

# 触覚・行動情報に基づく物体の多様体学習と能動的物体識別への応用

田中 大介, 松原 崇充, 杉本 謙二 (奈良先端大)

## Object Manifold Learning Based on Tactile and Action Information and Its Application to Active Object Identification

Daisuke TANAKA, Takamitsu MATSUBARA, and Kenji SUGIMOTO (NAIST)

**Abstract:** In this study, we consider an object identification problem based on tactile information using a robot hand. For efficient identification, active learning which obtains more information in short time is more suitable than passive learning. In the active learning algorithm, a model is used for evaluation of the uncertainty in learning. However, object features needed to construct the model are unknown exactly in the object identification problem. In this paper, we propose an unsupervised model learning method based on manifold learning which extracts the object features from tactile and action information. We show experimental results that verify the effectiveness of our proposed method.

**Keywords:** Active Object Identification, Manifold Learning, Gaussian Process Latent Variable Models

### 1 緒言

ロボットが実環境で稼働するためには、その環境を素早く認識するための技術が必要である。本稿ではこのような環境認識問題の一例として、ロボットハンドから取得される触覚情報に基づく物体識別問題 (Fig. 1) を考える。このとき、識別のためにはロボットが対象物体に対して何らかの探索行動を取る必要があるが、予め探索行動が決定されているような受動学習 [1] では識別タスクの達成までに時間を要する。これに対して、現在までに得られた情報に基づき探索行動を設計する能動学習を行うことで、最小限のタスク実行時間で達成可能となる [2, 3]。本稿では能動的に物体識別を行う手法について検討する。

能動的に探索行動を設計する際には、例えば推定の不確実性を測る情報理論的基準を用いることが考えられる。このような基準を用いるためには推定対象に関するモデルを得る必要がある。例えば、Saal らによる触覚情報に基づく能動的パラメータ推定に関する研究 [2] では、液体の粘度を推定する問題を考え、推定する際の探索行動・粘度パラメータ・触覚情報とを結ぶモデルを学習し、探索行動の設計やパラメータ推定に利用している。先行研究において推定対象である液体の粘度は物理パラメータであるため、モデル学習時に真値が与えられる。しかし、本研究で対象とする物体識別問題においては、このように推定対象となる物理パラメータが明確に与えられることは稀である。これは、探索行動の設計や物体識別に必要なモデル学習を困難にする。

そこで本稿では、能動的物体識別問題に適したモデル学習法として、多様体学習に基づく物体特徴抽出付きのモデル学習法を提案する。提案手法は、多様体学習法の一つである GPLVM [7] を基にした教師なし学習法である。効率的な能動学習の枠組みを提供する Saal らの手法を前提として、能動的物体識別に適した多様体学習を行う。これにより識別に適した特徴を抽出し、モデル学習や識別時に利用する。



Fig. 1 Object identification problem based on tactile information

本稿の構成を説明する。まず第 2 章で能動学習について概説する。次に第 3 章で能動的物体識別システムの構成について説明し、そのシステムの有効性の検証を第 4 章で行う。そして第 5 章で本研究をまとめ、今後の検討課題について述べる。

記法: スカラー値  $a, b, \dots$  に対して  $\text{diag}\{a, b, \dots\}$  は、 $a, b, \dots$  を対角要素に持つ対角行列を表す。また、行列  $A$  に対して  $\text{diag}(A)$  は  $A$  の対角要素を抽出しベクトル化する演算子である。さらに行列  $A, B$  に対して  $\text{block diag}\{A, B\}$  は  $A, B$  を対角に並べて構成するブロック対角行列を表す。

### 2 能動学習

能動学習に関する手法は、特に機械学習や人工知能の分野で盛んに研究されてきた。統計学の分野では実験計画法とも呼ばれ、近年ではロボット分野でも注目されている [2–6]。なお本稿における能動学習は、物体探索行動の最適設計とそれに基づく物体識別を逐次的に繰り返すことを指す。

