆるピンピッキング、すなわち、ばら積みされた対象物体それぞれの位置と姿勢を認識し、ロボットハンドによって把持(ピンピッキング)するタスクである。

これは、例えばベルトコンベヤ上の物体の移載や仕分けのようにロボットによるつかみ上げを主目的とする Pick and Place タスクと、その後、さらにつかみ上げた部品を別の部品と精密に組み合わせる(挿入)等をおこなう Pick and Insert タスクに分けることができる。当然ながら後者のほうが難度が高く、ハンドの把持位置の制御や、把持後の動作に関しても、より高精度な動作が求められる。

## 2.2 物体検出と精密位置合わせ

3次元物体認識技術も、これらの動作タスクに関連づけられる。すなわち、未知の入力シーンを撮影したデータから、把持対象物体の大まかな検出と位置・姿勢パラメータを決定する「物体検出」と、それを用いてさらに検出精度(モデルと入力データにおける位置姿勢パラメータの精度)の高い認識を実現する「精密位置合わせ」の2つに分けることがで

きる。

まず後者の精密位置合わせとしては、3次元モデルと入力データにおいて対応付け誤差の最小化をおこなう ICP (Iterative Closest Point) 手法 [Besl1992] と、その発展手法 [Granger2002] [Ghetverikov2002] [ZinBer2003] [Kaneko2003] [Fitzgibbon2003] [Phillips2007] [Nuchter2007] がよく用いられている。入力データとしては、一般的には、レンジファインダから得られる距離画像や、3次元点群(ポイントクラウドデータ)が利用されるが、同軸あるいはそれに近い視点からの濃淡またはカラー画像が得られる場合には、これらを統合的に利用する手法もある [Tateno2010]。この技術は、特に Pick and Insert を実現するためには必須の技術であり、レンジファインダのハード的な高精度化と並行して研究が続いている。

一方、物体検出は、Pick and Insert のみならず Pick and Place にも必要なタスクであり、シーン理解という観点からは移動ロボットにも適用できるなど、汎用性が高いことから、こちらの研究例のほうが多い。

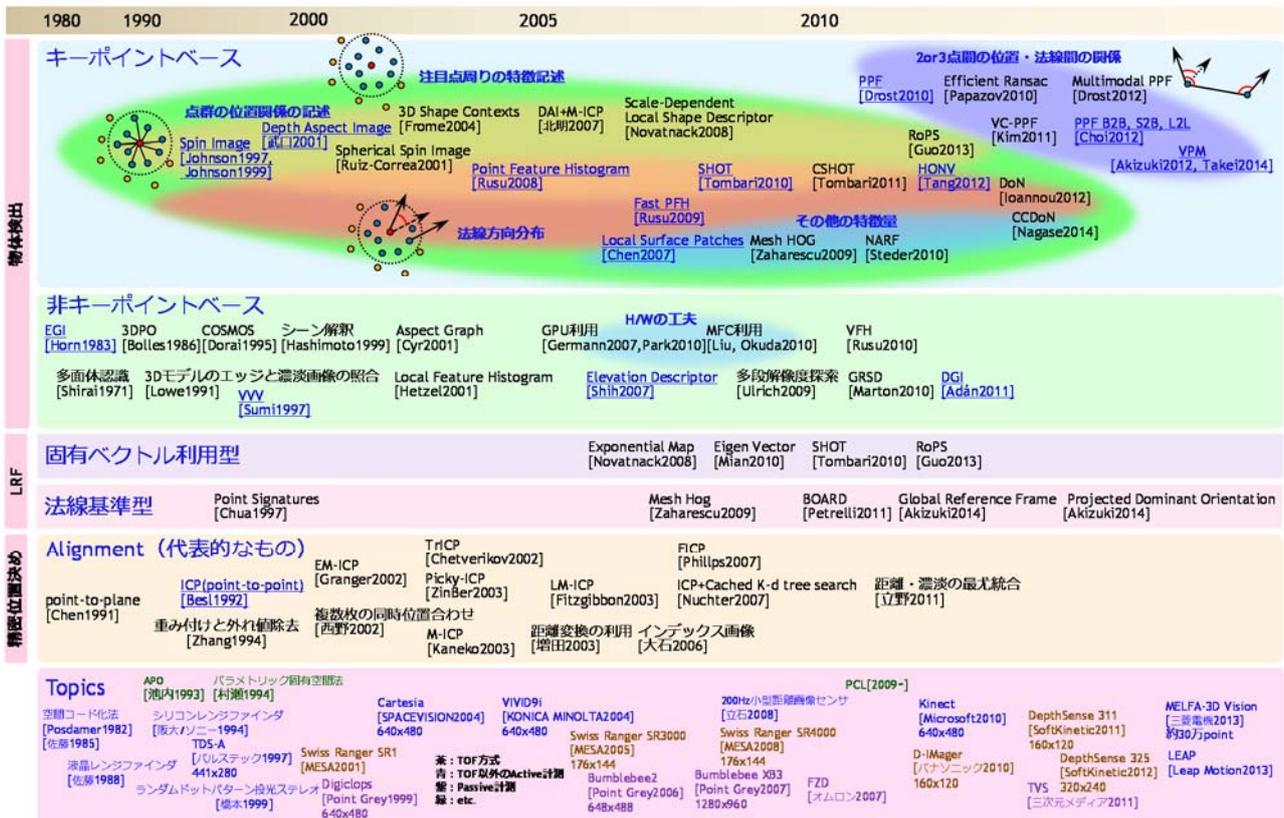


図2. モデルベース手法を中心とした3次元物体認識に関する研究マップ

図2に、マシンビジョン分野に関連する3次元物体認識技術の大きな変遷を示す。文字が小さく読みにくい部分があるがご寛恕願いたい。なお、詳細な図は筆者の研究室のWEBサイト<sup>1</sup>でも公開している。

### 2.3 物体検出技術開発の系譜

図3に示すように、物体検出技術は、アピアランスベース認識と、モデルベース認識の大きく2つに分けることができる。

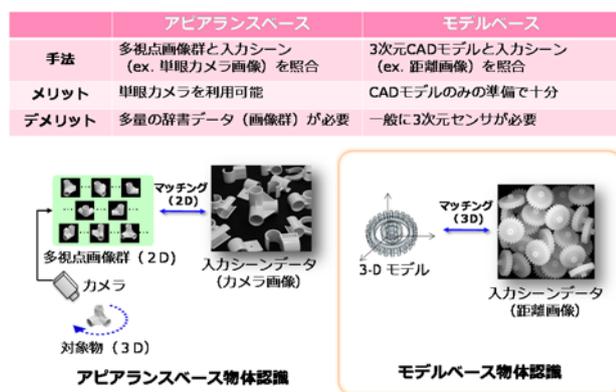


図3. アピアランスベースとモデルベース物体認識

アピアランスベース手法は、対象物に関する見え (Appearance) の情報をもとにした手法である。基本としては、モデル物体をさまざまな方向から撮影した多数の画像群を、撮影時の視線情報とともにデータベース化しておき、未知の入力データがその画像群のどれと最も近いかを判定することによって、対象物の位置姿勢を推定する技術である。この場合、大量の画像データの保管と効率的な検索が実用上のボトルネックとなるため、見えを構造化する手法 (APO) [Ikeuchi1993]や、画像群を固有空間においてパラメトリックに表現された多様体 (Manifold) として扱う手法[Murase1994]などが開発された。後者に関しては、近年、モデル画像群と入力画像との間に存在する背景変化のような事前学習が難しい外乱への対応手法[Shibata2013]も提案されており、実用化が目指されている。アピアランスベース手法は、入力デバイスが一般的なカメラのような、簡便なものでよいことや、必ずしも3次元形状モデルを持つ

必要がないという利点から、実用的なマシンビジョンとしては十分に魅力的な方法と考えられている。ただし、本稿の中心的な話題がモデルベース手法であることから、図2には含めていない。

