

オンラインマルチモーダルHDPによる物体概念の獲得

Acquisition of Object Concepts Using Online Multimodal HDP

青木 達哉 中村 友昭 長井 隆行
Tatsuya Aoki Tomoaki Nakamura Takayuki Nagai

電気通信大学大学院情報理工学研究科

Faculty of Infomatics and Engineering, The University of Electro-Communications

In this paper, we propose a method for online learning of object concepts using an extended version of Hierarchical Dirichlet Process (HDP). The robot can categorize multimodal information, which is obtained from objects, into object categories. These categories are considered as object concepts. By the proposed method, the robot can update its object concepts and estimate the number of object categories online. Furthermore, we introduce a novel model selection method using the particle filter, and category selection based on category significance evaluation using the sampling data for object learning. The simulation result shows that these processes enable the robot to estimate the number of categories more accurately.

1. 緒言

実環境でロボットが行動する際に、物体を正しく認知する能力は重要である。しかし、実環境には多種多様な物体が存在し、その種類は日々増加しているため、ロボットに予め全ての物体の情報を与えることは困難である。人間が全ての物体を覚えることなく、未知物体に対して柔軟に認知できるのは、自らの知識を用いた予測や逐次的な学習による知識の更新が行えるためだと考えられる。よって、より高度な認知を実現するために、ロボットにも同様の学習能力が必要である。

人間の物体の認知において、カテゴリ分類が重要な役割を果たしていることが指摘されている [Ashby 05]。この考えに基づいて、これまで物体の特徴の類似性を基にロボットによる物体カテゴリの獲得や獲得したカテゴリを利用した予測が可能手法を提案してきた。それらの手法は文書分類に用いられる確率モデルを拡張した手法であり、ロボットは教師なし学習で物体概念の獲得が可能となった [中村 13]。さらに、文献 [Araki 13] では、物体概念の逐次的な学習を可能としたオンライン学習手法を提案し、実験によりその有効性を示した。しかし、文献 [Araki 13] の手法では、予め適切なカテゴリ数を与える必要があり、学習中にカテゴリ数を変更することができないといった問題があった。そのため、カテゴリ数に対して学習物体数が少ないときには正確な物体カテゴリを学習することができないといった問題が生じていた。このような問題を解決するためには、逐次的に概念を獲得するなかで適切なカテゴリ数の推定を同時に行う必要がある。

本稿では、文献 [中村 13] で提案された学習データに応じたカテゴリ数推定が可能な Multimodal Hierarchical Dirichlet Process (MHDP) を拡張し、逐次的な物体カテゴリ数の推定と物体概念の獲得が可能な学習法を提案する。これを本稿では online MHDP (oMHDP) と呼ぶ。さらに、パーティクルフィルタによるモデル選択とカテゴリの重要度を評価するカテゴリ選択を導入することで、より適切なカテゴリ数の推定ができることを示す。

これまで物体カテゴリ分類に関しては、触覚情報を用いた手法 [Sinapov 11] や視覚情報を用いた手法 [Tsukada 10] などの研究が行われている。しかし、物体の特徴は複数の感覚を用いて観測されるため、単一の感覚を利用した場合、物体の特徴

を把握しきれない。そのため、本研究のようにマルチモーダル情報を用いる必要である。また、マルチモーダル情報の関係を学習する研究もいくつか行われている [Ridge 10][Lallee 13]。これらの研究では、モダリティ間の相互の予測を目的としている。一方、本研究では物体カテゴリを獲得し、その獲得したカテゴリを予測や認識に利用することを考えている点で他とは異なっている。

2. マルチモーダル情報の取得

ロボットが取得し、学習に利用するマルチモーダル情報について説明する。マルチモーダル情報はロボットが物体を観測することで取得する。取得したマルチモーダル情報からそれぞれの特徴量を抽出し、ベクトル量子化の処理を経て、特徴の発生頻度のパターンで表される Bag of Features (BoF) 表現へと変換する。以下ではそれぞれの情報で使われる特徴量と具体的な BoF への変換処理について説明する。