このような能動学習法の例として、Uncertainty Sam-

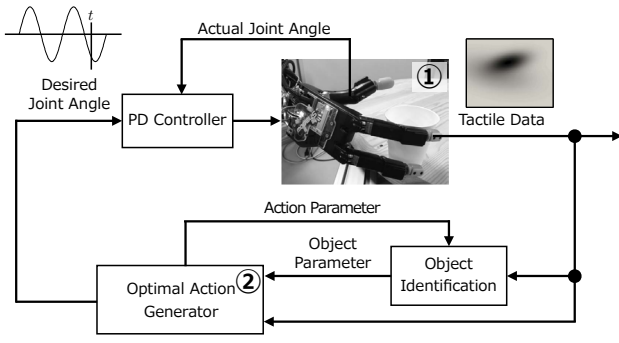


Fig. 2 Overview of the identification system

pling [8] がある。これは、学習器にとって不確実性を最も下げるサンプルを選択する。また、Expected error reduction [9] は汎化誤差を小さくするようなサンプルを選択する。このようなサンプルの選択基準にはエントロピーや average Kullback-Leibler divergence などが利用されているが、本稿では以下の式で表される相互情報量を用いる。

$$I[s; y|x] = \iint p(s, y|x) \log \frac{p(s, y|x)}{p(s)p(y|x)} dy ds \quad (1)$$

ここで、 $x, y$  は選択対象であるサンプルの入力と出力、 $s$  は学習対象である。この相互情報量は、 $y$  を得る前と得た後の  $s$  の不確実性の減少分を表す。すなわち、相互情報量が最大となると、 $s$  の不確実性が最も減ることを意味する。しかし、このような評価基準を利用するには、 $p(s, y|x)$  などの確率モデルが必要となる。次章ではこの確率モデルを得る手法について考え、さらにそれを用いて能動的物体識別を行うシステムを構築する。

### 3 能動的物体識別システム

#### 3.1 システムの概要

識別システムの全体像を Fig. 2 に示す。ロボットの探索行動の設計は、各関節の目標関節角度を与えることに対応する。目標関節角度が与えられると、それに追従するように PD 制御器により各関節が制御される。そのロボットの動作と、動作により得られる触覚情報を基にして物体の識別が行われる。さらにこの識別結果を基にして、次の行動が決定される。本章では最適行動の設計のために必要な、識別対象物体のモデル化と物体の多様体学習に基づく特徴抽出法 (Fig. 2①) と、最適探索行動の設計法 (Fig. 2②) についてそれぞれ 3.2 節と 3.3 節で説明する。最後に、全体の識別アルゴリズムを 3.4 節でまとめる。

#### 3.2 提案法: 行動・触覚情報に基づく識別物体の多様体学習

本節では、識別対象物体に関するモデルを構築する方法について議論する。ここでは Saal らの先行研究 [2] と同様の Gaussian Processes (GP) [10] によるモデル化を考えるが、本研究で対象とする物体識別問題においては識別物体の特徴を表すパラメータが訓練データとして得られない。本研究ではこれを得るため、行動・触覚情報に基づく物体の多様体学習法を提案する。これは、Gaussian Process Latent Variable Models (GPLVM) [7] に基づく多様体学習法であり、物体の特徴を行動・触覚情報に基づき抽出する。Table 1 に Saal らによる先行研究、本研究、GPLVM の問題設定の違いについてまとめる。

まず触覚情報と環境の特徴・行動とを結び関係を GP によりモデル化することから始める。これは、先行研究 [2] と同様のモデルである。観測変数である触覚情報  $y \in \mathbb{R}^{d_y}$  について、以下のような非線形関数  $f$  を考える。

$$y = f(x, s) + \epsilon \quad (2)$$

ここで、 $x \in \mathbb{R}^{d_x}$ ,  $s \in \mathbb{R}^{d_s}$  はそれぞれ潜在変数であり、 $x$  はその触覚情報を得る際の行動を表すパラメータ、 $s$  は識別対象物体の特徴を表すパラメータである。Saal らの先行研究 [2] では  $x, s$  は共に既知であったが、本研究の問題設定では  $s$  は未知とする。さらに  $\epsilon \sim \mathcal{N}(\epsilon|0, \Sigma_\epsilon)$  は観測ノイズであり、平均 0、共分散  $\Sigma_\epsilon = \text{diag}\{\sigma_1^2, \sigma_2^2, \dots, \sigma_{d_y}^2\}$  のガウス分布に従うとする。

