多重投票に基づくペア特徴の信頼性評価を考慮した ばら積み部品姿勢推定における誤認識低減*

川西 亮輔** 堂前 幸康** 奥田 晴久***

Improvement of Pose Estimation by Reliability Evaluation based on Repeated Voting of Point Pair Features

Ryosuke KAWANISHI, Yukiyasu DOMAE and Haruhisa OKUDA

This paper describes an improvement of object pose estimation method for bin-picking problem. A bin-picking system by using industrial robots contributes to factory automatization. Industrial robots need to recognize the poses of the object in a bin because they have different poses. We propose a pose estimation method based on point pair feature (PPF) matching. PPF is pose-invariant and has high robustness of occlusion situation. PPF matching performs well in easy bin scenes. However, the successful rate of the pose estimation by PPF matching often decreases in some difficult scenes such as a bin with shiny or black objects because these objects cause bad measurement data with sparse point clouds and low signal-to-noise ratio. Our proposal evaluates PPF reliability by using PPF correspondence between scene data and object database. A PPF which votes for the same pose several times causes false pose generation. Thus, we judge such PPFs unreliable. By rejection of poses generated by using unreliable PPFs, successful rate of pose estimation increased 45% in a difficult bin scene with shiny and black objects. Experimental results show effectiveness of our proposal.

Key words: bin picking, pose estimation, point pair feature

1. 緒 言

近年、産業用ロボットを用いた生産システムの自動化への期待が高まっている。自動化が望まれるタスクは今後さらに複雑化することが予想されるため、産業用ロボットのより高度な知能化技術が必要である。産業用ロボットの知能化技術の取り組みとして文献^{1)~3)}がある。

一般に産業用ロボットを用いた生産システムでは、人手でトレイに部品を整列させ、決まった姿勢でロボットに供給する(図1左)。これには部品整列のための作業員および部品の数だけ専用トレイが必要となるため、部品数の増加に伴い作業負担の増大やスペース効率・コストパフォーマンスの低下といった問題がある。これに対しばら積みの状態で部品を供給する場合は、部品数によらず1つのロボットシステムを導入すれば24時間稼働が可能であるという利点がある。ここでばら積みとは、複数の部品が位置や傾き(以下、まとめて姿勢と呼ぶ)の規則性なく積み重ねられている状態である(図1右)。ばら積み部品の取り扱いにはロボット知能化のための重要な技術課題の1つである。

ロボットが姿勢不定なばら積み部品を取り扱う方法には大きく分けて3つある。(i) 部品姿勢によらず把持位置を決定する方法^{4)~6)}、(ii) 計測データに円筒等のプリミティブを当てはめて把持姿勢を決定する方法^{7,8)}、(iii) 3D CAD等の部品モデルを当てはめて部品姿勢を推定する方法^{9)~14)}である。(i)はシーンにハンドモデルを当てはめることで直接的に把持位置を得る。処理が単純であるため高速なピッキングを実現できるが、把持位置を指定できないという課題がある。そのため部品組付などの精密なタスクに適用するためには複数ロボットを使用する等、追加装置が必要である。(ii)は(i)と(iii)の中間的な手法で、単純形状の

組み合わせで構成される部品には非常に有効であるが複雑形状物体には対応できない。(iii)は処理コストが高いという課題はあるが推定された姿勢を利用することで部品組付など高度なタスクの自動化が期待できる。いずれの手法にも一長一短があるが、本論文ではより高度なタスクの自動化が可能である(iii)部品モデル当てはめによる部品姿勢推定手法について焦点を当てる。

部品姿勢推定は、ばら積み状態の3次元計測結果と部品モデルとの位置合わせをすることにより実現する。位置合わせの方式には、(a) 3次元計測点群と部品モデルとの位置合わせ誤差の最小化問題を解く方式、(b) 各視点から見た部品モデルの画像を記憶しておきシーンの画像とマッチングする方式、(c) 部品の局所特徴の対応付けに基づく方式がある。(a)の手法にICPアルゴリズム⁹⁾がある。この手法は理想的な条件においては精密な姿勢推定が可能であるが、局所解に陥りやすいという課題がある。(b)の手法には対象部品のエッジや点群情報の2次元画像を記憶しておきシーンと照合することで姿勢を推定する Chamfer Matching¹⁰⁾や Spin Image¹¹⁾がある。これらの手法は背景に何も存在しない状態を仮定してデータセットを作成するため、多数の部品が積み重なるばら積みシーンには不向きである。(c)の手法にはペア特徴(PPF: Point Pair Feature)照合による姿勢推定手法^{12)~14)}がある。ペア特徴は面上の点やエッジ上の点などの特徴点や線の組からなる特徴である。特徴点間の相対的な距離や、(その点を含む)面の法線やエッジの勾配方向を用いて記述される。