2.1 視覚情報

視覚情報は頭部に取り付けた CCD カメラと TOF カメラで物体を観察することで取得する。観測する際には物体を任意の角度へ天板を回転できる回転テーブルに置き、様々な方向から物体を観察する。ここでは、10 度ずつ天板を回転させ、計 36 枚の画像を各物体につき取得する。各画像に対して、DSIFT (Dense Scale Invariant Feature Transform) を用いて特徴量を抽出する。DSIFT では、画像によって得られる特徴ベクトルの個数が異なるため、物体の特徴量として扱いづらい。そのため、得られた特徴ベクトルを代表ベクトルによってベクトル量子化することで、500 次元のヒストグラムへ変換して、視覚情報として用いる。

2.2 聴覚情報

聴覚情報はロボットが把持した物体を振り、そのときに発生する音をロボットのハンドに取り付けたマイクで観測し、取得する。得られた音声信号はフレームに分割し、フレームごとに 13 次元の MFCC (Mel-Frequency Cepstrum Coefficient) を計算することによって、13 次元の特徴ベクトルとすることができる。この特徴ベクトルもベクトル量子化を行い、50 次元のヒストグラムに変換して、聴覚情報として用いる。

2.3 触覚情報

触覚情報はロボットの左腕に取り付けられたバレットハンドと触覚アレイセンサを用いて取得する。触覚アレイセンサは 162 個のセンサで構成されており、これによって得られる情報

連絡先: 青木 達哉, 電気通信大学大学院情報理工学研究科, 東京都調布市調布ヶ丘 1-5-1, aoki@apple.ee.uec.ac.jp

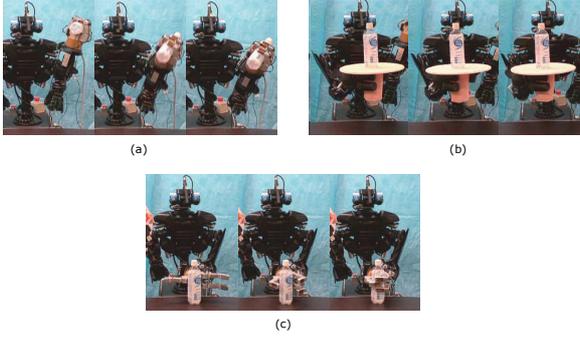


図 1: (a) 視覚情報の取得 (b) 聴覚情報の取得 (c) 触覚情報の取得

から触覚特徴量を計算する。しかし、触覚センサから得られる情報は同じ物体であっても把持位置によって変化してしまう。そのため、文献 [中村 10] で提案された手法を用いて、把持位置に依存しない触覚特徴量を求める。今回は 1 つの物体に対して 5 回ずつ把持を行い、810 (= 162 × 5) 個の特徴ベクトルを取得した。この特徴ベクトルもベクトル量子化を行い、15 次元のヒストグラムに変換して、触覚情報として用いる。

2.4 単語情報

5 人の被験者に学習に使用する物体の特徴を表す文章を音声で教示してもらった。教示発話の内容に制約を与えず、自由に考えてもらうこととした。教示発話は Google 音声認識を用いて認識し、その認識結果に対して形態素解析を行うことで、単語に分割した。物体の特徴を表す名詞、形容詞のみから単語の発生頻度ヒストグラムを作成し、単語情報として用いる。

3. Online MHDP

MHDP のパラメータ推定は、バッチ学習で行われるため、新たに物体を学習する際には全物体の情報を用いた再学習が必要となる。そのため、物体数が増加する逐次的な学習には対応していない。そこで、本稿では新規物体を追加学習することによってモデルのパラメータが更新できるように拡張を行い、逐次的な学習を可能にする手法を提案する。

