

奥行きセンサを用いた能動的物体認識

Active Object Recognition Using Depth Sensor

中里 一幾 (九大) 諸岡 健一 (九大) ○ 宮内 翔子 (九大)
正 辻 徳生 (九大) 正 倉爪 亮 (九大)

Kazuki NAKAZATO, Kyushu University
Ken'ichi MOROOKA, Kyushu University, morooka@ait.kyushu-u.ac.jp
Syoko MIYAUCHI, Kyushu University
Tokuo TSUJI, Kyushu University
Ryo KURAZUME, Kyushu University

This paper presents a viewpoint planning method for an active object recognition by using the shape information of objects. The proposed method uses the certainty that a given object is classified into one category. The certainty is represented by a probabilistic model. Moreover, the categorization possibility of unknown objects are quantified by the entropy indicating the ambiguity of the recognition. When an object is observed, the certainty is calculated by using the measured data. For each viewpoint, the entropy is computed based on the certainty. We choose as a next viewpoint the viewpoint with minimum entropy. From the experimental results using real objects, the proposed method can achieve an efficient object recognition compared with the method which selects viewpoints randomly.

Key Words: Active object recognition, viewpoint planning

1 緒言

生活支援ロボットが行うサービスの一つに、日用品の運搬がある。このサービスを実現するためには、ロボットが目前にある物体を認識する機能が必要である。ロボットは、回り込む、覗き込むなど自身の位置・姿勢を変えたり、物体を把持し、その姿勢を変えることで、様々な方向から物体を観測できる。そこで、ロボットが、物体認識に有効な情報を積極的に取得・認識する、能動的物体認識機能を有することで、安定した物体認識が期待される。

能動的物体認識を実現するためには、認識に有効な情報が得やすい視点を自動的に計画する枠組みが必要である。物体形状を効率的に計測するための視点計画法は、これまで多くの研究が行われている [1, 2]。一方、物体認識のための視点計画に関する研究は少ない。その中で、従来の能動的物体認識法として、事前に学習した物体の認識を目的とした、複数台の RGB カメラの視点位置・視線方向を決定するものがある。[3, 4]。しかし、あらゆる日用品のデータが事前にロボットに与えられるとは限らない。したがって、未知の物体が与えられても、その物体が属するカテゴリを認識する機能が、生活支援ロボットにとって必要である。

我々は、1台の距離センサを有するロボットを使って、形状が未知の日用品に対しても認識可能な、視点計画に基づく能動的物体認識法を提案した [5]。この手法では、対象物の不確かさをエントロピーで定量化し、そのエントロピーが最も減少する視点を選択する。シミュレーションとして、6つのカテゴリの物体認識問題を扱い、提案手法と、ランダムに視点を選択する手法との比較を行った。その結果、提案手法が効率的に物体認識できることが確認できた。

本稿では、距離センサを使って実際の日用品を計測し、その形状データを認識対象とした実験を行い、その結果について報告する。

2 日用品データベース [5]

提案手法は、日用品の大まかな形状特徴と、詳細な形状特徴の2種類の特徴量を用いて、視点計画を行う。

2.1 大まかな形状特徴

本手法では、形状幾何特徴量として、Clustered Viewpoint Feature Histogram (CVFH)[6]を用いる。距離センサで計測した物体表面の点群データが与えられると、まず、各点ごとに、全点群データでの平均法線ベクトルに対する、その点での法線ベクトルの傾きを求める。次に、全点群データの傾きを数え上げたヒストグラムを作成し、このヒストグラムの度数をベクトル化したものが、CVFHである。1つの日用品のカテゴリごとに、複数の物体の3次元形状モデルを用意する。各モデルを80個の視点 (Fig.1) から計測したときの点群データを仮想的に生成し、視点ごとに CVFH を求める。本手法の視点計画では、視点の位置のみを決定し、各学習データは、モデルの番号と視点の組み合わせからなる。

