

情報構造化環境における日用品の追跡

－ 3次元ポイントクラウドを用いた変化箇所の検出と物体識別 －

蔡 現旭^{*1}, 桑畑 舜也^{*1}, マルティネス モゾス オスカル^{*2},
長谷川 勉^{*2}, 辻 徳生^{*2}, 諸岡 健一^{*2}, 倉爪 亮^{*2}

Tracking Everyday Objects in the Informationally Structured Environments -- Spatial Change Detection in 3D Point Cloud and Categorization of Objects in the Scene --

Hyunk CHAE^{*1}, Shunya KUWAHATA^{*1}, Oscar MARTINEZ MOZOS^{*2},
Tutomu HASEGAWA^{*2}, Tokuo TSUJI^{*2}, Ken'ichi MOROOKA^{*2} and
Ryo KURAZUME^{*2}

^{*1} Graduate School of Information Science and Electrical Engineering, Kyushu University
744 Motooka, Nishi-ku, Fukuoka 819-0395 Japan

^{*2} Faculty of Information Science and Electrical Engineering, Kyusyu University
744 Motooka, Nishi-ku, Fukuoka 819-0395 Japan

This paper presents an everyday object detector that is integrated in an informationally structured environment that supports a personal service robot. Our approach detects changes in the environment by comparing 3D point cloud representing the same scene at different times and from different viewpoints. Detected changes are indicated by point clusters that are later categorized into a set of everyday objects such as cup, book or pet bottle. This system is used by a service robot to keep track of new objects that appear in the environment. In addition, we show experiments that validate our approach in different scenarios.

Key Words : RGB-D sensor, Object detection, Object categorization

1. はじめに

ロボットが人間と共存し、高齢者や身体障害者のための生活支援作業を行うことは、社会的、経済的に重要な研究課題の一つである。対象者に対する日用品の取り寄せや部屋の片づけなどの作業をロボットが代替することで、介護の人手不足の解消が期待できるため、多くの研究が行われてきた⁽¹⁾⁻⁽⁴⁾。生活支援作業を実現するためには多くの課題があるが、中でも環境内の小物物品の位置情報の認識は非常に重要である。高齢者介護施設の居住個室や、よく整理されたオフィスなど、存在する家具や日用小物が少ない環境であれば、人が各物品の初期配置を計測しコンピュータに入力することもできる。しかし、居住者の生活活動により、物品配置は変化する。日用品の追跡を自動化して環境情報を常時更新することができれば、生活支援ロボットの実現に向けた大きな前進である。

これまでに、作業対象となる日用品の配置情報の獲

得に関する様々な研究がなされている⁽⁶⁾⁻⁽¹⁰⁾。Fukui らは収納庫内に設置された RFID リーダーを用いて物品の出入を検出している⁽⁶⁾。しかし、物品が収納庫の外に出た場合は追跡することができない。より広い室内での物品追跡を実現するため、Nishida らは Ultrasonic タグを物品に付着しておき、天井に設置された受信機で物品を検出している⁽⁷⁾。また、Deyle らは UHF-RFID タグと特徴的な色を持つタグを物体に貼付しておき、RFID から発せられる信号の電界強度を指向性アンテナで検出して、その方向を求めたうえで、ビジョンによるカラー情報処理により物体を検出する⁽⁸⁾。前者ではタグのサイズが大きく高価である。後者では、指向性アンテナを走査する必要があり、位置の分解度も十分ではなく画像処理も併用している。また、Nelson と Green は、天井付近にカメラを設置し、部屋内の物体認識により物品追跡を行っている⁽⁹⁾。さらに、Odashima らも、室内の固定カメラで差分画像処理により物体移動を検知する手法を提案している⁽¹⁰⁾。しかし、固定カメラでは、人によるオクルージョンが多く発生する。加えて、カメラで環境内を常時撮影する必要があるの

^{*1} 九州大学大学院システム情報科学府 (〒819-0395 福岡市西
区元岡 744 番地) {huchae, kuwahata}@irvs.ait.kyushu-u.ac.jp

^{*2} 九州大学大学院システム情報科学府 (〒819-0395 福岡
市西区元岡 744 番地) omozos@irvs.ait.kyushu-u.ac.jp
{hasegawa, tsuji, morooka, kurazume}@ait.kyushu-u.ac.jp