一方モデルベース手法は、3次元物体モデルの利用を前提とし、モデルと入力シーン (の一部) との整合性を評価することによって、当該モデルと最もよくマッチする部分を検出するという考え方に基づいた手法であり、いわば2次元画像処理の代表例であるテンプレートマッチングやSIFTマッチングの3次元版である。1980年代に本格的かつ汎用的な空間コード化方式のレンジファインダが開発されたことを受けて、距離画像や3次元点群を前提としたモデルベース手法の研究が増加した。

また本稿では、モデルベース手法を、さらにキーポイントベース手法と、非キーポイントベース手法に大別している (図4)。

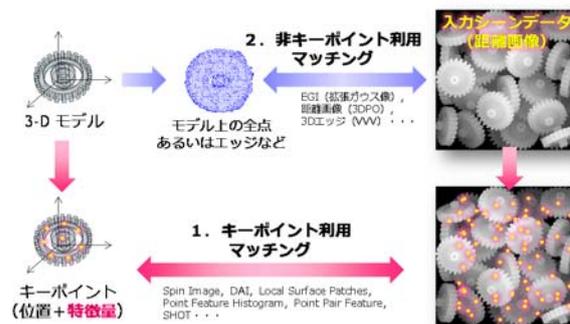


図4. モデルベース物体認識の2つのタイプ

ここでキーポイントベースの手法とは、モデルあるいは入力データとしての点群のなかから、なんらかのポリシーにのっとってマッチングに使用すべき3次元点 (キーポイント) を選択し、その点の独自性を表現した特徴量を付与したうえで、特徴量の類似性を評価することによってキーポイント単位でモデルと入力データとを照合する手法である。一方、非キーポイント手法は、単一視点からの物体の距離データ全体を特徴量化する手法である [Hetzl2001][Shih2007][Ulrich2009][Marton2010][Rusu2010][Adán2011]。

現時点では、前者が3次元物体認識の標準的な手

<sup>1</sup> <http://isl.sist.chukyo-u.ac.jp/>

法となっているため、次章にて詳述する。一方、後者としては、法線ベクトル群を利用した EGI 法 [Horn1983]、濃淡画像を併用した 3DPO [Bolles1986]、3次元情報を持つエッジに着目した VVV [Sumi1997]がある。

また、モデルベース手法の発展系として、個々の物体 (モデル) と物体群 (シーン全体) を連携させて総合的に考慮し、これら両方を矛盾なく認識する手法 [Hashimoto1999] も提案された。さらに、ハードウェア面での工夫としては、GPU 利用 [Germann2007][Park2010]のほか、特殊な照明制御が可能な簡便な撮影デバイス (MFC) を利用した手法 [Liu2010]なども開発された。

### 3. 3次元特徴量の研究動向

本章では、キーポイントベース手法において最も重要な役割を持つ、3次元特徴量の基礎と、主要な研究動向を紹介する。

#### 3.1 3次元特徴量の役割と重要性

物体認識における3次元特徴量の役割は、3次元点群から選択または検出されたキーポイントに、アイデンティティを与えることである。このアイデンティティによって、キーポイント同士の照合において、対応付けの正しさを指標化することが可能となる。したがって、できるかぎり強くその点をアイデンティファイできる特徴量が好ましいが、一方では、その特徴量がモデルと入力データの双方において安定的に記述される必要があることを忘れてはならない。

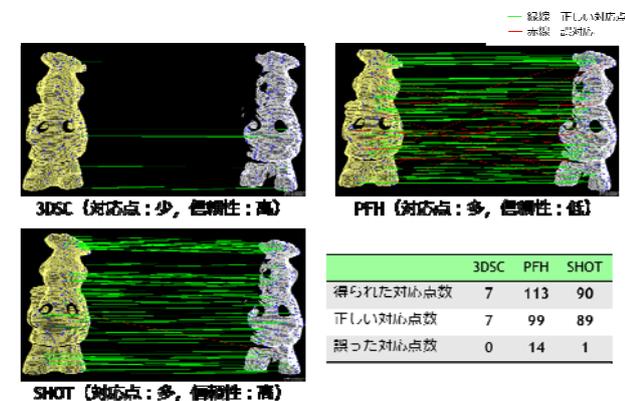


図5. さまざまな特徴量のマッチング比較例

この性能は再現性 (Repeatability) と呼ばれ、特徴量設計において非常に重要な性能ファクターとなっている。また、多くの特徴量は、例えば法線ベクトルのような表面形状を表現した数値を使用することから、ベクトルを定義するための局所的な座標系の設計も重要になってくる。これは次章にも関連するが、特徴量そのものと同様に、この座標系設計にも安定性の検討が不可欠である。

図5に示したのは、3DSC, PFH, SHOT と呼ばれる代表的な3次元特徴量を用いて同一物体 (モデルデータと認識対象データ) を対応づける実験をおこなった結果の一例である。表からわかるとおり、元データが同一であっても、どのような3次元特徴量を選択するかによって、対応点の数やその正解率に違いが生じることがある。このように、3次元特徴量は、距離データのハンドリングにおいて非常に重要な意味を持つ。

#### 3.2 3次元特徴量の分類

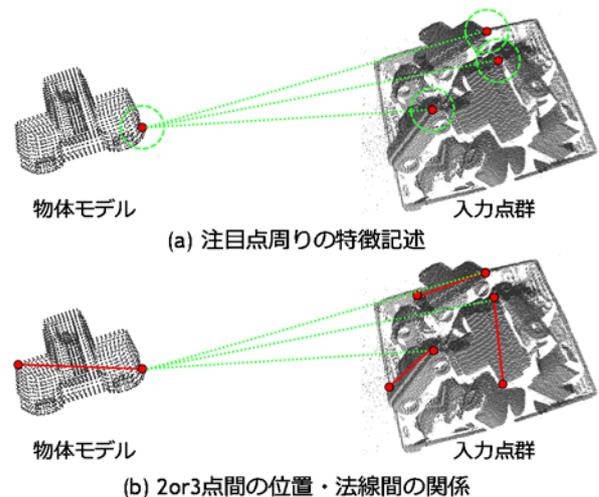


図6. 2つのタイプの3次元特徴量

3次元特徴量は、キーポイント周りの特徴を記述したものと、2点または3点間の位置や法線間の関係を記述したものの2種類に分けることができる。図6に、これら2つのタイプの特徴量の概念を示す。以下、3.3 および 3.4 において、それぞれの3次元特徴量の概要および主要な技術を紹介する。

#### 3.3 タイプ1: キーポイント周りの情報記述

このタイプの3次元特徴量は、図6(a)のように、通常、キーポイントを中心とする一定範囲内 (球形)

の3次元点群およびその派生情報を元に特徴を記述する。記述の形態としては、計算された情報をそのまま保持するものもあるが、ヒストグラム化して統計量として扱うこともある。また、球状の領域を事前に設定した方法で複数のサブ領域に分割し、サブ領域毎に特徴量を計算して分布として保持することもある。この場合は、領域という粗い位置情報が、特徴量分布に含まれていることになる。

タイプ1の特徴量は、領域内のどのような情報をもとに特徴量が計算されるかによって、さらに次の3つのカテゴリに分けられる。表1に分類を示す。

表1. キーポイントベース手法の分類

キーポイントベース手法			
キーポイント周りの情報記述			複数点間の関係記述
座標データ	法線ベクトル方向	その他の特徴量	2点間 or 3点間
PFH, SHOT, CSHOT, HONV		LSP, CCDON, NARF, MHOG, RoPS	PPF, ER, VC-PPF, MPPF, PPF B2B or S2B or L2L, VPM
SI, SSI, DAI, 3DSC, SDLSD	FPFH, DoN		