本研究では、学習データに存在しない未知の物体が、どのカテゴリに属するかを認識するため、観測した未知物体のカテゴリ分類可能性を、定量的に評価する。これを実現するために、各カテゴリの全モデルに対して、同一視点から観測したときの形状特徴の分布を求める。 k 番目の視点 $\mathbf{v}_k (k = 1, 2, \dots, 80)$ から、カテゴリ $c_i (i = 1, 2, \dots, N_c; N_c: \text{カテゴリ数})$ の日用品の D 次元 CVFH \mathbf{g}_{ik} が得られる確率 \mathcal{N}_g を、正規分布を用いて

$$\mathcal{N}_g(\mathbf{g}_{ik}, \boldsymbol{\mu}_{ik}, \sigma_{ik}^2) = \frac{1}{(2\pi)^{\frac{D}{2}} \sigma_{ik}} \exp\left\{-\frac{|\mathbf{g}_{ik} - \boldsymbol{\mu}_{ik}|^2}{2\sigma_{ik}^2}\right\} \quad (1)$$

と表現する。カテゴリ c_i に含まれる $N_m^{(i)}$ 個のモデルを $M_{ij} (j = 1, 2, \dots, N_m^{(i)})$ と記述すると、式 (1) の平均ベクトル $\boldsymbol{\mu}_{ik}$ 、分散 σ_{ik}^2 は、図 1 に示すような注目視点 \mathbf{v}_k と、その3近傍の視点の計4視点の CVFH を使って求める:

$$\boldsymbol{\mu}_{ik} = \frac{1}{4N_m^{(i)}} \sum_{j=1}^{N_m^{(i)}} \sum_{k' \in L_k} \mathbf{g}_{ijk'}; \quad (2)$$

$$\sigma_{ik}^2 = \frac{1}{4N_m^{(i)}} \sum_{j=1}^{N_m^{(i)}} \sum_{k' \in L_k} |\mathbf{g}_{ijk'} - \boldsymbol{\mu}_{ik}|^2. \quad (3)$$

\mathbf{g}_{ijk} は、 k 番目の視点からモデル M_{ij} を観測した時に得られる

CVFHである。また、 L_k は、 k 番目の視点と、その3近傍の視点の集合である。

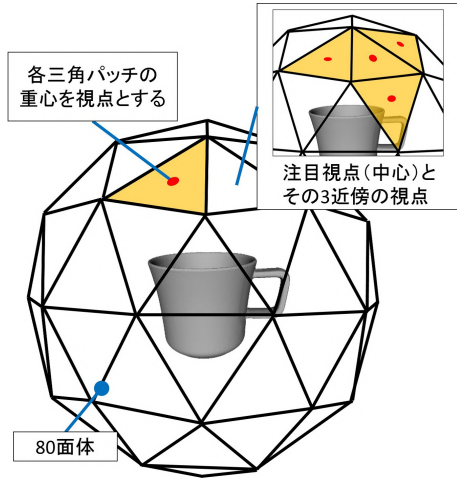


Fig.1 80 viewpoints used to generate CVFH feature.

2.2 詳細な形状特徴

CVFH は、表面積の大きい面の特徴を主に記述するので、大域的な特徴記述を実現している。一方、カップの取っ手のような、細かい形状の部分の特徴は記述されにくい。そこで、既に取得している点群データを利用した、形状の類似性に関する確信度を導入する。