Fig. 1 Industrial parts. The left figure shows parts aligned in the designated case. The right figure shows parts piled in the bin

* 原稿受付 平成 26 年 3 月 31 日

掲載決定 平成 26 年 7 月 11 日

** 正 会 員 三菱電機株式会社 先端技術総合研究所 (兵庫県尼崎市塚口本町 8-1-1)

*** 三菱電機株式会社 名古屋製作所 (愛知県名古屋市中区矢田南 5-1-14)

部品モデルとシーンとでペア特徴を対応付けることで、部品モデルの姿勢に対する相対姿勢として部品姿勢が得られる。この特徴量は姿勢変化に対して不変で、かつ局所的な特徴であるため背景の影響を受けにくいという性質から、ばら積みシーンに適しているといえる。そこで本研究では(c)の一種であるペア特徴照合による姿勢推定手法^{12)~14)}を採用する。

部品モデルとシーンとでペア特徴の正しい対応関係が得られれば一意に部品姿勢を算出できる。しかし一般に物体は類似したペア特徴を複数有しているため、どのペア特徴との対応付けが正しいかを判定する必要がある。そこで多数のペア特徴を利用し、それぞれの対応関係から算出された姿勢に投票する。そして最多投票数である姿勢を部品姿勢として決定する。この投票処理は一般化ハフ変換¹⁵⁾の一種であると考えてよい。正しく対応付けられたペア特徴から算出される姿勢は部品姿勢と一致するのに対し、誤った対応付けによって算出される姿勢は部品と一致せず、それぞれ異なる姿勢となる可能性が高い。そのため部品と一致しない姿勢への投票数は分散し部品姿勢と比べて少なくなることが期待される。

しかしシーンや対象部品によっては誤った姿勢への投票数が最多数となるケースがあることが実験的に確認されている。そのため誤った姿勢を部品姿勢として決定してしまう（姿勢を誤認識する）という課題がある。

Fig. 2 B2B feature. The top left figure shows an example of target 3D-CAD. The top right figure shows extracted edge points and their pairing. The bottom figure shows feature representation of PPF

そこで本論文では誤った姿勢へ投票が集中する原因を解析する。解析結果に基づき定義したペア特徴の信頼性を考慮することで姿勢の誤認識を低減させる手法を提案する。実験では、提案手法により姿勢推定の成功率（認識率）が向上するとともに、処理時間が短縮される効果も得られることを示す。

2. ペア特徴照合¹²⁾¹⁴⁾による姿勢推定

提案手法における姿勢推定の基本原理は Drost らのペア特徴照合¹²⁾に基づいており、ペア特徴としては Choi らが提案する B2B (Boundary-to-Boundary) 特徴¹⁴⁾を用いる。B2B 特徴は物体のエッジ点の組からなり、エッジ点を結んだ線分とエッジ勾配のなす角度 (図2の $\theta_1, \theta_2, \theta_3$) と距離 (図2の $\|d\|$) の4次元特徴ベクトルとして

$$\mathbf{F}_{B2B} = (\theta_1, \theta_2, \theta_3, d)^T = (\angle(\mathbf{n}_m, \mathbf{n}_s), \angle(\mathbf{n}_m, \mathbf{d}), \angle(\mathbf{n}_s, \mathbf{d}), \|\mathbf{d}\|)^T \quad (1)$$

と表される。ここで $\mathbf{n}_s, \mathbf{n}_m$ はそれぞれエッジ点 $\mathbf{p}_s, \mathbf{p}_m$ のエッジ勾配方向である。B2B 特徴は平面的かつ直線的な形状で構成される工業部品の姿勢推定に有効である。また面上の点を用いる場合と比べエッジ点は相対的に数が少ないため、処理に必要なメモリ量の削減および処理時間の短縮が期待できる。