式 (2) の非線形関数を、GP を用いてモデル化する。すなわち、 $a = 1, 2, \dots, d_y$  として

$$y_a \sim \mathcal{GP}(0, K_a) \quad (3)$$

を考える。ただし、 $\epsilon_a \sim \mathcal{N}(0, \sigma_a^2)$  であり、学習時の訓練データセットは  $\mathcal{D}_a = \{\mathcal{D}_{a,1}, \dots, \mathcal{D}_{a,L}\}$ ,  $\mathcal{D}_{a,\ell} = \{x^{(\ell,i)}, y_a^{(\ell,i)}\}_{i=1}^{N_\ell}$  である。ここで、 $L$  は識別対象物体数である。この GP モデルではモデルの簡単化のために  $s$  と  $x$  の独立性を仮定し、次式で表されるカーネル関数を考える。

$$k_a(s, x, s', x') = \alpha_a^2 \exp\left(-\frac{1}{2}(s - s')^T (H_a^s)^{-1} (s - s')\right) \times \exp\left(-\frac{1}{2}(x - x')^T (H_a^x)^{-1} (x - x')\right) + \sigma_a^2 \delta_{ss'} \delta_{xx'}$$

ここで、 $\alpha_a^2$  は  $f_a$  の分散であり、 $\delta_{xx'}$  は  $x$  と  $x'$  が同じサンプルであるときに 1、それ以外の時 0 となる演算子である。また、 $H_a^s, H_a^x$  はそれぞれ正の要素を対角に持つ対角行列であり、カーネルに対する  $s, x$  の各次元のスケールを調節する。なお、このモデルは Multifactor Gaussian

Table. 1 Difference of problem settings among Saal et al. [2], ours, and GPLVM [7]

	Saal et al. [2] (GP)	ours	GPLVM [7]
model	multifactor, $\mathbf{y} = \mathbf{f}(\boldsymbol{\theta}, \mathbf{x})$	multifactor, $\mathbf{y} = \mathbf{f}(\mathbf{s}, \mathbf{x})$	singlefactor, $\mathbf{y} = \mathbf{f}(\mathbf{x})$
training data set	$\{\mathbf{y}^{(i)}, \boldsymbol{\theta}^{(i)}, \mathbf{x}^{(i)}\}$	$\{\mathbf{y}^{(i)}, \mathbf{x}^{(i)}\}$	$\{\mathbf{y}^{(i)}\}$
latent variables to be learnt	none	$\mathbf{s}$	$\mathbf{x}$
number of latent variables	—	same as target object	same as training data

Process Models [11] の一例となっている．ここからは，表記の簡単化のため  $\mathbf{z} = [\mathbf{s}^T, \mathbf{x}^T]^T \in \mathbb{R}^{d_z}$ ,  $d_z = d_s + d_x$  を用いる．これにより，上記のカーネル関数は，

$$k_a(\mathbf{z}, \mathbf{z}') = \alpha_a^2 \exp\left(-\frac{1}{2}(\mathbf{z} - \mathbf{z}')^T \mathbf{H}_a^{-1}(\mathbf{z} - \mathbf{z}')\right) + \sigma_a^2 \delta_{\mathbf{z}\mathbf{z}'}$$

と表される．ただし， $\mathbf{H}_a = \text{block diag}\{\mathbf{H}_a^s, \mathbf{H}_a^x\}$  とした．