まず、カテゴリごとに学習モデルの中から、 m 個のモデル $M_{il} (l = 1, 2, \dots, m)$ を選択する。選択したモデルから、1つのモデル M_{il} に着目し、それ以外のモデル $M_{ij} (j \neq l)$ と距離を求める。この距離には、 n 番目の視点 $\mathbf{v}^{(n)}$ から得られる M_{il} と M_{ij} の距離画像間の距離 $d_{\mathbf{v}^{(n)}ijl}$ を用いる。すべてのモデルとの距離を求めると、モデル M_{il} に関する距離 $d_{\mathbf{v}^{(n)}ijl}$ の平均 μ_{dil} と分散 σ_{dil}^2 は、次式で得られる:

$$\mu_{dil} = \frac{1}{N_m^{(i)} - 1} \sum_{j=1, j \neq l}^{N_m^{(i)}} d_{\mathbf{v}^{(n)}ijl}; \quad (4)$$

$$\sigma_{dil}^2 = \frac{1}{N_m^{(i)} - 1} \sum_{j=1, j \neq l}^{N_m^{(i)}} (d_{\mathbf{v}^{(n)}ijl} - \mu_{dil})^2. \quad (5)$$

式 (4), (5) を使って、各モデル M_{il} について、他のモデルとの距離の平均と分散を求める。そして、 n 番目の視点 $\mathbf{v}^{(n)}$ から取得した観測データと、各カテゴリから選択したモデル M_{il} の点群データの距離画像間の距離 $\tilde{d}_{\mathbf{v}^{(n)}il}$ を求める。最終的に、 $\tilde{d}_{\mathbf{v}^{(n)}il}$ が得られる確率 \mathcal{N}_d は、次式より求める:

$$\mathcal{N}_d(\tilde{d}_{\mathbf{v}^{(n)}il}, \mu_{dil}, \sigma_{dil}^2) = \frac{1}{(2\pi)^{\frac{1}{2}} \sigma_{dil}} \exp\left\{-\frac{(\tilde{d}_{\mathbf{v}^{(n)}il} - \mu_{dil})^2}{2\sigma_{dil}^2}\right\}. \quad (6)$$

3 能動的物体認識法 [5]

能動的物体認識の流れを、Fig.2 に示す。データベースを構築した後、観測を行って得られた CVFH と点群データから確信度を求め、その確信度に基づいて、認識に有効な視点を選択する。ここで、確信度とは、観測している未知の物体がどのカテゴリに属するかを確率で表したものである。

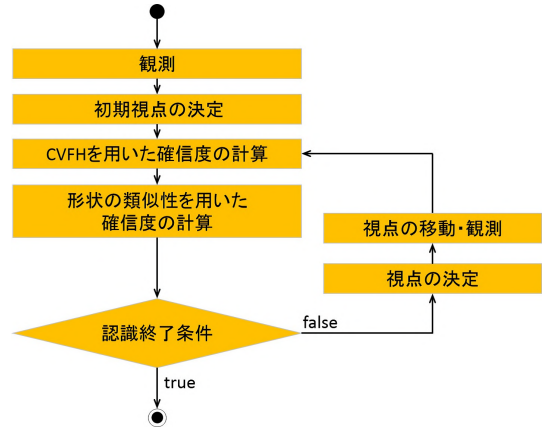


Fig.2 Our active object recognition.

3.1 初期視点の決定

1 回目の観測で、CVFH $\mathbf{g}^{(1)}$ が得られた時、各カテゴリから、 $\mathbf{g}^{(1)}$ に類似した特徴量を持つ物体候補と、その特徴量得られる視点 (初期視点) を決定する。具体的には、カテゴリ c_i 内の全モデルの CVFH と $\mathbf{g}^{(1)}$ の距離を求め、その距離が小さい順に T 個の学習データを選択する。選択した T 個の学習データと観測データの形状位置合わせを行い、位置合わせ誤差が最小となる学習データ、つまりモデルと視点の組み合わせを求める。選ばれた視点を、 c_i の初期視点 $\tilde{\mathbf{v}}_i^{(1)}$ とする。同様に、全カテゴリから、初期視点を決定し、初期視点を使って視点計画を行う。