PFH : Point Feature Histogram	SDLSD : Scale-Dependent Local Shape Descriptor	PPF : Point Pair Feature
SHOT : Signature of Histograms of Orientations	FPFH : Fast PFH	ER : Efficient Ransac
CSHOT : Color SHOT	DoN : Difference of Normals	VC-PPF : Visibility Context PPF
HONV : Histogram of Oriented Normal Vector	LSP : Local Surface Patches	MPPF : Multimodal PPF
SI : Spin Image	CCDON : Combination of Curvatures and Difference of Normals	PPF B2B or S2B or L2L : PPF Boundary-to-Boundary or Surface to Boundary or Line to Line
SSI : Spherical Spin Image	NARF : Normal Aligned Radial Feature	VPM : Vector Pair Matching
DAI : Depth Aspect Image	MHOG : Mesh HOG	
3DSC : 3D Shape Contexts	RoPS : Rotational Projection Statistics	

第1のカテゴリは、領域に含まれる点群が持つ3次元「座標」を特徴量にする手法である。図7に示したのは、特徴量ベースの物体認識手法として有名な Spin Image 法[Johnson1997, 1999]である。

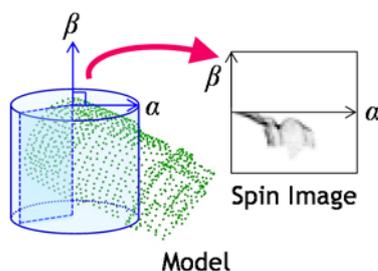


図7. Spin Image 特徴量[Johnson1997, 1999]

この手法は、ある注目点における法線に垂直な面を設定し、法線方向  $\beta$  とそれに直交する方向  $\alpha$  に関して、 $\beta$  を軸とする円柱面に周辺の点座標を投票し、これを画像的に表現したデータを特徴量としている。投票面の決定には法線を使用しているが、投票されるデータは点の座標である。このとき、 $\alpha$  の量を制

御することによって、考慮する空間的なレンジを調整することができる。これを小さくすればオクルージョンに頑健になるが、特徴量としての独自性は薄れるというトレードオフが生まれる。また、特徴量の次元数が比較的大きく、これを全ての点に関して保持することから、一般には計算量が多いという課題を持っている。

武口らによって提案された Depth Aspect Image (DAI) 法[Takeguchi2001]は、物体から特徴的な3点(曲率の大きな点)を抽出して ACF (Aspect Coordinate Frame) と呼ぶ平面を構成し、周辺座標を投影した画像(DAI)を得る。これを3点の組み合わせごとに生成してデータベース化しておき、入力画像から得た DAI と画像として照合させ、対応点を見つける手法である(図8)。

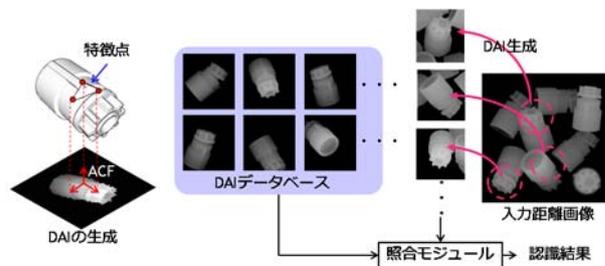


図8. Depth Aspect Image 特徴量 [Takeguchi2001]

Spin Image と同様に座標を投影した画像群として特徴量を記述するが、特徴的な3点組についてのみ特徴記述することから、照合効率が高まることが期待される。また、3D Shape Contexts 法[Frome2004]は、注目点周りの領域を緯度、経度、直径方向に分割し、サブ領域内の点群の個数をヒストグラム表現した特徴量である。

第2のカテゴリは、領域内の各点が持つ「法線ベクトル方向」を特徴量とする手法である。Rusuらによって提案された Point Feature Histogram (PFH) [Rusu2008]は、注目点と球領域内の  $k$  個の近傍点から多数の2点組を選択し、各点の法線方向から計算される角度パラメータをヒストグラム特徴としている。図9にそのようすを示す。2点組を用いる点では次に述べるカテゴリに近いが、PFHでは多数の2点組から得た統計量の特徴量としている点に注意すべきである。

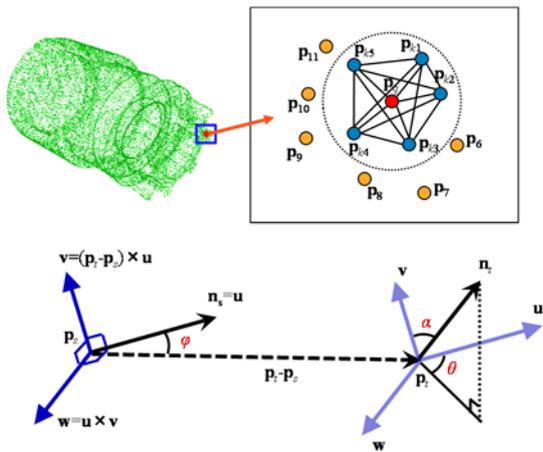


図 9. Point Feature Histogram 特徴量[Rusu2008]

また, Tombari らによって開発された, Signature of Histograms of Orientations (SHOT) 特徴 [Tombari 2010]もまた, 法線方向を利用したものである. 図 10 に示すように, 注目点周辺の球状の領域を, xy 平面で 2 分割, 球の内外で 2 分割, さらに z 軸に対して 8 分割, 合計 32 分割し, それぞれにおける法線ベクトル群と注目点の法線との関係を内積値として表現してヒストグラム化し, 最終的には 352 次元の特徴量として定義している.

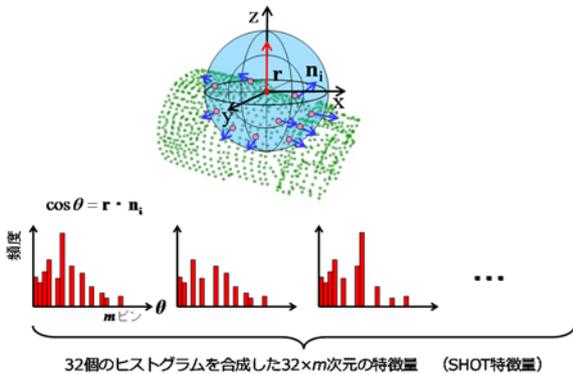


図 10. SHOT 特徴量[Tombari2010]

なお Tombari らは, この論文の中で, 特徴量を記述する際に幾何学的な基準となる, 参照座標系 (Reference Frame) の重要性について詳細に論じており, これはこの特徴量を頑健にする要因にもなっている. 参照座標系については次章で補足する.

最後に, 前述の 2 つに属さない特徴量を第 3 のカテゴリに分類する. この分類としては, 例えば, Chen

らによって提案された, Local Surface Patches (LSP) [Chen2007]がある (図 11).

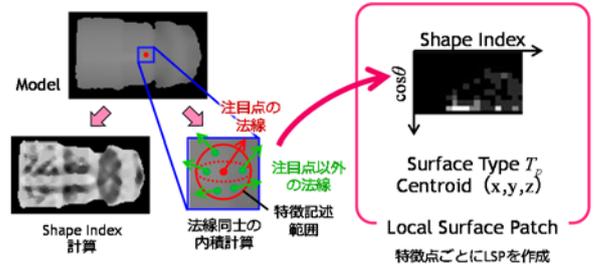


図 11. Local Surface Patches 特徴量[Chen2007]

LSP では, Shape Index 値と呼ばれる変量を利用する. これはその 3 次元点が局所的にどのような凹凸形状をしているかを表している. 図 11 のように, 領域内の特徴点ごとに Shape Index 値を求めるとともに, その点と注目点の法線ベクトルとの内積値も計算する. これらの関係を表現したものが Local Surface Patch である. したがって, LSP は, 特徴点周辺の領域内の各点における凹凸情報の分布をそのまま保持していると考えられるので, かなりアイデンティティの高い特徴量となっているが, 同時に高次元であることから, 特徴点の計算や照合に時間がかかるという問題がある.