このモデルを用いて，現在未知である環境の特徴を表すパラメータ  $\mathcal{S} = \{\mathbf{s}^{(1)}, \mathbf{s}^{(2)}, \dots, \mathbf{s}^{(L)}\}$  を GPLVM の考え方に基づき求める．Table 1 に示すように，本研究では考えるモデルと，学習する潜在変数の数の点で異なるが，以下に示すように GPLVM と同様，対数尤度最大化問題を解くことにより潜在変数を求めることができる．式 (3) の GP モデルについて，対数尤度関数は以下のように得られる．

$$\log p(\mathbf{y}_a | \mathbf{X}, \gamma_a, \mathcal{S}) = -\frac{1}{2} \log \det \mathbf{K}_a - \frac{1}{2} \mathbf{y}_a^T \mathbf{K}_a^{-1} \mathbf{y}_a - \frac{1}{2} \log(2\pi) \quad (4)$$

ただし， $\mathbf{K}_a \in \mathbb{R}^{N \times N}$  は  $K_{a,ij} = k_a(\mathbf{z}^{(i)}, \mathbf{z}^{(j)})$  を  $(i, j)$  要素とする行列であり， $\mathbf{z}^{(i)}$  は以下の行列  $\mathbf{Z} \in \mathbb{R}^{d_z \times N}$  の第  $i$  列に対応する．

$$\mathbf{Z} = \begin{bmatrix} \mathbf{s}^{(1)} & \dots & \mathbf{s}^{(1)} & \dots & \mathbf{s}^{(L)} & \dots & \mathbf{s}^{(L)} \\ \mathbf{x}^{(1,1)} & \dots & \mathbf{x}^{(1,N_1)} & \dots & \mathbf{x}^{(L,1)} & \dots & \mathbf{x}^{(L,N_L)} \end{bmatrix}$$

ここで  $N = \sum_{\ell=1}^L N_\ell$  とした．また， $\mathbf{X}$  は  $\mathbf{Z}$  の  $\mathbf{x}$  に対応する部分を抜き出した  $d_x \times N$  行列であり， $\mathbf{y}_a \in \mathbb{R}^N$  は，

$$\mathbf{y}_a = \left[ y_a^{(1,1)} \dots y_a^{(1,N_1)} \dots y_a^{(L,1)} \dots y_a^{(L,N_L)} \right]^T$$

である．さらに， $\gamma_a$  はハイパーパラメータの集合  $\gamma_a = \{\mathbf{H}_a^s, \mathbf{H}_a^x, \alpha_a^2, \sigma_a^2\}$  である． $\mathcal{S}$  はハイパーパラメータ  $\gamma_a$  と同時に， $\mathbf{y}$  の全次元に対する対数尤度関数 (4) を最大化するように決定する．

$$\max_{\gamma_1, \dots, \gamma_{d_y}, \mathcal{S}} \sum_{a=1}^{d_y} \log p(\mathbf{y}_a | \mathbf{X}, \gamma_a, \mathcal{S}) \quad (5)$$

この最適化問題を解くことにより，識別対象物体の特徴抽出と，その特徴・行動と触覚情報を結ぶモデルの学習を同時に行うことが可能である．

### 3.3 最適探索行動の設計とパラメータ推定

最適探索行動は，文献 [2] と同様に相互情報量を最大化するよう決定する．GP によりモデルを得たことで，式 (1) の積分が解析的に評価でき，相互情報量は以下のように表される．

$$I[\mathbf{s}; \mathbf{y} | \mathbf{x}] = -\frac{1}{2} \log \left( \frac{\det \boldsymbol{\Sigma}_{\mathbf{sy}}}{\det \boldsymbol{\Sigma} \det \mathbf{S}} \right) \quad (6)$$