3.2 CVFH を用いた確信度の計算

観測を n 回行った時、それまでの視点 $\mathbf{v}^{(1)}, \dots, \mathbf{v}^{(n-1)}$ と、その時に得られた特徴量 $\mathbf{g}^{(1)}, \dots, \mathbf{g}^{(n-1)}$ は既知である。この事前情報を用いて、 n 回目の観測で視点 $\mathbf{v}^{(n)}$ から特徴量 $\mathbf{g}^{(n)}$ が得られた時、それがカテゴリ $c^{(n)}$ である確率は、ベイズ推定により事後確率密度関数 $p_{post}(c^{(n)})$ で表される [5]:

$$p_{post}(c^{(n)}) = \frac{p(\mathbf{g}^{(n)} | c^{(n)}, \mathbf{v}^{(n)}) p_{pri}(c^{(n)})}{p(\mathbf{g}^{(n)} | \mathbf{v}^{(n)}, \mathbf{g}^{(n-1)}, \mathbf{v}^{(n-1)}, \dots, \mathbf{g}^{(1)}, \mathbf{v}^{(1)})}; \quad (7)$$

$$P_{post}(c^{(n)}) = P(c^{(n)} | \mathbf{g}^{(n)}, \mathbf{v}^{(n)}, \mathbf{g}^{(n-1)}, \mathbf{v}^{(n-1)}, \dots, \mathbf{g}^{(1)}, \mathbf{v}^{(1)}); \quad (8)$$

$$P_{pri}(c^{(n)}) = P(c^{(n)} | \mathbf{g}^{(n-1)}, \mathbf{v}^{(n-1)}, \dots, \mathbf{g}^{(1)}, \mathbf{v}^{(1)}). \quad (9)$$

本手法では、式 (8) の事後確率を、物体の確信度とみなす。ここで、式 (7) の分母の確率密度関数は、

$$p(\mathbf{g}^{(n)} | \mathbf{v}^{(n)}, \mathbf{g}^{(n-1)}, \mathbf{v}^{(n-1)}, \dots, \mathbf{g}^{(1)}, \mathbf{v}^{(1)}) = \sum_{i=1}^{N_c} p(\mathbf{g}^{(n)} | c_i^{(n)}, \mathbf{v}^{(n)}) P_{pri}(c_i^{(n)}) \quad (10)$$

と表される。事前確率 $P_{pri}(c^{(n)})$ は、1 ステップ前の事後確率と等しいので、

$$P_{pri}(c^{(n)}) = P_{post}(c^{(n-1)}) \quad (11)$$

で得られる。また、事前確率の初期値 $P_{pri}(c^{(0)})$ は、

$$P_{pri}(c^{(0)}) = \frac{1}{N_c} \quad (12)$$

となる。カテゴリ c_i の日用品を視点 \mathbf{v}_k から観測した時、CVFH \mathbf{g}_{ik} が得られる尤度 $p(\mathbf{g}_{ik}|c_i, \mathbf{v}_k)$ は、

$$p(\mathbf{g}_{ik}|c_i, \mathbf{v}_k) = \mathcal{N}_{\mathbf{g}}(\mathbf{g}_{ik}, \boldsymbol{\mu}_{ik}, \sigma_{ik}^2) \quad (13)$$

と表される。

3.3 形状の類似性を用いた確信度の計算

観測を n 回行った時、それまでの視点 $\mathbf{v}^{(1)}, \dots, \mathbf{v}^{(n-1)}$ と、その時に得られた形状の類似性を表す距離 $d^{(1)}, \dots, d^{(n-1)}$ は既知である。この事前情報を用いて、 n 回目の視点 $\mathbf{v}^{(n)}$ の観測データを使って、形状の類似性を表す距離 $d^{(n)}$ が得られた時、それがカテゴリ $c^{(n)}$ である確率を求める。ベイズ推定により、式 (7) の事後確率密度関数 $p_{post}(c^{(n)})$ は、次のように定義する:

$$p_{post}(c^{(n)}) = \frac{p(\mathbf{g}^{(n)}, d^{(n)}|c^{(n)}, \mathbf{v}^{(n)})p_{pri}(c^{(n)})}{p(\mathbf{g}^{(n)}, d^{(n)})}; \quad (14)$$