この問題を解決するために, 筆者らは CCDoN 特徴量という, この第 3 のカテゴリに属する新しい 3 次元特徴量を提案し, 効果を確認している [Nagase2014]. これについては, 第 5 章で紹介する.

### 3.4 タイプ 2 : 複数点間の関係記述

このタイプの特徴量は, 図 6(b)のように, 2 点または 3 点のポイントクラウドデータの関係性を記述している. したがって, どのような点を組み合わせるか, またその組み合わせにおけるどのようなパラメータを特徴量として採用するかのが 2 つが主要な設計要素となる.

この手法の代表例は, Drost らの Point Pair Feature (PPF) [Drost2010]である. 図 12 に原理を示す. この特徴量は, 物体モデル上の全ての 3 次元点から 2 点 (点対) を選択して組み合わせ, 図(a)のように, 2 点間の距離 (F1), 2 点を結ぶ線分と各点の法線方向との角度 (F2, F3), 2 点の法線間の角度 (F4), の計 4 つのパラメータを 4 次元特徴量 F と

して保持する. このとき, あらかじめ  $F$  をインデックスとして  $F$  をとる 2 点の点番号をテーブル化しておけば, 入力データから同様の方法によって得た特徴量  $F$  をキーとして, 効率よく対応点を検索することができる.

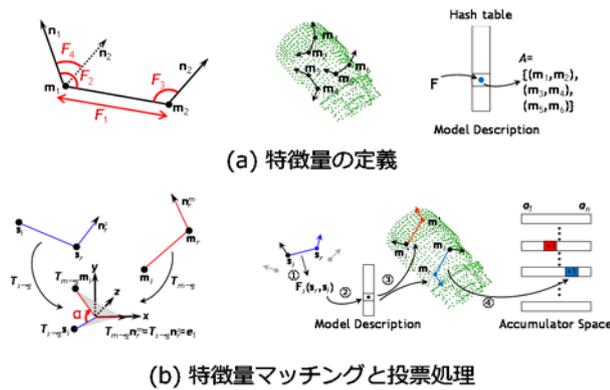


図 12. Point Pair 特徴量[Drost2010]

また同図(b)のように, 対応づけ後は点対間の剛体変換パラメータを求めることになる. これを投票空間に投票すれば, 高得票のパラメータは多くの点対が共通の剛体変換パラメータを持つことを意味するので, モデルが存在する位置と姿勢を特定することができる.

この PPF を発展させた手法として, Choi らの手法[Choi2012]がある. これは, PPF においてペアリングする点のある種のルールを用いて限定することによって点対としての独自性を高めるとともに, データ削減による高速化を図るものである. 図 13 に, Choi らが提案したルールを示す.

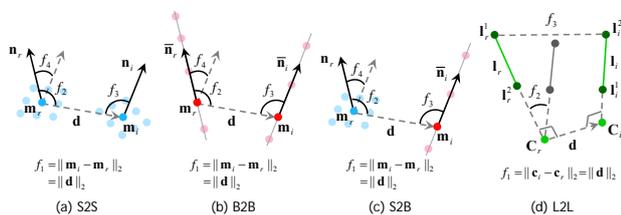


図 13. PPF の選択指針[Choi2012]

同図において, S2S は Surface to Surface すなわち面上の 2 つの点によるペアリングを示し, Drost らのオリジナル手法と同様である. ただし, これは意図的に面上の点だけを選択しているという意味で

はなく, ポイントクラウドデータを無作為にペアリングすると, 結果的に面上の点同士の組み合わせが多くなることを意味している. 一方, B2B は Boundary (稜線) 間に存在する点対, S2B は面と稜線を両端点とする点対である. このように両端点を限定することによって点対のアイデンティティを強めることができる. また L2L は物体稜線自体をラインセグメントとして取り出し, 2 つのラインセグメントペアから得られる幾何学的パラメータを特徴量としている. これは, 前述の 3 種の特徴量とは意味的に異なるものであるが, やはりアイデンティティの強い特徴量になっている. Choi らの実験によれば, B2B など非平面上の点を優先的にペアリングすることによって認識信頼性が高まることが示されている.

ここで, タイプ 1 とタイプ 2 からそれぞれ SHOT 特徴量, PPF を代表例として取りあげ, 次の 3 つの観点からこれら 2 つのタイプの関係を考察する.

1. まず, アイデンティティの観点からは, SHOT のほうが高次元である分, 独自性が高く, 誤照合の可能性が低いと考えられる. PPF における対応点対パラメータの投票処理は, この問題を改善するために重要な位置づけとなっている.
2. 特徴量の再現性 (Repeatability) の観点では, 双方ともに法線ベクトルの正確さに負うところが多いので, タイプがもつ原理的な傾向というよりは, むしろ法線の計算方法に依存していると考えられる. SHOT はヒストグラム化した法線群を使用しているために突発的なノイズには頑健と思われるが, PPF も同様の計算手法をとれば再現性を向上する効果が期待できる.
3. モデル物体上に設定する特徴量の数は, マッチング時間や信頼性に影響を与える重要なファクターである. 一般的にはアイデンティティの強い特徴量が得られる場合には, 特徴点数は少なくてもよいと考えられるが, 例えばばら積み物体の認識では頻繁に部分的なオクルージョンが予想されるため, 入力画像中において当該特徴点が観測できているかどうか, すなわち可観測 (observable) であるかどうかも重要である. したがって, 実際の問題では, 少数の高アイデンティティ特徴点を使えばよいとは一概には言えな

い. この可観測性の議論は非常に重要であり, 第5章にて筆者らの関連研究を紹介する.

このように, 3次元特徴量は, アイデンティティ, 再現性, 個数の観点から整理することができる.

#### 4. 局所参照座標系の研究動向

本章では, 3次元特徴量を語る時に避けて通れない概念である, 局所参照座標系 (LRF: Local Reference Frame) について, その意味と分類および主要な研究動向を概説する.

##### 4.1 LRF の役割

局所参照座標系 (LRF: Local Reference Frame) とは, キーポイントごとに設定される座標系のことである. 図14にLRFの概要を模式的に示す. 通常, 図のような3次元直交座標系であり, 第1軸は当該キーポイント周囲の局所的な面の法線ベクトル (赤線) であることが多い. 第2軸 (緑線) はこれと直交するベクトルである. 第3軸 (青線) は, 第1軸, 第2軸をもとに外積ベクトルとして定義される.

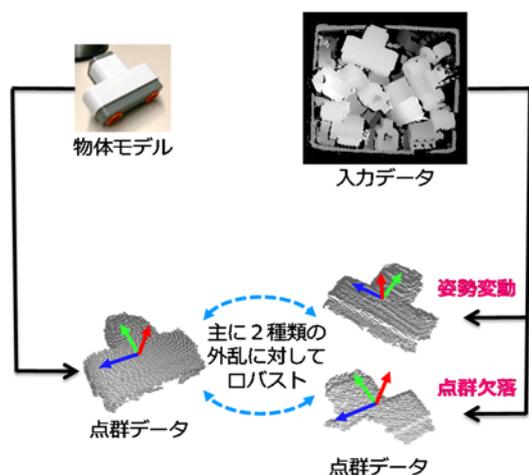


図14. LRFの概要

物体認識におけるLRFの役割としては, 大きく分けて次の2つがある.

1. 対応づけられた2つのキーポイント間の幾何学的な関係を計算する情報を提供する.
2. 特徴量の記述再現性 (Repeatability) を高める.

1は, 対応づけられたキーポイントの相対的な幾

何関係, 具体的には3次元回転行列と並進ベクトルを算出するための幾何情報である. キーポイントマッチングによって対応点が確定すれば, 対応点間のLRFを関連付ける剛体変換パラメータを相対的な幾何関係として算出することができ, これが位置姿勢情報となる. したがって, 高精度な位置姿勢パラメータ推定のためには, 高精度なLRFが不可欠である.

