

マルチモーダルカテゴリ能動知覚のための行動選択法と最適性

Optimal Action Selection for Active Perception of Multimodal Categorization

谷口 忠大 福田 一 高野 敏明
Taniguchi Tadahiro Fukuda Hajime Takano Toshiaki

立命館大学
Ritsumeikan University

In this paper, we propose an optimal action selection technique for multimodal object recognition and give theoretical foundation of the active perception technique. We assume that a robot obtain several multimodal categories through interaction with daily objects using multimodal categorization technique proposed by Nakamura et al. In such case, a robot can estimate a new object category efficiently by selecting an action which can collect more information than other actions do. We show that maximal expected KL-divergence criterion is optimal for reducing expected KL-divergence between the final posterior probability of object category and the expected posterior probability of object category after the next action. We also give an experiment to evaluate the proposed method.

1. 研究目的

自律ロボットが一般家庭のような人間の生活空間で活動するためには、実世界経験に基づいて物体知識を人間と共有しコミュニケーションを図る必要がある。しかし、人間とロボットは本質的に身体が異なる。ロボット自体が自らのセンサモータ系から得られる情報を組織化することで記号系を得て、これに基づき人間とのコミュニケーションを目指す、記号創発ロボティクスアプローチが重要である。

人間の持つ物体カテゴリは様々な差異や関係性に基づいて形成されている。センサモータ系に関わるものだけに限っても、物体カテゴリ形成には複数のモダリティから得られる情報が影響を与えている。NakamuraらはマルチモーダルHDPとそれに関連する一連の研究によって、視覚、触覚、聴覚といった感覚情報を統計モデルを用いて統合するマルチモーダルカテゴリゼーションの有用性を示してきた([1]ほか)。これらの研究を、さらに実世界で活用可能な形で展開していくことは重要な研究課題である。

マルチモーダルカテゴリゼーションでは複数のモダリティから得られた情報をクラスタリングすることでロボットはカテゴリ形成を行う。また、得られたクラスタへの対応を推定することで未知物体の認識を行う。その理論枠組みにおいては全てのモダリティ情報を取得することが前提になっているものの、一部のモダリティ情報のみで物体認識を行うことも可能ではある。現実には出来るだけ少ない行動によって迅速に対象物体を認識することが求められる。これは能動学習の範疇に含まれる研究課題であり、コンピュータビジョンの分野では能動視覚の分野で主に教師あり学習によるパターン認識課題を対象に精力的に研究されてきた(例えば,[2])。本稿では教師なし学習であるマルチモーダルカテゴリゼーションを対象に最適な行動選択について提案する*1。「クッション」ならば触覚、「鈴」ならば聴覚といったように、カテゴリに寄与するモダリティには偏りがあり、適切なモダリティ情報取得の選択が物体認識を高速化

連絡先: 谷口忠大, 立命館大学情報理工学部, 〒 525-8577 滋賀県草津市野路東 1-1-1, 077-561-5839, taniguchi@ci.ritsumeikan.ac.jp

*1 本稿は[3]をベースにしている。本稿では[3]では発見的であった提案手法に数学的基礎を与えるものである。

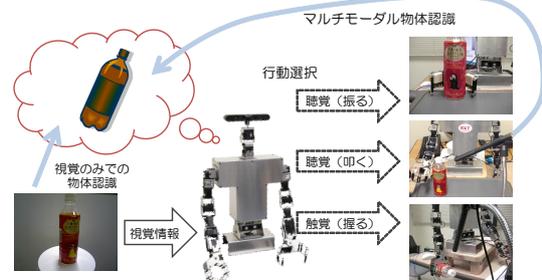


図 1: 実験に用いたロボットとタスクの概要図

すると期待される。

2. 提案手法

本稿で用いるマルチモーダルHDPのグラフィカルモデルを図2に示す。ロボットは視覚、聴覚二種(振る、叩く)、触覚の四種類のモダリティを持つとするが、一般には M 個のモダリティがあるとしてよい。それぞれの情報取得行動を表す添字を $\{v, a^s, a^h, h\} = \mathbf{M}$ とする。 $x_{jn}^v, x_{jn}^a, x_{jn}^h$ はそれぞれ j 番目の物体に関して各モダリティから得られる n 番目の観測値を表している。観測値は各次元の特徴量をK-means法でBag-of-Features(BoF)表現にして用いる。モデルの詳細はNakamura et al.[1]を参照のこと。

行動選択の状況として、既にロボットがモダリティ $m_0 \in \mathbf{M}$ に関する情報を得ていると仮定する。通常は $m_0 = v$ として遠隔で情報取得可能な視覚情報を仮定するが、視覚以外であっても構わない。提案手法では j 番目の物体を認識するために、行動選択の結果得られるカルバックライブラー情報量(KL情報量)の期待値が最大化されるモダリティ情報を取得する行動 m_j^* を選択する。

$$m_j^* = \underset{m}{\operatorname{argmax}} [E_{P(x_j^m | x_j^{m_0})} [\text{KL}(P(z_j | x^{(m_0, m)}), P(z_j | x^{m_0}))]] \quad (1)$$

$$\approx \underset{m}{\operatorname{argmax}} \frac{1}{K} \sum_{k \in \{1, \dots, K\}} \text{KL}(P(z_j | x_j^{m_0}, x_{j[k]}^m), P(z_j | x^{m_0})) \quad (2)$$

ここでダブル添字 (i, j) は $x^{(i, j)} = \{x^i, x^j\}$ を表すものとする。ま

た $x_j^m = (x_{j1}^m, \dots, x_{jm}^m, \dots, x_{jN_j^m}^m)$ とする. $x_{j[k]}^m$ は $x_{j[k]}^m \sim P(x_j^m | x_j^{m_0})$ によって振り出された k 番目のサンプルである. このサンプリングは

$$P(x_j^m | x_j^{m_0}) = \sum_{z_j} P(x_j^m | z_j) P(z_j | x_j^{m_0}) \quad (3)$$

のサンプリングにより実現する. z_j は物体カテゴリを表す.