3.1 MHDP

まず、oMHDP のベースとなる MHDP を説明する。MHDP は文書分類モデルの 1 つである Hierarchical Dirichlet Process を物体のカテゴリ分類に拡張した確率モデルである。このモデルでは、文書が物体、単語が特徴に対応しており、1 つのカテゴリから視覚や聴覚といった複数のモダリティ情報がそれぞれ生成されると考える。図 2 はモダリティ数が 4 つの場合の MHDP のグラフィカルモデルである。 $x_{ji}^v, x_{ji}^a, x_{ji}^t, x_{ji}^w$ はそれぞれ視覚情報、聴覚情報、触覚情報、単語情報を表している。各情報はそれぞれのモダリティ m 及びカテゴリ k に対応したパラメータ θ_k^m をパラメータとする多項分布より生成される。なお、パラメータ θ_k^m は α_0^m をハイパーパラメータとするディリクレ事前分布から決定される。また、 t_{ji}^m は特徴 x_{ji}^m とそのカテゴリ k を関係づけるクラスを表す。これは、 λ をハイパーパラメータとする CRP により生成された π_j をパラメータとする多項分布から決定される。また、 k_{jt} は j 番目の物体のクラス t のカテゴリを表す。これは γ をハイパーパラメータとする Chinese Restaurant Process (CRP) により生成された β をパラメータとする多項分布から決定される。

3.2 oMHDP の学習

oMHDP のデータの生成過程は MHDP と同じであるが、パラメータの推定法が異なる。oMHDP では、物体の情報を取得

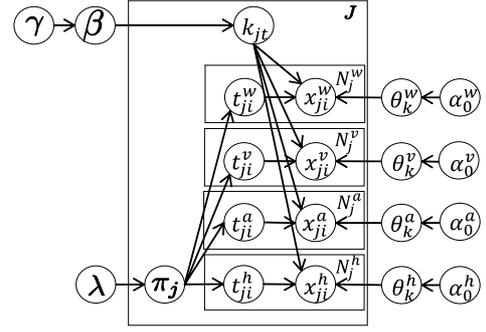


図 2: MHDP のグラフィカルモデル

する度にその物体のみからパラメータの更新を行い、適切なパラメータを得ることを目指す。ここで逐次更新すべきパラメータは全物体に共通する β と θ の 2 つである。oMHDP ではギブスサンプリングにより、 j 個目の学習物体の特徴 \bar{x}_{ji}^m に対するクラス t_{ji}^m 及びクラス t_j に対するカテゴリ k_{jt} を推定することで、全物体に共通する β, θ と学習物体に対する π_j を推定することで学習する。ただし、oMHDP では新規物体以外の情報を保持していないため、 $(j-1)$ 個の物体を学習することで得られた直前のパラメータ集合 $\Theta^{j-1} = \{\theta_k^{vj-1}, \theta_k^{aj-1}, \theta_k^{tj-1}, \theta_k^{wj-1}, \beta^{j-1}\}$ をギブスサンプリングを行う際の初期値として用いる。これは、 $(j-1)$ 個の物体を学習した際に得られたパラメータを事前分布にして、 j 個目の物体を学習することになる。このように、逐次的な学習が行えるように拡張する。

学習物体の特徴 \bar{x}_{ji}^m に対するクラス t_{ji}^m は次の条件付き確率よりサンプリングされる。

$$\begin{aligned} t_{ji}^m &\sim P(t_{ji}^m | \bar{\mathbf{X}}^{-mj}, \Theta^{j-1}, \lambda) \\ &= P(t_{ji}^m | \lambda) \frac{N_{k\bar{x}_{ji}^m} + \alpha_0^m}{N_k^m + d^m \alpha_0^m} \end{aligned} \quad (1)$$

$$P(t_{ji}^m | \lambda) = \begin{cases} \frac{N_{jt}}{\lambda + N_j - 1} & (t = 1, \dots, T_j) \\ \frac{\lambda}{\lambda + N_j - 1} & (t = T_j + 1) \end{cases} \quad (2)$$

なお、式 (1) において、 $N_{k\bar{x}_{ji}^m}$ は特徴 \bar{x}_{ji}^m と同じ特徴にカテゴリ k が割り振られた数、 N_k^m はモダリティ m の特徴にカテゴリ k が割り振られた数、 d^m はモダリティ m の次元数、 λ は新規のクラスの選択のしやすさを表す CRP のハイパーパラメータを表す。また、式 (2) において、 N_{jt} は j 個目の学習物体の特徴のうちクラス t に割り振られた数、 N_j は j 個目の学習物体の総特徴数 ($N_j = \sum_t N_{jt}$)、 T_j は j 個目の学習物体に対するクラスの数を表す。