2に関しては, 例えばSHOT特徴量に代表されるいくつかの3次元特徴量は, キーポイント周りの点群データを, LRFを基準としていくつかのサブ領域に分割し, サブ領域ごとに法線分布等を記述する. したがって, 角度誤差が小さいLRFを設定することができれば, それぞれのサブ領域内に属する点群が安定する. すなわち, モデル物体上の特徴量と, それに対応する入力データ上の特徴量が数値として類似する. これは再現性と呼ばれ, 再現性の高さはLRFの安定性に大きく依存している.

ところで, LRFの算出方法は, 固有ベクトルを利用したものと, 法線を基準にして設定するものの, 2つのタイプに分けることができる. 以下にそれぞれのLRFを紹介する.

##### 4.2 固有ベクトルを利用した設定法

このタイプに属する最も基本的なLRFは, キーポイント周りの点群の3次元座標をもとに共分散行列を計算し, その固有ベクトル群を用いてLRFを設定する手法である[Mian2010].

図15に, Mianの手法の概念を示す.

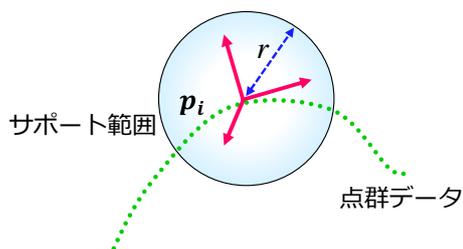


図15. 固有ベクトルを利用したLRFの算出

この手法では, 半径  $r$  の球領域内の点群の座標データの共分散行列から以下の式(1)および(2)により得られた固有ベクトル群をそのままLRFとして採用する. (1)は共分散行列の算出式, (2)は(1)で使用される平均ベクトルの算出式である.

$$\Sigma_{\hat{p}} = \frac{1}{k} \sum_{i=0}^k (\mathbf{p}_i - \hat{\mathbf{p}})(\mathbf{p}_i - \hat{\mathbf{p}})^T \quad (1)$$

$$\hat{\mathbf{p}} = \frac{1}{k} \sum_{i=0}^k \mathbf{p}_i \quad (2)$$

一般的な平面的点群の場合、固有ベクトル群のうち、第3主成分が法線ベクトルに相当する。また、固有ベクトル群は直交基底を構成するため、その意味でもこれをLRFとして用いるのは自然である。

Tombariらは、この手法を改良し、注目点からの距離が遠いほど重みを小さくする重み付き共分散行列をもとに固有ベクトル群を計算するようにした。同時に、固有ベクトルの方向に正負の曖昧性が存在することを指摘し、これを解決することによって再現性を大幅に向上させることに成功した[Tombari2010]。

また、RoPS LRF[Guo2013]では、照合対象の点群間の密度の違いの影響を吸収する工夫が提案されている。物体の本来の形状を離散的な点群データから表現するために、形状を三角パッチで表現し、パッチ内部の点を考慮した共分散行列を生成した。このLRFは、一定範囲の情報を利用して統計的に座標軸を求めるため、遮蔽によって比較的多くのデータが欠落した場合には、その影響を受けやすいという問題が浮上する。

### 4.3 法線を基準にした設定法

2つめのタイプは、LRFの3軸をそれぞれ独立して算出する手法である[Chua1997][Zaharescu2009][Petrelli2011][Akizuki2014a][Akizuki2014b]。これらの手法においては、キーポイント周りの局所形状の法線ベクトル方向が安定していることから、これをz軸にする点が共通しており、x軸の計算方法に特色がある。たとえばBOARD LRF[Petrelli2011]では、キーポイント周りの点群の法線ベクトルの中で最もz軸との傾きが大きいもの(内積値最小)を選び、これをz軸に対して直交化することによってx軸としている(図16)。

具体的には、この内積値を、z軸周りのx軸の方向角 $\phi$ における関数(分布)とみなし、内積値最小になるときの $\phi$ を求めることによってx軸を決定している。加えて、サポート範囲の点群に情報欠損が

存在することを想定し、上記の $\cos \theta$ と $\phi$ の分布関係において情報欠損の有無を判定し、もし内積最小値がその $\phi$ の範囲内に存在するようならば、非欠損領域のデータを用いて内積最小値を補完的に推定することによってLRFの再現性を向上させている。

また、Mesh HoG LRF [Zaharescu2009]では、z軸によって規定される極座標系において、勾配方向分布から統計的に主方向を推定する方法を採った。このタイプのLRFは、一般的には遮蔽には頑健な傾向を持っている。

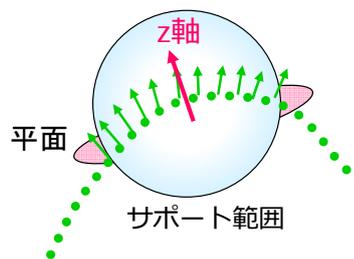


図16. BOARD-LRF算出の概念図

### 4.4 点群欠落とLRFの再現性の関係

ここで、いくつかのLRFについて、対応点間の点群データの欠落率と、得られたLRFの角度誤差の評価結果を紹介する。比較に用いたLRFは、固有ベクトル利用型としてSHOT LRFを、法線方向基準型としてBOARD LRFを、また、次章5.4にて紹介する筆者らが提案したDPN LRFの3種である。対となる点群データに対して、あらかじめオクルージョンの影響を模擬した欠落を生じさせたものを実験に用いた。推定したLRFの角度誤差の分布を図17に示す。

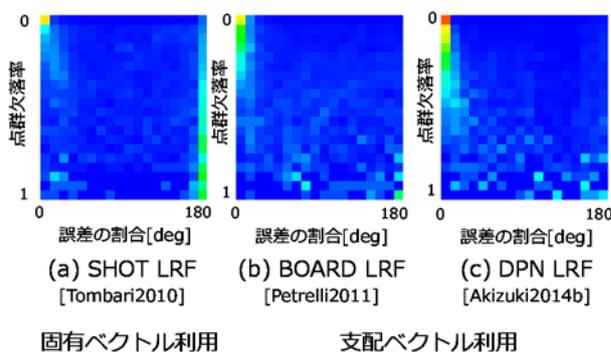


図17. 対応点間のデータ欠落率と角度誤差 (横軸: LRF 角度誤差, 縦軸: データ欠落率)

同図では、左から順に SHOT LRF, BOARD LRF, DPN LRF による結果である。各誤差分布の横軸は LRF の角度誤差[deg]を示しており、左が誤差小、右が誤差大である。また、縦軸は次の(1)式によって計算された点群データの欠落率であり、上が欠落率小、下が欠落率大であることを示している。

$$\frac{|N_M - N_S|}{\max(N_M, N_S)} \quad (3)$$

$N_M, N_S$  は LRF の計算に用いたデータ点数である。値が大きいほど対応点周りのデータ点の欠落が大きかったことを示す。誤差分布の色は、当該データ欠落率と生じた角度誤差の組み合わせが発生した割合を示しており、青～黄～赤の順に大きいことを表している。

なお、この分布図では1行ごとに総和が1になるように正規化している。理想的には、データ欠落率に依らず、全ての推定結果が分布図の左端（角度誤差が小さいことを示す箇所）の列に集中し、中央部や右には分布がない（誤差が少ないことを示す青色領域が広い）ことが望ましい。SHOT LRF は、固有ベクトルをそのまま LRF に割り当てているため、推定結果が欠落率の影響を大きく受けている。

一方 BOARD LRF は、点群の欠落を考慮して LRF を設定する機能を持っているため、SHOT LRF と比べると欠落率の影響が小さく、かつ大きな誤差が少ないことがわかる。さらに、筆者らが提案した DPN LRF では、欠落に対する頑健性が高い。BOARD LRF の分布と比較すると、DPN LRF の方が、欠落率が高い場合でも誤差が小さい（図の左側に分布がある）ことがわかる。すなわち、入力データから安定して LRF を設定できている。これは、法線方向分布を利用して軸方向を推定していることが要因であると考えられる。