ただし，右辺の行列はそれぞれ次の確率分布の要素から決定される．

$$\begin{aligned} p(\mathbf{s}) &= \mathcal{N}(\mathbf{s} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) \\ p(\mathbf{s}, \mathbf{y} | \mathbf{x}) &= \mathcal{N} \left( \begin{bmatrix} \mathbf{s} \\ \mathbf{y} \end{bmatrix} \middle| \begin{bmatrix} \boldsymbol{\mu} \\ \mathbf{m}(\mathbf{x}) \end{bmatrix}, \boldsymbol{\Sigma}_{\mathbf{sy}} \right) \quad (7) \\ \boldsymbol{\Sigma}_{\mathbf{sy}} &= \begin{bmatrix} \boldsymbol{\Sigma} & \mathbf{C}(\mathbf{x}) \\ \mathbf{C}^T(\mathbf{x}) & \mathbf{S}(\mathbf{x}) \end{bmatrix} \end{aligned}$$

$\mathbf{m}(\mathbf{x}) \in \mathbb{R}^{d_y}$ ,  $\mathbf{C}(\mathbf{x}) \in \mathbb{R}^{d_s \times d_y}$ ,  $\mathbf{S}(\mathbf{x}) \in \mathbb{R}^{d_y \times d_y}$  はそれぞれ次のように表される．

$$\begin{aligned} m_a &= \mathbf{q}_a(\mathbf{x}) \mathbf{K}_a^{-1} \mathbf{y}_a \\ S_{ab} &= \mathbf{y}_a^T \mathbf{K}_a^{-1} \mathbf{Q}_{ab}(\mathbf{x}) \mathbf{K}_b^T \mathbf{y}_b - m_a m_b \\ &\quad + \delta_{ab} (\alpha_a^2 - \text{tr}(\mathbf{K}_a^{-1} \mathbf{Q}_{aa})) \\ \mathbf{C} &= \mathbf{Z}(\mathbf{x}) - \boldsymbol{\mu} \mathbf{m}^T \end{aligned}$$

ただし， $m_a$  は  $\mathbf{m}$  の  $a$  番目の要素， $S_{ab}$  は  $\mathbf{S}$  の  $(a, b)$  要素である． $\mathbf{q}, \mathbf{Q}, \mathbf{Z}$  に関しては文献 [2] を参照されたい．これらが決定されると，現時点での最適な探索行動を式 (6) を最大化することで決定できる．

また， $t$  回目の探索行動  $\mathbf{x}_t$  により得られた触覚情報  $\mathbf{y}_t^{obs}$  を用いて，パラメータを逐次的に更新する． $p_{t-1}(\mathbf{s}) = \mathcal{N}(\mathbf{s} | \boldsymbol{\mu}_{t-1}, \boldsymbol{\Sigma}_{t-1})$  を事前分布， $p(\mathbf{s} | \mathbf{y}_t, \mathbf{x}_t) = p_t(\mathbf{s}) = \mathcal{N}(\mathbf{s} | \boldsymbol{\mu}_t, \boldsymbol{\Sigma}_t)$  を事後分布とすると，式 (7) を用いて以下のようにして逐次的に分布を更新できる．

$$\boldsymbol{\mu}_t = \boldsymbol{\mu}_{t-1} + \mathbf{C}_t \mathbf{S}_t^{-1} (\mathbf{y}_t^{obs} - \mathbf{m}_t) \quad (8)$$

$$\boldsymbol{\Sigma}_t = \boldsymbol{\Sigma}_{t-1} - \mathbf{C}_t \mathbf{S}_t^{-1} \mathbf{C}_t^T \quad (9)$$

ただし， $\mathbf{m}_t = \mathbf{m}(\mathbf{x}_t)$ ,  $\mathbf{C}_t = \mathbf{C}(\mathbf{x}_t)$ ,  $\mathbf{S}_t = \mathbf{S}(\mathbf{x}_t)$  である．

---

**Algorithm 1: Object Identification Algorithm**

---

**Step 1: Model learning**

**input** : Training data sets  $\mathcal{D}_1, \mathcal{D}_2, \dots, \mathcal{D}_{d_y}$  and  
dimension of object feature parameters  $d_s$

**output**: Object feature parameter set  $\mathcal{S}$ , and  
hyperparameter sets  $\gamma_1, \gamma_2, \dots, \gamma_{d_y}$