また、クラス t_j に対するカテゴリ k_{jt} は次の条件付き確率よりサンプリングされる。

$$\begin{aligned} k_{jt} &\sim P(k_{jt} | \bar{\mathbf{X}}^{-jt}, \Theta^{j-1}, \gamma) \\ &= P(k_{jt} | \beta^{j-1}, \gamma) \prod_{\bar{x}_{ji}^m \in \bar{\mathbf{X}}_{jt}} \frac{N_{k\bar{x}_{ji}^m} + \alpha_0^m}{N_k^m + d^m \alpha_0^m} \end{aligned} \quad (3)$$

$$P(k_{jt} | \beta^{j-1}, \gamma) = \begin{cases} \frac{M_k}{\gamma + M - 1} & (k = 1, \dots, K) \\ \frac{\gamma}{\gamma + M - 1} & (k = K + 1) \end{cases} \quad (4)$$

なお、 $\bar{\mathbf{X}}^{-jt}$ はクラス t_j に割り振られた特徴 $\bar{\mathbf{X}}_{jt}$ を除いた特徴の集合、 M_k はクラスにカテゴリ k が割り振られた数、 M

はクラスに割り振られた全カテゴリの総数 ($M = \sum_k M_k$), γ は新規のカテゴリの選択のしやすさを表す CRP のハイパーパラメータ, K はカテゴリ数を表す. これらの式を用いて j 個目の学習物体の全特徴に対して式 (1) によるサンプリングと全クラスに対して式 (3) によるサンプリングを行う. その収束結果からパラメータ β, π_j, θ の推定値を得ることができる.

3.3 パーティクルフィルタによるモデル選択

サンプリング時の初期値の影響を軽減するために, パーティクルフィルタ (PF) によるモデル選択を行う. この処理は新規物体の学習前に行う. 各パーティクル毎にモデル選択の指標となるスコアを算出し, スコアが低いパーティクルをスコアが高いパーティクルと入れ替える. 本手法では, 新規物体の情報のうちのある 1 つモダリティの情報 \mathbf{X}^* をそれ以外のモダリティの情報 \mathbf{X}_{obs}^{-*} とそれまでの学習で推定したパラメータ Θ^{j-1} を用いた次式の予測確率 $P(\mathbf{X}^* | \mathbf{X}_{obs}^{-*}, \Theta^{j-1})$ をスコアとして用いる.

$$P(\mathbf{X}^* | \mathbf{X}_{obs}^{-*}, \Theta^{j-1}) = \prod_{x_i^* \in \mathbf{X}^*} \sum_k P(x_i^* | \hat{\theta}_k^*) P(k | \mathbf{X}_{obs}^{-*}) \quad (5)$$

このスコアが高いパーティクルは過去の学習によって, 新規物体の情報を正しく予測できるようにモデルのパラメータ推定ができています. そのようなパーティクルを複製することで学習時の誤りの軽減を行う.

3.4 カテゴリ選択

新規カテゴリは確率的に形成されるため, 物体の特徴を正しく表せていない不要なカテゴリが形成される可能性がある. oMHDP は直前の学習で推定したパラメータを新規物体を学習する際の事前分布に用いるため, 形成されたカテゴリは物体の特徴を表せているかに関わらず, それ以降の学習に影響を与える. そこで, 獲得したカテゴリの選択を学習に導入し, 不要なカテゴリの除外を行う. この処理はデータ生成とカテゴリ評価の 2 つに分かれる. カテゴリ選択では学習モデルの全カテゴリのパラメータを評価しなければならない. しかし, 直前の学習に用いたデータしか保持しないため, 評価するためには情報が不足している. そのため, 推定したパラメータからサンプリングによってカテゴリ選択用データ \mathbf{D}_v を生成し, 情報不足を解消する. 学習で推定された $\hat{\theta}_k = \{\hat{\theta}_k^v, \hat{\theta}_k^t, \hat{\theta}_k^a, \hat{\theta}_k^w\}$ で決定される多項分布は学習した物体に対する特徴の発生確率を表わしており, この多項分布から生成したデータは各カテゴリの物体を表現していると考えられる.