以下ではペア特徴照合による姿勢推定手法の処理手順について簡潔に述べる。処理の流れを図3に示す。数式等の詳細については文献¹²⁾¹⁴⁾を参照されたい。まず事前に対象部品のペア特徴を登録したデータセットを作成する。部品モデルの投影画像から Canny オペレータ¹⁶⁾などのエッジ検出器を用いてエッジ点を抽出する。エッジ点周辺の3次元点群データを直線にフィッティングすることによって3次元的なエッジ勾配方向を算出する。2点のエッジ点を組にしてペア特徴を作成する。ペア特徴は2つのエッジ点のうち1つが姿勢算出の基準となる点（基点）である。同じエッジ点ペアであっても基点が違えば異なる特徴として扱う。特徴ベクトル $\mathbf{F}_{B2B}$ に加えて基点の3次元座標とインデックスもデータセットに登録される。このとき、類似したペア特徴ごとに分類して登録することでマッチング時のアクセスを高速化する。

次に姿勢推定について述べる。ばら積みシーンから基点を選択する。ペアとなるエッジ点を選択してペア特徴を作成する。データセット中で類似したペア特徴を検索し、シーンとデータセットとのペア特徴間の相対姿勢を算出する。算出された姿勢

Fig. 3 Procedure of PPF matching¹²⁾¹⁴⁾ based pose estimation

パラメータとデータセット中のペア特徴の基点に対応するビン（投票空間を区切ったマス）に投票する。これをペアとなるエッジ点を変えて繰り返し行い、投票数 n が閾値以上である姿勢（姿勢仮説）のみ取り出してそれ以外は破棄する。以上の処理をばら積みシーンの基点を変えて繰り返し行う。このとき投票空間は基点を変えるたびに初期化される。シーンのエッジ点の中には認識対象のエッジではないものも含まれているが、事前にそれを知ることは困難であるため、本手法ではペア特徴を作成する際の基点としてシーンのエッジ点すべてを用いている。

得られた姿勢仮説をクラスタリングし、クラスタ内姿勢仮説の合計投票数 N が大きい順に部品姿勢候補とする。クラスタの姿勢はクラスタ内の各姿勢仮説 h の投票数 n_h で重みをつけ以下の式で算出される。

$$\mathbf{q} = \sum_h \frac{n_h \mathbf{q}_h}{N}, \quad \mathbf{t} = \sum_h \frac{n_h \mathbf{t}_h}{N} \quad (2)$$

ここで $\mathbf{q}$, $\mathbf{t}$ はそれぞれ部品モデルに対するばら積みシーンの部品の相対的な回転と並進を表す。ただし回転 $\mathbf{q}$ は任意の回転軸と回転角から算出される quaternion で表現している。

最後に各クラスタの姿勢を初期値としてシーンの 3 次元点群データと部品モデルとを ICP アルゴリズムによって位置合わせし、シーン点群 - モデル間の平均距離が最も短い姿勢を部品姿勢として決定する。

3. 多重投票による誤認識

ペア特徴照合による姿勢推定において部品を誤認識する原因は様々である。本論文ではその中でも姿勢への多重投票という現象について焦点を当てる。多重投票とは、シーンペア特徴とデータセットペア特徴とをマッチングさせた際に、同じビン（すなわち姿勢）に複数回投票される現象である（図 4）。多重投票の例としては、データセット中に同じエッジ点を基点とし、もう 1 つのエッジ点の距離が近いペア特徴が複数存在するようなときに発生する（図 5）。これはシーンペア特徴と照合するデータセットペア特徴の中に上記のようなペア特徴が含まれる場

Fig. 4 Normal voting and repeated voting for poses

Fig. 5 An example of similar PPFs. The positions of edge points which compose these PPFs are near each other

合は同じような姿勢が複数算出されるからである。ここでデータセットペア特徴の基点が同じであるという条件は多重投票が発生する例のひとつであり必須条件ではない。

投票数が多いということはその姿勢仮説が多数のシーンペア特徴とマッチングしており部品姿勢としての信頼性が高いことを意味する。しかし多重投票が起こるとマッチングしたシーンペア特徴が少ないにもかかわらず投票数が多い姿勢仮説が生成される。そのため実際にはマッチングする特徴が少なく信頼性が低いにもかかわらず、見た目の投票数が多いため信頼性が高い姿勢仮説のように見えるという問題が生じる。