で、プライバシーの侵害が避けられない、さらに広域視野の確保と分解能の両立も難しい。

我々は、環境内に複数のセンサを分散配置した情報環境構造化システムを開発している⁽⁵⁾⁽¹¹⁾⁽¹²⁾⁽¹³⁾。このシステムでは、環境分散センサで人や物の位置情報などの環境情報を取得してデータマネジメントシステムで管理する。ロボットは作業に必要な情報を受け取り、生活支援を実現する。

環境分散センサとして、知的収納庫とフロアセンシングシステムを用いている。知的収納庫は RFID リーダーと圧力センサを用いて、庫内の RFID タグ貼付物品を認識しその出入管理ができる⁽¹¹⁾。フロアセンシングシステムは床直上をスキャンするように設置された Laser Range Finder (LRF) で、床上に置かれた物体の検出や移動体の追跡を行うものである⁽⁵⁾⁽¹¹⁾⁽¹²⁾。

一方、生活環境中には、テーブル、机、椅子、ベッドなど家具がある。これらの上には、日用品が置かれることも多いが、その種類も置かれた状況もさまざまであるため、それぞれの家具にセンサを設置して認識するのは難しい。このため、これらの領域は情報構造化環境における死角領域となっていた。

本論文では、移動ロボットに搭載した RGB-D 視覚センサを用いて、環境分散センサの死角領域であるテーブル、机の上の日用品を識別する手法を提案する。識別をセンサの視野内にあるすべての物品に対して行うと、処理コストが非常にかかる。それを低減するために、提案手法では対象場所の前時刻の情景との変化箇所だけに注目して識別を行う。画像処理手法としては、対象場所の低レベルの 3 次元点群データを記憶情報として保存し、新たに取得したデータとの差分を変化箇所として検出し、物体識別を行う。

3 次元物体識別のために、Histogram に基づく色々な記述子が提案されている⁽¹⁵⁾⁻⁽²⁰⁾。Alexandre は Lai らの RGB-D 物体データセット⁽²¹⁾を用いた物体識別において、PFH (Point Feature Histogram)⁽¹⁵⁾、VFH (Viewpoint Feature Histogram)⁽¹⁶⁾、SHOT (Signature of Histogram of Orientation)⁽¹⁷⁾⁽¹⁸⁾などの特徴記述子を比較している⁽²⁰⁾。その結果、SHOT が識別率と計算コストの両方で共に良い性能を示した。本稿では検出された変化箇所に対して、SHOT 特徴量を用いて物品識別を行う。

システムとしての実装は、日用品の取り寄せなどの直接的な生活支援作業を行うロボットに、移動センシング機能を付加するもので、環境変化を認識して構造化情報を更新することを役割に加える。視覚センサとしては、Kinect センサ⁽²³⁾を用いる。このセンサは安価で

あり、高速に RGB 画像および距離情報を得ることができる。

ロボットに視覚センサを搭載するため、居住者が映り込む可能性もあるが、不都合があれば、移動ロボットの行動を制止できるので、プライバシーの侵害を抑制できる。

第 2 章では情報環境構造化システム、第 3 章と第 4 章ではポイントクラウドを用いた変化箇所の検出と識別について述べる。第 5 章で提案手法による実験について示す。

2. 情報環境構造化システム

情報環境構造化システムの構成と環境分散センサについて述べる。図 1 のように、部屋には“収納庫”、“ベッド”、“机”、“テーブル”および“椅子”が置かれ、環境分散センサとして知的収納庫とフロアセンシングシステムが設置されている。

フロアセンシングシステムでは、壁の下部に設置された鏡により、2 つの異なる方向から床上をレーザでスキャンができるので、オクルージョンにロバストな検出ができる。




Fig. 1 Experiment room as our scenario. It includes cabinets, bed, desk, table, and so on.