式 1 は次の行動選択により KL 情報量が最も多く得られると期待される行動を選択するという基準であり, 式 2 はそのモンテカルロ近似を表している. このマルチモーダル HDP の性質を用いることでサンプリングを通してモンテカルロ近似を他の近似を入れることなく計算することが出来る.

定理 1 (最適性). マルチモーダルカテゴリゼーションにおける認識のための行動選択の目的を一度の行動選択により, 全行動をとった後の認識状態に近づけることとする. このとき, 一度の行動選択後の物体カテゴリ z_j についての確率分布と, 全ての行動選択後の物体カテゴリ z_j についての確率分布の間の KL 情報量をその近さの尺度として用いるならば, 式 1 の期待 KL 情報量最大化基準により選ばれた行動 m_j^* は最適な行動選択となっている.

$$\begin{aligned} \operatorname{argmin}_m E_{P(x_j^{(m_1, \dots, m_{M-1})} | x_j^{m_0})} [\text{KL}(P(z_j | x_j^{(m_0, \dots, m_{M-1})}), P(z_j | x_j^{(m, m_0)}))] \\ = \operatorname{argmax}_m E_{P(x_j^m | x_j^{m_0})} [\text{KL}(P(z_j | x_j^{(m, m_0)}), P(z_j | x_j^{m_0}))] \quad (4) \end{aligned}$$

ここで M はモダリティ数である (証明は省略) □

つまり, 次行動での期待 KL 情報量を最大化させる行動を取ることが, 最終的な認識状態に KL 情報量の意味で近づく最適な行動選択であることが保証される.

3. 実験

提案手法の有効性を示すために, ロボットを用いた実験を行った. 実験には図 1 に示すロボットを用い, 対象物体としては日用品 17 物体を準備した (図 3). 事前にマルチモーダル HDP による学習を行った結果, 図 3 に示されるカテゴリを得た. この学習結果に基づいて行動選択に関する実験を行った. 他の実験条件については [3] と同様の条件を用いた.

ロボットに対象物体について一周分の視覚情報を取得させ, その結果から, 提案手法に基づいて期待 KL 情報量最大の行動を選択させた (KL.max). 本実験条件の場合, 行動の選択肢は三つしか無いために, 比較対象として KL 情報量最小の行動を選択させたもの (KL.min), 視覚情報のみで推定したもの (Vision) を準備した. それぞれの対象物体に対して行動選択後の物体カテゴリの事後確率分布と全モダリティ情報を得た後の最終的な物体カテゴリの事後確率分布の間の KL 情報量を計算し, その平均をとった. 図 4 に標準偏差を誤差棒として添えて示す. 提案手法が最も最終的な認識状態に近づいていることがわかる.

4. まとめと今後の課題

本研究では能動学習の視点からマルチモーダルカテゴリゼーションにおける認識のための行動選択手法を提案し, その最適性を示した. KL 情報量の期待値は情報利得 (Information Gain: IG) とも呼ばれ能動学習や能動視覚においてしばしば用いられる基準である. 本稿では期待 KL 情報量最大化基準がマルチモーダル HDP においても有効であることを示した. また, マ

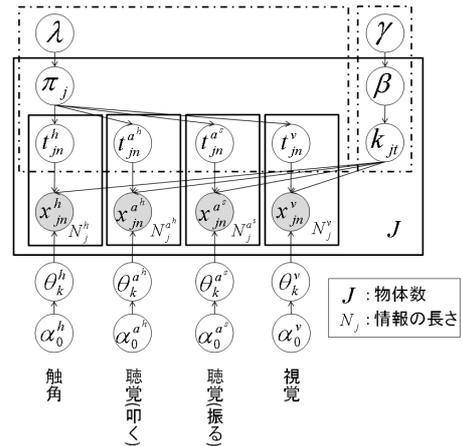


図 2: マルチモーダル HDP のグラフィカルモデル



図 3: 実験に用いた日用品 17 物体とカテゴリ分類の結果

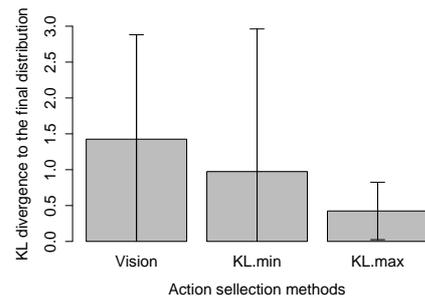


図 4: 行動選択結果の物体カテゴリの事後確率分布と全行動選択後の物体カテゴリの事後確率分布の間の KL 情報量の平均

ルチモーダル HDP のグラフィカルモデルの性質から, 明示的に評価値をモンテカルロ近似により求めることが可能であり, マルチモーダル HDP の理論に数理的に適合した手法であると言える. 今後の課題としては, 学習フェーズにおける能動学習手法の開発が求められる.

参考文献

- [1] Tomoaki Nakamura, Takayuki Nagai, and Naoto Iwahashi. Multimodal categorization by hierarchical dirichlet process. In *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2011)*, 2011.
- [2] Sumantra Dutta Roy, Santanu Chaudhury, and Subshashis Banerjee. Active recognition through next view planning: a survey. *Pattern Recognition*, Vol. 37, No. 3, pp. 429–446, 2004.
- [3] 福田一, 竹下卓哉, 谷口忠大. マルチモーダルカテゴリ推定のための最適な行動選択. 2013 年度人工知能学会全国大会 (JSAI2013), 2013.