続いて, カテゴリの選択が必ずしも正しく働くとは限らないため, カテゴリの評価をランダムに選択した N_p 個のパーティクルで実施する. 生成したカテゴリ選択用データ \mathbf{D}_v を \bar{p} 番目のパーティクルが学習で推定したパラメータ $\Theta^{\bar{p}}$ を用いて, カテゴリ認識を行う. なお, 推定したパラメータを用いたカテゴリ認識については次節 3.5 で説明する. このときカテゴリの必要性が高ければ, 複数のパーティクルで同じような特徴を表すカテゴリが形成されるため, 複数のデータが同一のカテゴリであると認識される. よって, カテゴリの重要度の閾値 S を定め, 生成したカテゴリ選択用データのうち \bar{p} 番目のパーティクルのカテゴリ k と認識された数 $V_{\bar{p}k}$ と比較することで各カテゴリの重要度を判断する. なお, $\delta(k, \hat{k}_{d\bar{p}k})$ は $k = \hat{k}_{d\bar{p}k}$ の場合に 1, それ以外の場合に 0 となる関数である.

$$V_{\bar{p}k} = \sum_{d_k^p \in \mathbf{D}_v} \delta(k, \hat{k}_{d\bar{p}k}) \quad (6)$$

$$\hat{k}_{d\bar{p}k} = \operatorname{argmax} P(k | d_k^p, \Theta^{\bar{p}}) \quad (7)$$

以下にカテゴリ選択のアルゴリズムをまとめる.

[カテゴリ選択のアルゴリズム]

1. カテゴリ選択用のデータ \mathbf{D}_v の生成
推定したパラメータ θ_k^p が定める多項分布よりサンプリング
for all p, k ($1 \leq k \leq K_p, 1 \leq p \leq P$)
 $d_k^p \sim \text{Mult}(\theta_k^p)$
 Add d_k^p to \mathbf{D}_v
end for
2. パーティクル毎にカテゴリを評価
カテゴリ選択用のデータ \mathbf{D}_v を \bar{p} 番目のパーティクルのパラメータ $\Theta^{\bar{p}}$ を用いて認識
for $i \leftarrow 1$ to N_p do
 $\bar{p} \sim \text{Random}[1 \leq i \leq N_p]$
 for $d \in \mathbf{D}_v$
 $k = \operatorname{argmax} P(k | d, \Theta^{\bar{p}})$
 $V_{\bar{p}k} + +$
 end for
end for
閾値 S と比較し重要度を判断
for all k, \bar{p}
 if $V_{\bar{p}k} < S$
 Delete k -th category of \bar{p} -th particle
 end if
end for

3.5 学習モデルを用いたカテゴリ認識

oMHDP は推定したパラメータを用いることで, 未知物体のカテゴリ認識を行うことができる. 学習時と同様に取得した未知物体のマルチモーダル情報と推定したパラメータを用いて, 未知物体の各特徴に対するクラスと各クラスに対するカテゴリを式 (1) 及び式 (3) によって推定する. 未知物体 \mathbf{X} の特徴数を \hat{N} , t 番目のクラスの特徴数 \hat{N}_t , t 番目のクラスのカテゴリを \hat{k}_t とすると, 未知物体がカテゴリ k である確率 $P(k | \mathbf{X})$ が求められる. これを最大とするカテゴリが未知物体のカテゴリ \hat{k} となる.

$$\begin{aligned} \hat{k} &= \operatorname{argmax}_k P(k | \mathbf{X}) \\ &= \operatorname{argmax}_k \left(\frac{\sum_t \delta(k, \hat{k}_t) \hat{N}_t}{\hat{N}} \right) \end{aligned} \quad (8)$$

ただし, $\delta(k, \hat{k}_t)$ は $k = \hat{k}_t$ の場合に 1, それ以外の場合に 0 となる関数である. なお, 未知物体のカテゴリ認識では, パラメータのうち θ_k^m は学習時に推定された値を利用し, 未知物体の情報によって β_k, π_{jt} を更新する.