ロボットは安川電機の SmartPal を用いる。このロボットは移動台車、7 つの関節を持つ 2 つのアーム、およびグリップで構成されている。頭上に搭載された Kinect センサから取得したカラー画像情報と奥行き情報に基づいて、テーブル上などのセンサ死角領域に置かれた日用品の探索・識別を行う⁽¹³⁾。

3. ビジョン搭載ロボットによる変化箇所検出

環境内のテーブルや机の上などの情景を Kinect センサで奥行き計測を行い、低レベル 3 D 記憶情報(ポイントクラウドデータ)として保存する。日用品を探索するときは、当該家具に接近して情景の奥行き計測を行い、

新たに 3D 情報を取得する。記憶情報と新規取得情報との差分をとり、変化を検出する。

2 つの情報の取得時のカメラ位置が異なるため、これらから単純な差分をとることで変化を検出するのは困難である。差分は、家具上面からの物品の高さの差とする。差分をとるには、情報間で対応を取る必要がある。高精度のレジストレーションを行わなければならない。レジストレーションには、フロアセンシングシステムにより取得できる情報（ロボットと家具の位置）と ICP（Iterative Closest Point）アルゴリズムを用いる。

図 2 の Detection pipeline は変化箇所検出アルゴリズムを示している。まず、2 つのデータから平面検出によって、家具の基準平面（テーブル・机の上面）をそれぞれ特定する。




Fig. 2 Schematic diagram for change detection and its categorization

次に、記憶情報と新規取得情報のレジストレーションを行う。家具上面に加え、家具を構成する箇所（テーブル前面・足など）を用いて行う。レジストレーションの手法には ICP を用いるが、局所解に陥る可能性を考慮し、事前にフロアセンシングシステムで取得したロボットと家具の位置から、回転・並進処理により、おおまかな位置合わせを行う。

次に、セグメンテーションを行う。平面を除去後、平面上に残るデータに対して行う。セグメントを変化箇所の候補となる家具上の物品とみなす。

その後、セグメント毎にエレベーションマップを作成する。マップには、物品の基準平面からの高さを記述する。まず基準平面をグリッド化し、各グリッドにおける物品の基準平面上からの高さをマップに記述する。

最後に、セグメント間マッチングを行う。マッチングされなかったセグメントを変化箇所とする。マッチングの条件には、4 つの項目がある。（1）セグメント

間の重心位置の距離、（2）基準平面からのセグメントの高さ（エレベーションマップの平均値、分散値）、

（3）セグメントの水平投影面積（マップの大きさ）、

（4）セグメントの色情報である。色情報には HSV 値の H 値（色相）を用いる。セグメントごとに H 値ヒストグラムを作成する。最頻値をとる H 値をセグメント間で比較する。セグメント間ですべての項目について大きな差がなければ、その組はマッチングしたとする。

差分処理で得られた変化箇所に対して、第 4 章で述べる識別処理を行う。これにより、情報内に存在するすべての物品の識別を行うよりも、誤認識や処理コストを低減することができる。

4. 検出された物品の識別

4・1 SHOT 特徴記述子を用いたポイントクラウドの特徴量の記述

SHOT 記述子⁽¹⁷⁾⁽¹⁸⁾は、3次元点群（ポイントクラウド）に対して、サーフェスマッチングを目的に Tombari らにより提案された。本稿では、検出した物品の識別に用いる。

まず、対象である物品のポイントクラウドデータの各点の法線ベクトルを計算する。サンプリング（sampling）して、各ボクセルのセンタを特徴点とする⁽¹⁴⁾。SHOT 特徴量は入力ポイントクラウドに対して、固有値分解を用いて各特徴点に基準座標系を定義する。まず、以下のように加重値線形結合として共分散行列 M を計算する。

$$M = \frac{\sum_{i: d_i \leq R} (R - d_i)(p_i - p)(p_i - p)^T}{\sum_{i: d_i \leq R} (R - d_i)}, \quad d_i = \sqrt{p_i - p} \quad (1)$$

d_i は p (中心点) と半径 R の範囲内にある p_i (近接点) との距離を表し、 $R - d_i$ は加重値を示す。したがって、式 (1) で二つの点間の距離 d が近い程 $R - d_i$ は大きくなり、その点は共分散行列 M に反映させる。ここで、計算した M の固有値と固有ベクトルを求めて、第 1, 第 2, 第 3 主成分を点 p の基準座標系とする。ただし、第 1 主成分と第 2 主成分の固有値が近い値をとる場合は、特徴点として使用しない。それから、定義した基準座標系と近接点の法線ベクトルとの角度 θ_i を内積により計算し、角度の $\cos \theta_i$ の頻度数をヒストグラムの各要素に蓄積する (Histograms of Orientations)。

基準座標系を軸として、球面グリッドを方位各により 8 分割、上下 2 分割、球面半径により 2 分割で 32 領域に分割する。これから、一つの特徴点に 11 外形ビン (bin) と 32 個の内積ヒストグラムで 352 の値を SHOT 特徴量として記述する。サポート領域 R と球体の各領域内のセクタヒストグラムビンの幅 b をきめる二つの