さらに、ばら積みシーンでは複数の部品が隣接しているため同一部品上のエッジ点の組でないペア特徴（偽のペア特徴）が作成される（図 6）。偽のペア特徴かどうかを部品姿勢推定前に判別することは困難であるため、偽のペア特徴で多重投票が起きて生成される姿勢を部品姿勢と誤認識する可能性がある。

また正しい部品上のペア特徴で多重投票が起きた場合でも式 (2) によりクラスタ姿勢を算出する際に悪影響がある。多重投票が起きると同じような姿勢が多数生成されるため、クラスタ内でも姿勢の分布が偏る（図 7）。これにより信頼性の低い多重投票により生成された姿勢により近い姿勢がクラスタ姿勢として算出される。

4. ペア特徴の信頼性評価に基づく誤認識低減手法

本論文では多重投票による問題を解消することで誤認識を低減する手法を提案する。多重投票を回避するためには、シーンとデータセットとでペア特徴が 1 対 1 対応となればよい。そのための対策として、データセットのビンサイズを調節する方法がある。ビンを細かく区切り近接した類似ペア特徴（図 5）が同じビンに登録されないようにすれば多重投票は起こらないが、データセット容量が大きくなる、あるいは疎になるため認識率が低下したり姿勢推定の精度が低下したりするといった問題がある。ペア特徴の元となるエッジ点の抽出間隔を十分に広げること考えられるが、この場合もデータセットが疎になる問題が残る。そのほかに多重投票しやすいペア特徴をあらかじめ学習しておき姿勢推定に用いないようにする方法も考えられる。しかし実際には多くのペア特徴が多重投票しうるため利用でき

Fig. 6 An example of a PPF which causes false poses generation. The PPF consists of edge points extracted from different objects

Fig. 7 Deviation of the pose hypotheses distribution in a pose cluster

るペア特徴が著しく減少する。

以上のように多重投票そのものを回避するのは困難である。そこで提案手法では姿勢仮説の生成条件および姿勢クラスターの順位決定を、投票数ではなく“姿勢算出に用いたシーンペア特徴の数”とすることにより解決する。これによりシーン-データセット間でペア特徴が1対1対応になっている状態と実質的に同等の効果があるうえ、データセットが疎になることもなく、抽出可能なペア特徴をすべて利用できる。さらに実装上はペア特徴の種類をカウントするだけでよいため処理が簡単である。

クラスターの姿勢算出に偏りが生じる問題は、姿勢仮説 h に対する多重投票数 V_h に基づき以下の式で重み w_h を設定することで解決する。

$$w_h = 1/V_h \quad (3)$$

多重投票するシーンペア特徴はどのデータセットペア特徴とも正しく対応するのか不明であり、そもそも正しく対応するペア特徴がない可能性もある。また多重投票の多い姿勢は周囲に似た特徴が多数あることを意味しており、逆に多重投票の少ない姿勢は周囲に似た特徴が少なく、よりユニークで姿勢推定に適した特徴であるといえる。以上のことから多重投票の多い姿勢に対して重みを小さく（信頼度を低く）設定する。提案手法ではクラスターの姿勢を重み w_h とクラスター内の重みの和 W を用いて以下の式で算出する。

$$\mathbf{q} = \sum_h \bar{w}_h \mathbf{q}_h, \quad \mathbf{t} = \sum_h \bar{w}_h \mathbf{t}_h \quad (4)$$

$$\bar{w}_h = \frac{1}{2} \left(\frac{n_h}{N} + \frac{w_h}{W} \right) \quad (5)$$

ここで、クラスター内の姿勢仮説は必ずしも精度良く部品姿勢を推定していない。ばら積み部品の姿勢推定のようなケースでは正確なクラスタリングのために必要なクラスター数等のパラメータを事前に設定することが困難であるため、クラスタリングでは姿勢の大まかな分類しかしない。そのため状況によっては誤差の大きい姿勢仮説がクラスターに統合され部品姿勢推定の精度が低下することがある。

提案手法ではそのような誤差の大きい姿勢仮説を RANSAC¹⁷⁾ に基づくロバスト推定法によりアウトライアと判定し除外する。この際、多重投票されたクラスターでは投票数の偏りから精度の良い姿勢仮説がアウトライアと誤判定される恐れがあるため、重み w_h を用いることで多重投票の影響を排除することが重要である。