4. 実験

実環境中でロボットが学習することを考えた場合, 学習可能な物体数やカテゴリ数は多いことが求められる. しかし, 従来 [Araki 13] で行われた実験のようにロボットが実際にデータを取得しながら, 学習するには多くの時間がかかってしまい, 大規模な実験が困難である. そこで, 本稿はロボットが実際に取得した物体データのヒストグラムの次元を入れ替えることで, 同程度の複雑さを持つ擬似データを作成し, 学習する物体数や物体カテゴリ数が多くなった場合に対する oMHDP の学習性能の評価を行った. 実験は人手での分類で 11 カテゴリに分けられる 56 個の物体データから 88 カテゴリの 448 物体に相当する擬似データを作成し, 行った.

4.1 学習時のカテゴリ数推定

まず, 提案手法が適宜カテゴリ数を推定しながら学習できるかを検証した. また, oMHDP 及びカテゴリ選択を追

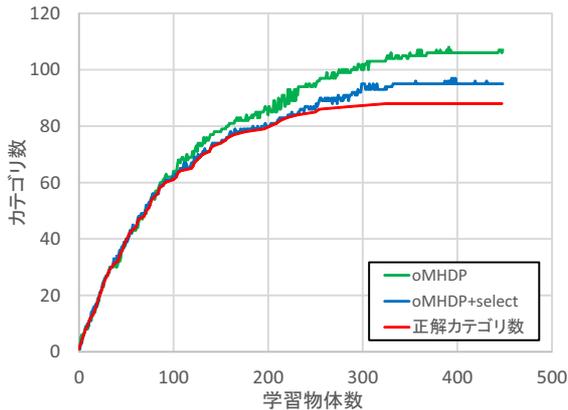


図 3: 推定カテゴリ数と正解カテゴリ数の比較 (総学習データ数 448 個, カテゴリ数 88 個)

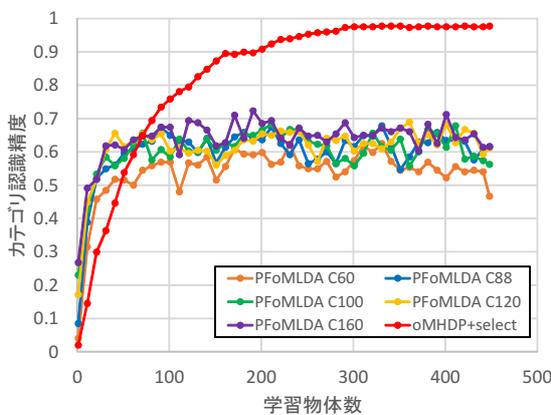


図 4: 学習物体数とカテゴリ認識精度の関係

加した oMHDP+select の 2 通りの手法で同様の学習し, カテゴリ選択の有無の影響も検証した. 図 3 に oMHDP 及び oMHDP+select でそれぞれ学習を行った際のカテゴリ数推定の結果を示した. また, 学習データを分類するために必要なカテゴリの数を正解カテゴリ数と定義し, 図 3 に赤線で示した. 実験結果から最終的に推定された数は正解とは異なったが, 提案手法を用いることでどちらも学習したデータを分類するために必要なカテゴリ数の推定を適切に行えたことが示された. また, 事前に想定したように oMHDP の学習時に必要以上のカテゴリが推定されてしまった. しかし, 不要なカテゴリを除外するカテゴリ選択を導入することによって, より適切なカテゴリ数の推定が可能となった. このことは, 学習で推定したパラメータより生成したデータが学習に用いたデータの代替として, モデルの評価に利用できることを示唆している.