パラメータは入力データによって適当な選択が必要である。

4・2 識別方法 各データを特徴ベクトルに変換し、FLANN (Fast Library for Approximate Nearest Neighbor) ⁽¹⁴⁾⁽²²⁾を用いて、ベクトル間のマッチングポイントを計算する。マッチングポイント数 ($corr_i$) とデータの特徴点の数 (F_{model}, F_{test}) との比率を識別の判断基準 (D) として定義した (式2)。

$$D = \frac{corr_i}{\max(F_{model}, F_{test})} \quad (2)$$

入力された学習データと評価データにより計算した D が最大値を持つカテゴリを識別結果として決定した。

5. 実験

5・1 実験セッティングとデータセット 提案手法の精度評価のため、室内環境で2つのテーブルと1つの机で実験を行った。




Fig. 3 Set up for capturing data and captured data.

対象である家具上のデータ (記憶情報) を取得する。次に、家具上の情景と Kinect センサの視点を変化させ、新たにデータ (新規取得情報) を取得する (図 4)。これを各家具で5組ずつ用意し、それぞれの組で物品の変化箇所の検出を行う。その後、検出された箇所のデータを切り出し、物品識別を行う。

対象とした物品のカテゴリは図 5 に示すように“chipstar”, “book”, “cup”, “can”, および“pet bottle”の5つである。1つのカテゴリには色や種類が異なる3つの物体が含まれている。例えば, “chipstar”は3つの異色の chipstar が含まれており, “can”は3つの異種の can が含まれている。各物品に対して16方向に回転したデータを取得している (図 6), データセットの数は240 (=5x3x16) である。本の場合は両面の各面を8方向に回転した。



Fig. 4 Test data for change detection: (Left part) Memory data, (right part) Newly captured data. One set has two data which are captured in time and different point of view of a Kinect sensor.



Fig. 5 Dataset for everyday object with 5 categories



Fig. 6 Rotation of object (chipstar) for dataset.

5・2 変化箇所検出精度 記憶情報と新規取得情報を用いた変化箇所の検出を行い、その結果を表1にまとめた。検出精度は、変化箇所数に対する検出成功数の割合である。

Table 1 Result of change detection

	Change Number ¹	Correct Number	Correct Rate (%)
Table A	23	23	100.0
Table B	23	23	100.0
Desk	31	29	93.5
Total	77	75	97.4

ある程度の大きさの物品が変化したのであれば、高精度で変化箇所を検出できている。検出に失敗した例

¹ 表1の Change Number は図7の右側のように、各家具 (5つのデータペア) から検出された物品数の合計である。

の原因は、3D 情報から家具上面を特定するための平面検出に失敗したためであった。

図 7 で実験結果の一例を示す。この例では、すべての変化箇所を検出できている。入力データのそれぞれ右手前に置かれているコップは同じ位置にあり、形状もよく似ているのだが、色の違いにより変化箇所として検出できている。




Fig. 7 Results of change detection: Left part is memory and newly capture data (1 pair data of Table A), detected object from each data is shown in top-right and bottom-right images, respectively.

5・3 識別性能 構築したポイントクラウドのデータセットを用い、変化箇所として検出された物品の識別実験を行った。実験では、データセットでの精度確認（実験 1）と変化した場所の検出結果（実験 2）を用いた。

まず、実験 1 では 240 個のデータセットを学習データとし、その内にある 239 個のデータを評価データとして識別実験を行う。特徴点の選択のためサンプリングはボクセルグリッド (voxelgrid) のリーフサイズ (leaf size) を 1.0cm と 2.0cm とした ($V_s=0.01;0.02$)。SHOT 記述子のパラメータは $R=0.08$, $b=0.04$ とした。実験 1 の識別結果は表 2 に示す。表 2 より、2 つのリーフサイズにおいて“book”の識別精度が最も高かった。“book”のように直方体は他の 4 つの円柱形とは確と識別ができることを確認した。“chipstar”, “can”, “cup”, “pet bottle”のように外形が似ている場合、相対的に小さいものである“can”, “cup”の識別の難しかったことを挙げられた。リーフサイズごとの識別精度の平均は、 $V_s=1.0\text{cm}$ のとき 81.25%, $V_s=2.0\text{cm}$ のとき 70.83%であった。