アウトライア判定の処理手順を以下に述べる。ランダムに選択したクラスター内の姿勢仮説 i に対する誤差が以下の式を満たす姿勢仮説 j の数 P_{num} をカウントする。

$$w_{hj} \left(\|\mathbf{q}_j - \mathbf{q}_i\| + \|\mathbf{t}_j - \mathbf{t}_i\| \right) < E_{th} \quad (6)$$

Fig. 8 Experimental conditions

ここで E_{th} は閾値である。この処理を、姿勢仮説 i を変えて繰り返し P_{num} が最大となるときの式(6)を満たさない姿勢仮説をアウトライアと判定し除外する。最終的にアウトライアを除外したクラスターの中でシーンペア特徴数が多い順に部品姿勢候補とする。

5. 実験

提案手法の有効性を示すため、実際にばら積みした部品の姿勢推定実験を行った。実験環境を図8に示す。実験に用いた7種類の部品を図9に示す。ばら積みシーンの3次元点群と距離画像は、無作為に作成した100例のシーンを3次元ビジョンセンサで計測することによって取得した。使用したセンサは三菱電機製 MELFA-3D Vision、計測方式は空間コード化法である。計測有効点数は30~60万点、視野角は15~20度、奥行き方向の計測誤差は最小0.3mm、カメラ解像度は最大1280×960ピクセルである。用いた計算機はCPU: Core i5-2400、メモリ: 2GBである。今回の実験では推定された部品姿勢における3D CADと計測された点群データとを重ね合わせたときの平均距離が一定値以下となった場合を姿勢推定成功とした。計測データそれぞれに対し従来手法¹⁴⁾と提案手法を適用し認識率および処理時間を比較した。

認識率および処理時間の比較をそれぞれ表1, 2に、部品の3D CADおよび姿勢推定結果の例を図10に示す。従来手法で特に認識率が低かったObject 7において、提案手法では認識率が45%向上した。対象部品によっても異なるが、認識率が9割以上であれば把持失敗時のエラーリカバリなど運用上の工夫をすることで実用可能な段階に達する。4割程度であった部品の認識率が提案手法によって8割以上となり、大幅に実用段階に近づいた。また全体として提案手法は従来手法と比べ処理時間が短縮されており、Object 7においては約7秒短縮された。実験結果より提案手法の有効性が示された。

Object 7は黒色かつ光沢のある部品であり、部分的に計測できなかったりノイズの影響を大きく受けたりする。結果として部品エッジ以外のエッジ点からなる偽のペア特徴が多数作成されていた。これに多重投票が重なることで誤った姿勢仮説が多数生成されたのが誤認識の原因であったと思われる。提案手法により多重投票を排除し誤った姿勢仮説の生成を抑制することで認識率を向上させることができた。

提案手法によっても誤認識となった例としては、部品表面の

Fig. 9 Target objects and their circumscribed cube size [mm]

光沢などの影響で認識するのに十分な計測データが得られなかったケースや、裏表など異なる姿勢で類似した形状が見られるワークなどが挙げられる。これに対しては計測アルゴリズムの改良および姿勢に固有な特徴を選択して姿勢推定を行うなどの改善が必要である。

また提案手法は従来手法と比べ生成される姿勢仮説の数が少ないため、全体として処理コストが低減され処理時間が短縮された。特に Object7 のようにサイズが大きく多数の特徴が抽出される部品は小さい部品と比べ多数の姿勢仮説が生成されるため、提案手法による姿勢仮説の削減効果が大きかったと考えられる。一方、多重投票を抑制することで正しい姿勢が削除されたり投票数が少なくなったりすることがあり、結果的に姿勢推定の精度が低下するケースがある。ただし推定精度の低下は多重投票の有無だけが問題ではなく、計測データの S/N が悪かったりオクルージョンによって部品エッジが一部得られなかったりすることも根本的な要因として挙げられる。

6. 結 言

本論文ではペア特徴照合によるばら積み部品姿勢推定の認識率向上のために、姿勢仮説の信頼性評価を考慮したアウトライア除去による誤認識低減手法を提案した。これにより誤認識の原因となる誤った姿勢仮説の生成を減らすことができる。またクラスタリング処理において姿勢算出時に多重投票の悪影響を低減することができる。さらには誤った姿勢仮説の生成数が少なくなったことで、認識率を維持したまま処理時間が大幅に短縮されるという効果も得られる。実験結果より提案手法の有効性が示された。