4.2 学習後のカテゴリ認識

提案手法であるカテゴリ選択を導入した oMHDP+select と文献 [Araki 13] で提案された物体概念のオンライン学習手法である PFoMLDA の 2 種類の手法でそれぞれ擬似データの学習を行い, その結果を比較した. ただし, PFoMLDA は事前にカテゴリ数を設定する必要がある. そのため, 正解数とその前後の数を与え, それぞれ学習を行った. データを学習する順番はランダムに決定し, 全学習法で統一した. 図 4 に 88 カテゴリ, 448 個のデータを学習した際の学習物体数と全学習データを再認識した際のカテゴリ認識精度の関係を示した. 未学習データが多い初期は PFoMLDA と比べると提案手法のカテゴリ

認識精度は低くなった. これは, 提案手法が学習の進行とともにカテゴリ数を推定し, 必要に応じてカテゴリ数を増やしていくためである. そのため, 学習物体数が少ない場合は全データを正しく認識するために必要な数のカテゴリが学習できていない. しかし, 学習物体数が増加すると, 不足していたカテゴリが適切に形成され, 次第にカテゴリ認識精度は向上し, 最終的に比較手法である PFoMLDA を上回った. この結果から, カテゴリ数を事前に決定する必要がない提案手法は学習物体数や種類数の想定が難しい実環境で, 適応力の高いオンライン学習を可能にすると考えられる. また, oMHDP+select は高精度な分類が行えており, 学習の過程でのカテゴリの選択により必要性の低いカテゴリを除外することができていると考えられる. 一方で, 正解のカテゴリ数を事前に与えても PFoMLDA ではカテゴリ認識精度が 60 ~ 70% 程度までしか学習ができなかった. この原因としては, 事前に多くのカテゴリ数を用意したことで, 学習初期に同一のカテゴリの物体を異なるカテゴリに分類してしまった可能性が挙げられる. 逐次的なカテゴリ数推定は学習可能な物体数やカテゴリ数を増加させるためにも, 重要な能力であることが示唆された.

5. まとめ

提案手法により, ロボットは取得した物体情報から適切にカテゴリ数の推定を行える逐次的な物体概念の獲得を実現することができた. 従来手法の問題であったカテゴリ数決定の問題を解消し, また学習可能な物体数を大幅に増加でき, 提案手法はより実用性の高いオンライン学習手法であると言える. また, データの生成モデルの特徴を利用し, 大量のデータを保持することなく, 学習モデル全体の評価を行った. これにより, 不要なカテゴリの学習への影響を解消し, より適切なカテゴリ数の学習モデルの形成を可能にした. 一方で, カテゴリ数の増加に応じて, 1 物体に対する学習時間が増加する問題を残しており, 長期学習やパラメータの即時更新の実現に向けて, この問題は解決する必要がある.

参考文献

- [中村 10] 中村ほか, “把持動作による物体カテゴリの形成と認識”, 情報処理学会全国大会 2010, 5V-3, 2010
- [中村 13] 中村ほか, “階層ディリクレ過程に基づくロボットによる物体のマルチモーダルカテゴリゼーション”, 計測自動制御学会論文集, Vol.49, No.4, pp.469-478, 2013
- [Araki 13] Araki *et al.*, “Long-term learning of concept and word by robots: Interactive learning framework and preliminary results”, Intelligent Robots and Systems(IROS), 2013 IEEE/RSJ International Conference on, pp.2280-2287, 2013
- [Ashby 05] Ashby *et al.*, “Human Category Learning”, Annual Review of Psychology, 56, pp.149-178, 2005
- [Lallee 13] Lallee *et al.*, “Multi-modal convergence maps: from body schema and self-representation to mental imagery”, Adaptive Behavior, Vol. 21, No.4, pp.274-285, 2013
- [Ridge 10] Ridge *et al.*, “Self-supervised Cross-Modal Online Learning of Basic Object Affordances for Developmental Robot Systems”, Robotics and Automation(ICRA), 2010 IEEE International Conference on, pp. 5047-5054, 2010
- [Sinapov 11] Sinapov *et al.*, “Object category recognition by a humanoid robot using behavior-grounded relational learning”, Robotics and Automation (ICRA), 2011 IEEE International Conference on, pp. 184-190, 2011
- [Tsukada 10] Tsukada *et al.*, “Unsupervised and adaptive category classification for a vision-based mobile robot”, Neural Networks (IJCNN), The 2010 International Joint Conference on, pp1-6, 2010