## 5. 3次元特徴量に関する筆者の研究事例

### 5.1 Vector Pair Matching (VPM) とその周辺

#### 5.1.1. VPM(ベース手法)[Akizuki2012, 2013]

3点の3次元点の組が3次元位置姿勢算出のための最小のデータセットであることを踏まえ、ベクトルペア特徴量を定義する。これは、始点を共有した

2つの空間ベクトルとして表現される照合単位である(図18)。

VPM法では、認識に用いるベクトルペアを独自性の高いものだけに限定することによって、認識の高速性と信頼性を両立した。物体モデル中におけるベクトルペアの特徴量の発生確率を事前に分析し、低発生確率なものほど、独自性が高いと考えて優先的に選択している。

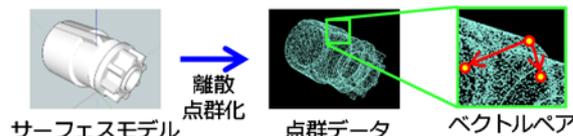


図18. ベクトルペア

#### 5.1.2. 可観測性の導入[Akizuki2013]

特徴量の独自性の高さは認識性能の向上のために有効であるが、そもそも、入力シーンにおいてキーポイント自体がオクルージョンの影響を受けやすい場合には、認識に用いるべきではないと考えられる。この考え方に基づき、物体を構成する各3次元点の観測可能性を算出し、これをオリジナルのVPM法に組み合わせることによって、独自性が高く、かつ観測される可能性が高いベクトルペアを選択して利用することができている。なお、可観測率は、計算機シミュレーションによって求めており、複雑な形状にも対応しやすいという利点がある。

#### 5.1.3. 入力シーンの予測学習[Takei2014]

従来のVPM法では、物体モデルがもつ情報のみを用いて特徴量を選択しているため、この段階では実際に入力データに発生する特徴量を予測できない。したがって、選択されたベクトルペアを用いてマッチングすると、図19のように、物体と物体の重なり部分など事前予測しにくい箇所に誤照合を起す可能性が高い。

ここで、もし特徴量選択時に入力画像が与えられていたら、独自性が高く、かつ入力画像中で正しい対応箇所以外には照合しないベクトルペア特徴量を選択できるはずである。そこで提案手法では、3D-CGによって生成された予測入力データから物体モデルと正しく対応する点の特徴量と、偽の特徴量を抽出し、識別性能を評価する。そして、この性能が高い特徴量を選択して照合に用いることによって、

高信頼な認識を実現した。

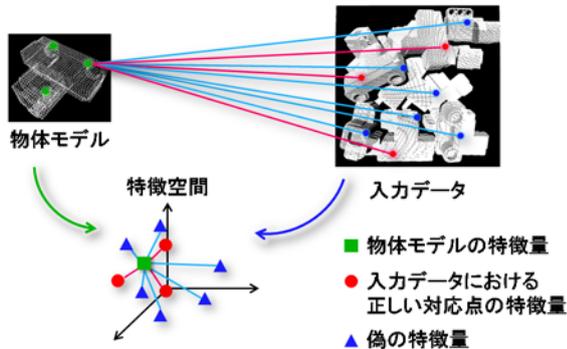


図 19. 物体モデルと入力データの特徴量の対応

### 5.2 CCDoN 特徴量

Ioannou らが提案した DoN (Difference of Normals) 特徴量[Ioannou2012]は、キーポイントを中心とする大きさが異なる 2 つの球状領域を設定し、これらから算出した法線ベクトル間の差分値をもとに特徴量を定義していた。これは、領域ベースの手法でありながら少数のスカラー値で構成されるため、高速な処理が可能であるが、特徴量としてのアイデンティティはさほど強くないために、誤照合が少なくなかった。

そこで我々は、DoN 特徴量を改良し、CCDoN 特徴量 (Combination of Curvatures and Difference of Normals) を提案した (図 20)。これは、DoN 特徴量に対して、2 つの領域それぞれで算出した曲率値 (Curvature) を追加し、合計 3 次元の特徴量としたものである。曲率値は姿勢変動に頑健であることから、次元数が小さいまま、特徴量の表現能力を高めることができた。

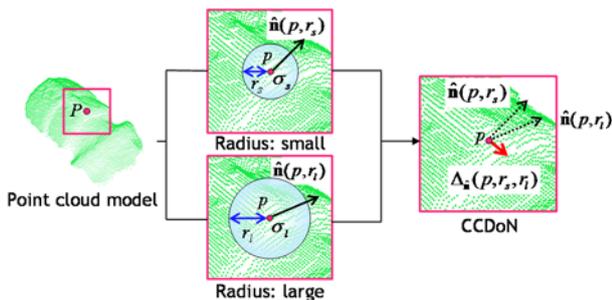


図 20. CCDoN 特徴量[Nagase2014]

### 5.3 GRF (Global Reference Frame)

工業部品の多くは、平面のような単純な形状で構成されることが多い。したがって、平面上のキーポイントに関しては、法線ベクトル (第 1 軸) は比較的算出しやすいが、それと直交する第 2 軸の算出にあたっては、これを規定するための手がかり情報に乏しいことから、座標系としては不安定であった。

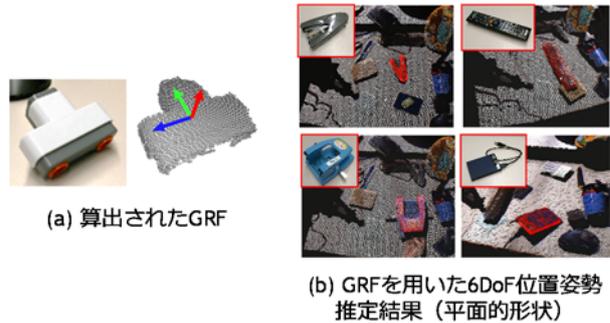


図 21. GRF の例と平面物体に対する 6DoF 位置姿勢推定結果

そこで我々は、物体の外形 (稜線による輪郭) のような大域的なデータ分布をもとに、RF を決定する新たな手法[Akizuki2014a]を提案した。具体的には、平面の外形輪郭部分に存在する点群には特定方向の偏り (長手方向) が存在する場合が多いことに着目し、これをもとに座標系を決定する。キーポイント周りの局所的な情報をもとに算出される LRF とは異なり、距離データの大域的な (Global) 情報に基づいた参照座標系であることから、Global Reference Frame (GRF) と呼んでいる。図 21 に、算出された GRF の例と、GRF を用いて平面物体の 6 自由度の位置姿勢を推定した結果を示す。

### 5.4 Dominant Projected Normals (DPN)

本手法は、照合対象の点群データの密度の違いと、オクルージョンに起因した点群の欠落に頑健な、新しい LRF の提案である。DPN LRF は照合対象の点群の密度の違いに対応するために、RoPS LRF [Guo2013]と同様に、計測点間に存在する物体本来の形状を考慮して軸方向を算出する。また、点群の欠落に対する頑健性を獲得するために、法線方向分布を分析したうえで、支配的方向を算出する方法を採っている。キーポイントマッチングを実行する際に、LRF を DPN に差し替えるだけで、対応点探索

の信頼性を向上させることが可能である (図 22)。

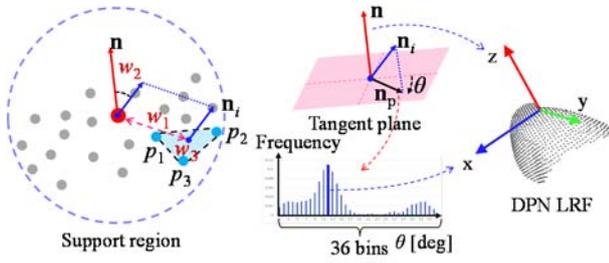


図 22. DPN LRF [Akizuki2014b]