$$\begin{aligned} p(\mathbf{g}^{(n)}, d^{(n)}) &= p(\mathbf{g}^{(n)}, d^{(n)}|\mathbf{v}^{(n)}, \mathbf{g}^{(n-1)}, d^{(n-1)}, \mathbf{v}^{(n-1)}, \\ &\quad \dots, \mathbf{g}^{(1)}, d^{(1)}, \mathbf{v}^{(1)}, \mathbf{g}^{(1)}, \mathbf{v}^{(1)}); \end{aligned} \quad (15)$$

$$\begin{aligned} P_{post}(c^{(n)}) &= P(c^{(n)}|\mathbf{g}^{(n)}, d^{(n)}, \mathbf{v}^{(n)}, \mathbf{g}^{(n-1)}, d^{(n-1)}, \mathbf{v}^{(n-1)}, \\ &\quad \dots, \mathbf{g}^{(1)}, d^{(1)}, \mathbf{v}^{(1)}, \mathbf{g}^{(1)}, \mathbf{v}^{(1)}); \end{aligned} \quad (16)$$

$$\begin{aligned} P_{pri}(c^{(n)}) &= P(c^{(n)}|\mathbf{g}^{(n-1)}, d^{(n-1)}, \mathbf{v}^{(n-1)}, \\ &\quad \dots, \mathbf{g}^{(1)}, d^{(1)}, \mathbf{v}^{(1)}, \mathbf{g}^{(1)}, \mathbf{v}^{(1)}). \end{aligned} \quad (17)$$

ここで、CVFH と形状の相関はなくそれぞれ独立とみなすと、式 (14) の分母の確率密度関数は、

$$p(\mathbf{g}^{(n)}, d^{(n)}) = p(\mathbf{g}^{(n)})p(d^{(n)}) \quad (18)$$

と分解でき、

$$\begin{aligned} p(\mathbf{g}^{(n)}) &= p(\mathbf{g}^{(n)}|\mathbf{v}^{(n)}, \mathbf{g}^{(n-1)}, d^{(n-1)}, \mathbf{v}^{(n-1)}, \\ &\quad \dots, \mathbf{g}^{(1)}, d^{(1)}, \mathbf{v}^{(1)}, \mathbf{g}^{(1)}, \mathbf{v}^{(1)}) \\ &= \sum_{i=1}^{N_c} p(\mathbf{g}^{(n)}|c_i^{(n)}, \mathbf{v}^{(n)})P_{pri}(c_i^{(n)}) \end{aligned} \quad (19)$$

$$\begin{aligned} p(d^{(n)}) &= p(d^{(n)}|\mathbf{v}^{(n)}, \mathbf{g}^{(n-1)}, d^{(n-1)}, \mathbf{v}^{(n-1)}, \\ &\quad \dots, \mathbf{g}^{(1)}, d^{(1)}, \mathbf{v}^{(1)}, \mathbf{g}^{(1)}, \mathbf{v}^{(1)}) \\ &= \sum_{i=1}^{N_c} p(d^{(n)}|c_i^{(n)}, \mathbf{v}^{(n)})P_{pri}(c_i^{(n)}) \end{aligned} \quad (20)$$

と表される。同様に、式 (14) の尤度は、

$$\begin{aligned} p(\mathbf{g}^{(n)}, d^{(n)}|c^{(n)}, \mathbf{v}^{(n)}) &= p(\mathbf{g}^{(n)}|c^{(n)}, \mathbf{v}^{(n)})p(d^{(n)}|c^{(n)}, \mathbf{v}^{(n)}) \end{aligned} \quad (21)$$