リーフサイズによる計算時間は、1 回のマッチングにおいて、 $V_s=1.0\text{cm}$ のとき 568.88ms, $V_s=2.0\text{cm}$ のとき 159.52ms であった。

実験 2 では、各家具で配置変化の検出結果（表 1 の Correct Number）を評価データとして、データセットとの識別精度を評価した。識別精度は表 3 に示すように、Table A のとき 47.38%, Table B は 47.83%, Desk は 41.38%であった（平均 45.68%）。実験 1 と同一に“book”の識別精度は高かったが（平均 88.89%）、他の 4 つのカテゴリは物体の外形（円柱）が似ているため識別が難しかったと考えられる。各家具で変化箇所の検出結果とその識別結果の細部については、図 8 (7 ページ) に示す。

Table 2 Categorization result for experiment 1

Confusion matrix for $V_s=0.01$, average correct = **81.25%**

%	chipstar	book	can	cup	pet bottle
chipstar	95.83	0.00	2.08	0.00	2.08
book	0.00	100.00	0.00	0.00	0.00
can	10.42	0.00	58.33	10.42	20.83
cup	6.25	0.00	12.50	72.92	8.33
pet bottle	10.42	0.00	6.25	4.17	79.17

Confusion matrix for $V_s=0.02$, average correct = **70.83%**

%	chipstar	book	can	cup	pet bottle
chipstar	75.00	0.00	8.33	6.25	10.42
book	0.00	100.00	0.00	0.00	0.00
can	16.67	0.00	64.58	6.25	12.50
cup	12.50	0.00	25.00	52.08	10.42
pet bottle	27.08	0.00	6.25	4.17	62.50

Table 3 Categorization result for experiment 2

%	Table A	Table B	Desk	Average
Correct rate	47.38	47.83	41.38	45.68

実験 1 と実験 2 より、小さいものは十分なマッチングポイント数の獲得が重要であることを挙げられる。対象物体の特徴点（リーフサイズ）や記述子のパラメータなどの変化による識別結果が変わると考えられ、今後は入力データのポイント数と特徴点数との比率などにより、似ているカテゴリの識別精度を向上させる予定である。

6. 結論と今後の課題

生活環境における日用品の情報構造化の一環として、人の日常活動にともなう配置変化を検出し、その検出された位置にある物体を識別する手法について述べた。これは、生活支援を行う移動作業ロボットに視覚システムを搭載し、机やテーブルなど物品の置かれる可能性のある領域ごとに状況を記憶しておき、変化が生じたときに検知し変化物体配置を認識するものである。記憶情報として 3 次元ポイントクラウドを保存し、新たに得られたデータとの差分を用いて変化箇所を検出した。変化箇所に対して SHOT 記述量を計算し、マッチングポイント数を比較して識別した。配置変化の検出実験の結果、3 種類のテーブルと机において、高い

検出精度を示すことが確認された。5つの日用品のカテゴリにおいても識別を行い、約45%の識別を成功した。誤識別の原因であった外形が似ている物体の場合には、対象物体の入力データとそれの特徴量などについて検討する予定である。