5.5 点群密度に頑健な RPD 特徴量の提案

本節では、最新の研究成果として、RPD 特徴量 [Takahashi2015]を紹介する。

たとえば移動ロボットにおける周辺状況認識など、現実の距離データのハンドリングにおいては、レンジファインダ等のセンサから得られる点群の密度が一定しないことが想定されるため、これがキーポイントベースの物体認識の実用化における重要な課題となっている。

図 23 は、ある対象物 (人形) をセンサから徐々に遠ざけていったときに、SHOT 特徴を用いてマッチングをした場合の、ワーキングディスタンス W と、モデル-入力データ間の類似度 S の関係を実験的に求めた一例である。

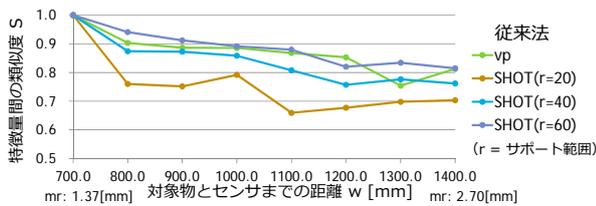


図 23. 点群密度の差が引き起こす認識率低下の例

横軸が W であり、W が大きいほど入力距離データの点群密度は粗いことを意味している。縦軸が S であり、ベクトルペア法と SHOT 法 (サポート半径を変えて実験した) を用いた実測値をプロットしている。この図からわかるように、モデルと入力画像の点群密度がほぼ一致している場合 (W=700mm) では、手法に依らず高い類似度が得られているが、入力データの点群密度がモデルと異なる度合いが大きくなればなるほど、どの手法でも類似度が低下しており、正しいマッチングが困難になっている様子が

みてとれる。これは主に、点群が粗い場合に、法線の算出が安定せず、法線をもとに計算されるタイプの特徴量の再現性が低下しやすいことに起因している。

一方、モデル点群であっても、入力点群であっても、同一物体上に設定された複数の局所領域間のデータ点数比は、点群密度に依らず一定である可能性が高いと考えら得れる。そこで我々は、この相対量の特徴量として採用する新しい3次元特徴量 (RPD: Relative Point Density) を提案した。

RPD 特徴量は、以下の (4) および (5) 式によって定義される (図 24) 。

$$f = \left( \frac{C(p)}{S}, \frac{C(q_1)}{S}, \frac{C(q_2)}{S} \right) \tag{4}$$

$$S = C(p) + C(q_1) + C(q_2) \tag{5}$$

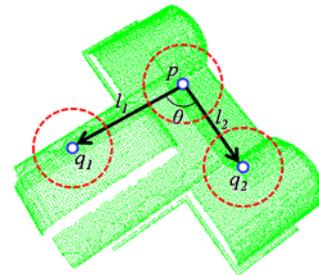


図 24. RPD 特徴量の概念図

図 25 に、本特徴量による認識実験結果の一例を紹介する。図のように、従来の3次元特徴量 (VPM および 3DHV) と比較して、点群荒さの影響をほとんど受けない安定した性能を有していることがわかる。

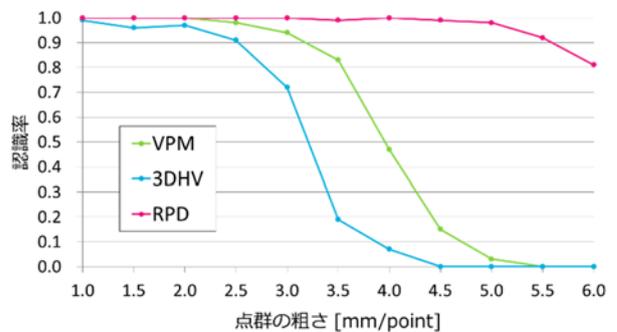


図 25. RPD 特徴の性能 (認識成功率と粗さの関係)

## 6. おわりに

距離データハンドリング, 特に物体認識の分野における3次元特徴量について論じた. 昨今, 汎用的で安価なレンジファインダや3次元モデルデータの普及にともない. 3次元物体認識に関する研究分野がふたたび注目されている. 物体認識手法の研究の歴史を振り返り, モデルベース認識, キーポイントベース認識の位置づけを明らかにするとともに, そのなかで重要な3次元特徴量の分類と研究動向を紹介し, 主要な方法については概要を解説した. また, 3次元特徴量を利用する際に避けて通れない概念として, 局所参照座標系の意味と重要性についても論じた. さらに, 筆者らの最近の研究事例として, LRFの高信頼化, 特徴量の改良や新提案についても紹介した.

**謝辞** 本稿の執筆には, 研究室所属の秋月秀一, 永瀬誠信, 武井翔一, 高橋祥平の4名の学生の協力を得た. 記して謝意を表す.

## 参考文献

[Adan2011] A.Adan, P.Merchan, S.Salamanca, 3D scene retrieval and recognition with Depth Gradient Images, *Pattern Recognition Letters*, Vol.32, pp.1337-1353, 2011.

[Akizuki2012] S.Akizuki, M.Hashimoto, High-speed and Reliable Object Recognition using Distinctive 3-D Vector Pairs in a Range Image, *International Symposium on Optomechatronic Technologies (ISOT)*, pp1-6, 2012

[Akizuki2013a] 秋月秀一, 橋本学, 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, *電気学会論文誌C 研究開発レター*, Vol.133, No.9, pp.1853-1854, 2013.

[Akizuki2013b] 秋月秀一, 橋本学, 可観測性を考慮した3Dベクトルペア選択によるばら積み部品の位置姿勢認識, *ビジョン技術の実利用ワークショップ (ViEW)*, OS5-O2, Dec. 2013.

[Akizuki2014a] 秋月秀一, 橋本学, Global Reference Frameを用いた対象物の見えに依存しない3次元位置姿勢認識, *精密工学会誌*, 2014.

[Akizuki2014b] 秋月秀一, 橋本学, 安定的な3D特徴量記述のための点群の密度変化にロバストなLocal Reference Frame, *ビジョン技術の実利用ワークショップ (ViEW)*, 2014.

[Besl1992] P.J.Besl, N.D.McKay, A Method For Registration Of 3-D Shapes, *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*,

Vol.14, No.2, pp.239-256, 1992.

[Bolles1986] R.Bolles, R.Horaud, 3DPO: A three-dimensional part orientation system, *International Journal of Robotics Research*, Vol.5, Issue 3, pp.3-26, 1986.

[Chen2007] H.Chen, B.Bhanu, 3D Free-Form Object Recognition in Range Images Using Local Surface Patches, *Pattern Recognition Letters*, Vol.28, Issue 10, pp.1252-1262, 2007.

[Chetverikov2002] D.Chetverikov, D.Svirko, D.Stepanov, P.Krsek, The Trimmed Iterative Closest Point Algorithm, *Proceedings. International Conference on Pattern Recognition (ICIP)*, Vol.3, pp.545-548, 2002.

[Choi2012] C.Choi, Y.Taguchi, O.Tuzel, M.Liu, S.Ramalingam, Voting-Based Pose Estimation for Robotic Assembly Using a 3D Sensor, *IEEE International Conference on Robotics and Automation (ICRA)*, pp.1724-1731, 2012.

[Chua1997] C.S.Chua, R.Jarvis, Point Signatures: A New Representation for 3D Object Recognition, *International Journal of Computer Vision (IJCV)*, Vol.25, Issue 1, pp63-85, 1997.

[Dorai1995] C.Dorai, A.K.Jain, COSMOS-A Representation Scheme for Free-Form Surfaces, *Proceedings. Fifth International Conference on Computer Vision (ICCV)*, pp.1024-1029, 1995.