と、分解できる。

ここで、各カテゴリごとに、 m 個のモデルを選び、2.2 節で述べた手順で、 $\mathbf{v}^{(n)}$ から取得した観測データが得られる確率を、式

(6) によって求める。選択した m 個のモデルに対して確率を計算し、それが最大となるモデルを、形状の類似性の確信度を求めるモデルとして採用する。この時の形状の類似度の分布の平均と分散を、 $\tilde{\mu}_{di}$, $\tilde{\sigma}_{di}^2$ とすると、カテゴリ c_i の日用品を視点 \mathbf{v}_k から観測した時、形状の類似性の尤度 $p(d_{\mathbf{v}_k il}|c_i, \mathbf{v}_k)$ は、

$$p(d_{\mathbf{v}_k il}|c_i, \mathbf{v}_k) = \mathcal{N}_d(d_{\mathbf{v}^{(n)} il}, \tilde{\mu}_{di}, \tilde{\sigma}_{di}^2) \quad (22)$$

と表される。

3.4 視点の決定

3.1 節で選んだ各カテゴリ c_i の代表モデル \tilde{M}_i を使って、次の視点候補を選択する。80 個の各視点 \mathbf{v}_k から得られる CVFH $\mathbf{g}^{(k)}$ を、 \tilde{M}_i の CVFH $\tilde{\mathbf{g}}_{ik}$ として式 (7) に代入し、仮の事後確率を視点ごとに求める。次に、 $\mathbf{g}^{(n)}$ が得られた時の物体の不確かさを表すエントロピーを

$$H(P(X)) = - \sum_X P(X) \log P(X) \quad (23)$$

と定義する。このエントロピーが減少する、つまり、物体を認識しやすい情報が得られる視点を選ぶ。具体的には、 $\tilde{\mathbf{g}}_{ik}$ によるエントロピーの減少量を、式 (24) の相互情報量によって算出する:

$$I(c^{(n)}; \tilde{\mathbf{g}}_{ik}) = H(P_{pri}(c^{(n)})) - H(P_{post}(c^{(n)})). \quad (24)$$

ここで、事前確率 $P_{pri}(c^{(n)})$ は、式 (9) より得る。式 (24) を用いて、移動可能な全ての視点の候補について相互情報量を計算し、相互情報量が最大となる視点を、次の視点として決定する:

$$\mathbf{v}_{k^*} = \arg \max_{k^*} \frac{1}{N_c} \sum_{i=1}^{N_c} I(c^{(n)}; \tilde{\mathbf{g}}_{ik}). \quad (25)$$

認識終了条件は、いずれか 1 つのカテゴリの確信度が 0.90 以上とし、認識終了条件を満たすまで、視点計画-データ取得-確信度の計算の処理ループを繰り返す。

4 実験

距離センサを使って日用品の計測を行い、実物の形状データを使って本能的物体認識手法の有効性を検証した。Fig.3 に示すようなパンチルトステージの上に日用品を載せ、距離センサ (コニカミノルタ社製・VIVID910) を用いて計測した。本実験に用いた日用品を、Fig.4(a) に示す。各日用品に対して、Fig.5 に示すような 48 視点から計測した。学習に用いた日用品カテゴリと学習モデル数を、Table1 に示す。また、学習データ作成に用いた形状モデルの一例を、Fig.4(b) に示す。これらのデータセットを用いて、提案手法で視点計画を行った場合と、ランダムに視点を選択した場合 (ランダム法) で比較実験を行った。

本実験では、まず、計測した点群データを 1 つ選択し、これを初期観測データとして、能動的物体認識を行った。ここで、提案手法の場合は、全計測データをテストデータとして使用した。一方、ランダム法の場合は、物品ごとにランダムに 10 個計測データを選び、1 つのデータに対して 20 回認識を繰り返し行った。また、認識が成功した場合における、認識終了までの平均観測視点数とその標準偏差、および最大観測視点数によって、提案手法とランダム法を比較した。

Table2 に、平均観測視点数とその標準偏差、および最大観測視点数を示す。また、各手法で観測数が 6 回以上になった場合を認識失敗とした。Table3 に、実験での認識率と失敗数を示す。Table2 から分かるように、平均観測数と最大観測数は、提案手法はランダム法よりも少ない、または同等という結果となった。また、失敗数や識別率を比べると、提案手法は安定した物体認識ができていことが分かる。以上より、提案手法で視点計画を行った方が、ランダムに視点を選択するよりも、効率的な物体認識ができていことが確認できた。




Fig.3 Measurement of daily necessities using VIVID910.