謝辞 本研究はJSPS 科研費 22300069 の助成を受けたものです。

参考文献

- (1) L. C. Goron, Z. C. Marton, G. Lazea, and M. Beetz, "Automatic Layered 3D Reconstruction of Simplified Object Models for Grasping", *Joint 41st International Symposium on Robotics (ISR) and 6th German Conference on Robotics*, (2010), pp.1-6.
- (2) S. Zhu, D. Pangercic, and M. Beetz, "Contracting Curve Density Algorithm for Applications in Personal Robotics", *11th IEEE-RAS International Conference on Humanoid Robots*, (2011), pp. 171-178.
- (3) K. Lai, L. Bo, X. Ren, and Dieter Fox, "A Large-Scale Hierarchical Multi-View RGB-D Object Dataset", *Proc. of the IEEE International Conference on Robotics and Automation*, (2011), pp.1817-1824.
- (4) A. Janoch, S. Karayev, Y. Jia, J. T. Barron, M. Fritz, K. Saneko, and T. Darrell, "A Category-Level 3-D Object Dataset: Putting the Kinect to Work", *ICCV Workshop on Consumer Depth Cameras in Computer Vision*, (2011).
- (5) K. Murakami, K. Matsuo, T. Hasegawa, and R. Kurazume, "Position Tracking and Recognition of Everyday Objects by using Sensors Embedded in an Environment and Mounted on Mobile Robots", *Proc. of the IEEE International Conference on Robotics and Automation*, (2012), pp.2210-2216.
- (6) R. Fukui, H. Morishita, T. Mori, and T. Sato, "Development of a home-use automated container storage/retrieval system", *Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, (2008), pp.2875-2882.
- (7) T. Nishida, H. Aizawa, T. Hori, N. H. Hoffman, T. Kanade, and M. Kakikura, "3D Ultrasonic Tagging System for Observing Human Activity", *Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, Vol. 1, (2010), pp.785-791.
- (8) T. Deyle, H. Nguyen, M. S. Reynolds, and C. C. Kemp, "RFID-Guided Robots for Pervasive Automation", *IEEE Pervasive Computing*, Vol. 9, Issue 2, (2010), pp.37-45.
- (9) R. Nelson and I. Green, "Tracking Objects using Recognition", *Proc. of the International Conference on Pattern Recognition*, (2002), pp.1025-1039.
- (10) S. Odashima, T. Sato and T. Mori, "Household Object Management via Integration of Object Movement Detection from Multiple Cameras", *Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, (2010), pp.3187-3194.
- (11) K. Murakami, T. Hasegawa, Y. Nohara, B. W. Ahn, and R. Kurazume, "Position Tracking System for Commodities in a Daily Life Environment", *Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, (2010), pp.3712-3718.
- (12) Y. Nohara, T. Hasegawa, and K. Murakami, "Floor Sensing System using Laser Range Finder and Morror for Localizing Daily Life Commodities", *Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, (2010), pp.1030-1035.
- (13) 桑畑舜也, 長谷川勉, 蔡現旭, 諸岡健一, 倉爪亮, "情報構造化環境における日用品の追跡 - 移動ロボットによる低レベル視覚記憶の照合と変化検出 -", 日本ロボット学会第30回記念学術講演会, (2012), 2J2-7.
- (14) R. B. Rusu and S. Cousins, "3D is here: Point Cloud Library (PCL)", *Proc. of the IEEE International Conference on Robotics and Automation*, (2011), TuA215.
- (15) R. B. Rusu, N. Blodow, Z. C. Marton, and M. Beetz, "Aligning Point Cloud Views using Persistent Feature Histograms", *Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, (2008), pp.3384-3391.
- (16) R. B. Rusu, G. Bradski, R. Thibaux, and J. Hsu, "Fast 3D Recognition and Pose Using the Viewpoint Feature Histogram", *Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, (2010), pp.2155-2162.
- (17) F. Tombari, S. Salti, and L. Di Stefano, "Unique Signatures of Histograms for Local Surface Description", *11th European Conference on Computer Vision*, Part III, (2010), pp.356-369.
- (18) F. Tombari, S. Salti, and L. Di. Stefano, "A combined texture-shape descriptor for enhanced 3D feature matching", *18th IEEE International Conference on Image Processing*, (2011), pp.809-812.
- (19) J. Behley, V. Steinhage, and A. B. Cremers, "Performance of Histogram Descriptors for the Classification of 3D Laser Range Data in Urban Environments", *Proc. of the IEEE International Conference on Robotics and Automation*, (2012), pp.4391-4398.
- (20) L. A. Alexandre, "3D Descriptors for Object and Category Recognition: a Comparative Evaluation", *Workshop on Color-Depth Camera Fusion in Robotics at the IEEE/RSJ International Conference on Intelligent Robots and Systems*, (2012).
- (21) K. Lai, L. Bo, X. Ren, and D. Fox, "A Large-Scale Hierarchical Multi-View RGB-D Object Dataset", *Proc. of the International Conference on Robotics and Automation*, (2011), pp.1817-1824.
- (22) M. Muja and D. G. Lowe, "Fast Approximate Nearest Neighbors with Automatic Algorithm Configuration", *VISAPP International Conference on Computer Vision Theory and Applications*, (2009), pp.331-340.
- (23) Microsoft Kinect, <http://www.xbox.com/en-us/kinect>




Fig. 8 Results of change detection and categorization for experiment 2: left part is the set of previous and current scene in 3 different table and desk, right part is the detected clusters and its categorization results (black=true value, green=correct match, red=non-match)