[Drost2010] B.Drost, M.Ulrich, N.Navab, S.Ilic, Model Globally, Match Locally: Efficient and Robust 3D Object Recognition, *2010 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.998-1005, 2010.

[Fitzgibbon2003] A.W.Fitzgibbon, Robust Registration of 2D and 3D points sets, *Image Vision Computing*, Vol.21, pp.1145-1153, 2003.

[Frome2004] A.Frome, D.Huber, R.Kolluri, T.Bulow, J.Malik, Recognizing Object in Range Data Using Regional Point Descriptors, *8th European Conference on Computer Vision*, Prague, Czech Republic, pp.224-237, 2004.

[Germann2007] M.Germann, M.D.Breitenstein, I.K.Park, H.Pfister, Automatic Pose Estimation for Range Images on the GPU, *International Conference on 3-D Digital Imaging and Modeling(3DIM)*, pp.81-90, 2007.

[Granger2002] S.Granger, X.Pennec, Multi-scale EM-ICP: A Fast and Robust Approach for Surface Registration, *European Conference on Computer Vision(ECCV)*, Vol.2353, pp.418-432, 2002.

[Guo2013] Y.Guo, F.Sohei, M.Bennamoun, M.Lu, J.Wan, Rotational Projection Statistics for 3D Local Surface Description and Object Recognition, *International Journal of Computer Vision (IJCV)*, Vol.105, Issue 1, pp.63-86, 2013.

- [Hashimoto1999] 橋本学, 黒田伸一, 鷲見和彦, 宇佐美照夫, 仲田周二, シーン仮説と入力画像の大局的画像整合性評価に基づく複数物体の認識, 電学論 D-II, Vol.J82-D-II(12), pp.2288-2297, 1999.
- [Hetzl2001] G.Hetzl, B.Leibe, P.Levi, B.Schiele, 3D Object Recognition from Range Images using Local Feature Histograms, Computer Vision and Pattern Recognition, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), pp.II-394-II-399, 2001.
- [Horn1984] B.K.P.Horn, Extended Gaussian Images, Proceedings of the IEEE, Vol.72, No.12, pp.1671-1686, 1984.
- [Ikeuchi1993] K.Ikeuchi, S.B.Kang, Assembly Plan from Observation, AAAI Technical Report FS-93-04, pp.115-119, 1993.
- [Johnson1997] A.E.Johnson, M.Hebert, Surface Registration by Matching Oriented Points, Proceedings. International Conference on Recent Advances in 3-D Digital Imaging and Modeling, pp.121-128, 1997.
- [Johnson1999] A.E.Johnson, M.Hebert, Using Spin Images for Efficient Object Recognition in Cluttered 3D Scenes, IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI), pp433-449, 1999.
- [Kaneko2003] S.Kaneko, T.Kondo, A.Miyamoto, Robust matching of 3D contours using iterative closest point algorithm improved by M-estimation, Pattern Recognition, vol.36, pp.2041-2047, 2003.
- [Liu2010] M.Liu, O.Tuzel, A.Veeraraghavan, R.Chellappa, A.Agrawal, H.Okuda, Pose Estimation in Heavy Clutter using a Multi-Flash Camera, IEEE International Conference on Robotics and Automation (ICRA), pp.2028-2035, 2010.
- [Marton2010] Z.Marton, D.Pangerc, R.B.Rusu, A.Holzbach, M.Beetz, Hierarchical Object Geometric Categorization and Appearance Classification For Mobile Manipulation, IEEE-RAS Proc. International Conference on Humanoid Robots (ICHR), pp.365-370, 2010.
- [Mian2010] A.Mian, M.Bennamoun, R.Owens, On the Repeatability and Quality of Keypoints for Local Feature-based 3D Object Retrieval from Cluttered Scenes, International Journal of Computer Vision (IJCV), Vol.89, Issue 2-3, pp348-361, 2010.
- [Murase1994] 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-, 電学論 D-II, Vol.J77-D-II, No.11, pp.2179-2187, 1994.
- [Nagase2014] 永瀬誠信, 秋月秀一, 橋本学, CCDoN: ばら積み部品の高速度・高信頼な6自由度位置姿勢推定のための局所特徴量, 精密工学会誌, 2014.
- [Nuchter2007] A.Nuchter, K.Lingemann, J.Hertzberg, Cached K-d Tree Search For ICP Algorithms, International Conference on 3-D Digital Imaging and Modeling (3DIM), pp.419-426, 2007.
- [Park2010] I.K.Park, M.Germann, M.D.Breitenstein, H.Pfister, Fast and Automatic Object Pose Estimation for Range Images on the GPU, Machine Vision and Applications, Vol.21, No.5, pp.749-766, 2010.
- [Petrelli2011] A.Petrelli, L.D.Stefano, On the Repeatability of the Local Reference Frame for Partial Shape Matching, IEEE International Conference on Computer Vision (ICCV), pp.2244-2251, 2011.
- [Phillips2007] J.M.Phillips, R.Liu, C.Tomasi, Outlier Robust ICP for Minimizing Fractional RMSD, Sixth International Conference on 3-D Digital Imaging and Modeling (3DIM), pp.427-434, 2007.
- [Rusu2008] R.B.Rusu, N.Blodow, Z.C.Marton, M.Beetz, Aligning Point Cloud Views using Persistent Feature Histograms, IEEE/RSJ International Conference on Intelligent Robots and System (IROS), pp.22-26, 2008.
- [Rusu2010] R.B.Rusu, G.Bradschi, R.Thibaux, J.Hsu, Fast 3D Recognition and Pose Using the Viewpoint Feature Histogram, IEEE/RSJ International Conference on Intelligent Robots and System (IROS), pp.2155-2162, 2010.
- [Shibata2013] Yutaro Shibata, Manabu Hashimoto, An Extended Method of the Parametric Eigenspace Method by Automatic Background Elimination, Proceeding of 19th Korea-Japan Joint Workshop on Frontiers of Computer Vision (FCV), pp.246-249, 2013.
- [Shin2007] J.Shih, C.Lee, J.T.Wang, A New 3D Model Retrieval Approach Based on the Elevation Descriptor, Pattern Recognition, Vol.40, pp.283-295, 2007.
- [Sumi1997] 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.
- [Takahashi2015] 高橋祥平, 武井翔一, 永瀬誠信, 秋月秀一, 橋本学, 点群の粗さに依存しない物体認識のためのRPD (Relative Point Density) 特徴量の提案, DIA2015, 2015.
- [Tateno2010] 立野圭祐, 小竹大輔, 内山晋二, 実部品のピッキングのための距離・濃淡画像を最尤に統合する高精度高安定なモデルフィッティング法, 画像の認識・理解シンポジウム (MIRU2010), IS2-4, pp.714-721, 2010.
- [Takeguchi2001] 武口智行, 金子俊一, 近藤司, 五十嵐悟, 距離アスペクト画像の2次元照合によるロボスト物体認識, 電学論 D-II, Vol.J84-D-II, No.8, pp.1710-1721, 2001.
- [Tombari2010] F.Tombari, S.Salti, L.D.Stefano, Unique Signatures of Histograms for Local Surface Description, European Conference on Computer Vision (ECCV), pp.356-369, 2010.
- [Ulrich2009] M.Ulrich, C.Wiedemann, C.Steger, CAD-Based Recognition of 3D Objects In Monocular Images, Proceedings. IEEE International Conference on

Robotics and Automation (ICRA), pp.2090-2097, 2009.  
[Zaharescu2009] A.Zaharescu, E.Boyer, K.Varanasi, R.Horaud, Surface Feature Detection and Description with Applications to Mesh Matching, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp373-380, 2009.  
[ZinBer2003] T.ZinBer, J.Schmidt, H.Niemann, A Refind ICP Algorithm for Robust 3-D Correspondence Estimation, Proceedings. International Conference on Image Processing (ICIP), Vol.3, pp.II-695-8, 2003.