Fig.5 Measurement viewpoints.




Fig.4 Daily necessities used in our experiments: (a) photographic image; (b) 3D models.

5 結言

本稿では、距離センサを使って取得した実物の日常品の形状データを対象とした、物体認識実験を行った。開発した手法の有効性を評価するために、提案手法と、ランダムに視点を選択する手法との比較実験を行った。実物の形状データを用いた場合でも、提案手法により少ない観測数で安定した物体認識ができていたことが確認できた。今後は、鍵の誤認識を踏まえ、新たな特徴量や手法の検討が必要である。

Table 1 Number of the models in each category.

NO.	カテゴリ	学習モデル数
1	リンゴ	11
2	バナナ	15
3	ペットボトル	13
4	カップ	8
5	鍵	16
6	ペン	11
7	携帯電話 (スマートフォン)	12
8	スプーン	14

Table 2 Average and maximum number of observations.

テスト カテゴリ	平均観測数 ± 標準偏差		最大観測数	
	本手法	従来法	本手法	従来法
リンゴ	2.06±0.28	2.64±0.88	3	5
バナナ	2.15±0.51	2.20±0.78	5	5
ペットボトル	1.72±0.65	2.18±0.49	4	5
カップ	1.68±0.47	1.70±0.46	2	2
ペン	2.81±0.73	3.04±0.72	4	5
携帯電話	1.55±0.84	1.54±0.65	4	4
スプーン	1.46±0.64	1.55±0.62	3	4

Table 3 Number of failed and recognition rate.

テスト カテゴリ	*失敗数		識別率	
	本手法	従来法	本手法	従来法
リンゴ	0	18	1.00	0.96
バナナ	1	2	0.96	0.85
ペットボトル	1	1	0.98	0.84
カップ	0	0	1.00	1.00
ペン	0	2	0.88	0.87
携帯電話	0	0	0.92	0.96
スプーン	0	0	1.00	0.98

*失敗数：観測数が6回以上となった数

References

- [1] 諸岡健一, 查紅彬, 長谷川勉: “複数の距離画像の統合による3次元物体モデル生成のための視点計画”, 電子情報通信学会 D-II, Vol.J82-D-II, No.3, pp.371-381, 1999.
- [2] Sumantra Dutta Roy, Santanu Chaudhury, Subhashis Banerjee: “Active recognition through next view planning: a survey”, Pattern Recognition, Volume 37, Issue 3, March 2004, Pages 429-446
- [3] 松ヶ野修功, 高橋友和, 井出一郎, 日加田慶人, 村瀬洋: “複数視点物体認識における視点配置の決定法” 電子情報通信学会, pp.19-pp.24, 2004.
- [4] F. Farshidi, S.Sirouspour, T.Kirubarajan: “Robust sequential view planning for object recognition using multiple cameras”, Image and Vision Computing 27 pp.1072-1082, 2009.
- [5] 中里一幾, 諸岡健一, 辻徳生, 倉爪亮: “能動的物体認識のための視点計画法”, 第15回公益社団法人計測自動制御学会システムインテグレーション部門講演会 (SI) 予稿集, 3G2-3, 2014.
- [6] Aitor Aldoma, Markus Vincze: “CAD-Model Recognition and 6DOF Pose Estimation Using 3D Cues”, 2011 IEEE International Conference on Computer Vision Workshops, 978-1-467-3-0063-6, 2011.