今後の課題としては、部品サイズによらずに一定の処理コストと認識率で姿勢を推定可能な手法の構築が挙げられる。現状のアルゴリズムでは画像上の見た目のサイズもしくは実サイズが大きい部品ほど、抽出される特徴の数が多いため処理時間が長くなる傾向がある。認識率を維持したまま処理時間を短くするためには、適切な特徴選択手法を適用することで姿勢認識に寄与しない余分な特徴のみを排除する必要がある。

謝 辞

本研究を進めるにあたり、技術提供いただいた Mitsubishi Electric Research Laboratories の田口裕一氏、実装・検証にご協力いただいた元三菱電機名古屋製作所の北明靖雄氏、技術的なディスカッションにご参加いただいた三菱電機先端技術総合研究所の渡邊信太郎氏、関真規氏、平位隆史氏に深く感謝いたします。

参 考 文 献

- 1) 平井: “戦略的先端ロボット要素技術開発プロジェクト,” 日本ロボット学会論文誌, 27, 10 (2009) 2.
- 2) 鷺見: “柔軟物も取り扱える生産用ロボットシステムの開発,” 日本ロボット学会論文誌, 27, 10 (2009) 4.
- 3) 野田ほか: “次世代セル生産を実現するロボット知能化技術,” 第 10 回 SICE システムインテグレーション部門講演会論文集 (2009) 766.
- 4) Domae, et al.: “Fast Grasability Evaluation on Single Depth Maps for Bin Picking with General Grippers,” ICRA2014 (2014).
- 5) Rao, et al.: “Grasping novel objects with depth segmentation,” IROS2010 (2010) 2578.
- 6) Hupfau, et al.: “Grasp Densities for Grasp Refinement in Industrial Bin Picking,” IEEE ICRA 2011 Workshop on Uncertainty in Automation, 2011.
- 7) Liu, et al.: “Ellipse Detection Based Bin-Picking Visual Servoing System,” CCPR2010, (2010) 1.
- 8) Lee, et al.: “3D Visual Perception System for Bin Picking in Automotive Sub-Assembly,” Automation/IEEE CASE 2012, (2012) 706.
- 9) Faugeras and Hebert: “The Representation, Recognition, and Locating of 3-D Objects,” International Journal of Robotics Research, 5, 3 (1986).

- 10) Borgefors: “Hierarchical Chamfer Matching: A Parametric Edge Matching Algorithm,” IEEE Transactions on Pattern Analysis and Machine Intelligence, 10, 6 (1988) 849.
- 11) Johnson and Hebert: “Efficient Multiple Model Recognition in Cluttered 3-d Scenes,” CVPR (1998) 671.
- 12) Drost, et al.: “Model Globally, Match Locally: Efficient and Robust 3D Object Recognition,” CVPR (2010) 998.
- 13) Buchholz, et al.: “RANSAM for Industrial Bin-Picking,” ISR / ROBOTIK 2010 (2010) 1317.
- 14) Choi, et al.: “Voting-Based Pose Estimation for Robotic Assembly Using a 3D Sensor,” ICRA2012 (2012) 1724.
- 15) Ballard: “Generalizing the Hough transform to detect arbitrary shapes,” Pattern Recognition, 13, 2 (1981) 111.
- 16) Canny: “A Computational Approach to Edge Detection,” IEEE Transactions on Pattern Analysis and Machine Intelligence, 8, 6 (1986) 679.
- 17) Fischler and Bolles: “Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography,” Communications of the ACM, 24, 6 (1981) 381.

Table 1 Experimental results of pose estimation successful rate

	Conventional PPF matching %	PPF matching with Our Proposal %
Object 1	87	100
Object 2	100	100
Object 3	92	95
Object 4	68	81
Object 5	89	89
Object 6	99	99
Object 7	41	86

Table 2 Experimental results of processing time

	Conventional PPF matching ms	PPF matching with Our Proposal ms
Object 1	4853	2371
Object 2	4934	2550
Object 3	2580	2474
Object 4	1355	1279
Object 5	3547	2455
Object 6	1323	1156
Object 7	12655	5863

Fig. 10 Pose estimation results. White frames show estimated poses of objects