Solve the maximization problem (Eq. (5))

---

**Step 2: Object Identification**

**input** : Object feature parameter set  $\mathcal{S}$ ,  
hyperparameter sets  $\gamma_1, \gamma_2, \dots, \gamma_{d_y}$ ,  
initial distribution of parameter  $\mu_0$  and  
 $\Sigma_0$ , convergence threshold  $\sigma$ , and  
maximum number of update  $T$

**output**: Identified object number

$$\ell^* \in \{1, 2, \dots, L\}$$

**for**  $t = 1, 2, \dots, T$  **do**

$$\mathbf{x}_t \leftarrow \arg \max_{\mathbf{x} \in \mathcal{X}} I[\mathbf{s}; \mathbf{y}|\mathbf{x}] \text{ (Eq. (6))}$$

Obtain tactile information  $\mathbf{y}_t^{obj}$  by action  $\mathbf{x}_t$

Update  $\mu_t$  and  $\Sigma_t$  using Eqs. (8), (9)

**if**  $\|\mu_t - \mu_{t-1}\|^2 < \sigma$  **then**

**break**

**end**

**end**

$$\ell^* \leftarrow \arg \min_{\ell} \|\mathbf{s}^{(\ell)} - \mu_t\|^2$$

---

### 3.4 識別アルゴリズム

物体識別アルゴリズムを Algorithm 1 に示す．本識別システムは，モデル学習ステップと物体識別ステップの2ステップから構成される．まず，物体の多様体学習により識別対象物体に関するモデルの教師なし学習を行う．そして，得られたモデルを用いて，最適な探索行動を設計し，環境の特徴を表すパラメータ  $\mathbf{s}$  を推定する．そして，得られた推定結果と一番近い  $\mathbf{s}^{(\ell)}$  に対応する物体を識別結果とする．

## 4 実験

### 4.1 実験設定

今回は Fig. 3 に示す  $L = 4$  個の飲料容器の識別を目的とする．これに対して，Fig. 4 に示すロボットハンド (Shadow Robot 社製) と，指先に装着された BioTac センサ (SynTouch 社製) を用いて識別実験を行う．ただし，ロボットハンドで動作させる関節角は人差し指の2




Fig. 3 Objects for Identification Experiment




Fig. 4 Robot hand and tactile sensor for experiment

関節 (FFJ3, FFJ4) とした．これらはそれぞれ，人差し指を内側に曲げる動作と左右に動かす動作を生成する．これらの動作を規定する行動パラメータと触覚情報に関して以下に説明する．

**行動パラメータ** 本実験では，行動パラメータを Dynamic Movement Primitives (DMP) に基づいて設定する．DMP は，軌道の形を規定するパラメータ  $\theta$  を用いて， $\mathcal{Y} = h(\theta, g, \mathcal{P})$  のような関数で軌道を表現する． $\mathcal{Y}$  は  $\theta$  を用いて出力された軌道， $g$  は既知の目標状態であり， $\mathcal{P}$  は時定数などのパラメータ集合である．詳細は例えば文献 [12] などを参照されたい．本実験ではある教示軌道に対してパラメータベクトル  $\theta_{\text{teach}}$  を得ておき， $\theta = \theta_{\text{teach}} + \mathbf{x}$  とし新たな軌道を生成する．具体的な方法は以下のとおりである：本実験ではまず教示軌道として，物体表面を押しした後さらに横にすべらせるような動作軌道を生成した．この軌道を各関節に対して基底数  $M = 25$  で近似し  $\tilde{\theta}_{\text{teach}}$  を得た．本実験ではこの内の3基底分のパラメータを変更することにする．すなわち， $\theta_{\text{teach}}$  は2関節分の  $\tilde{\theta}_{\text{teach}}$  のうち対応するパラメータを抜き出した6次元ベクトルであり，さらに  $d_x = 6$  次元である．これにより生成された FFJ3 の軌道を Fig. 5 に示す．図中の太線は教示軌道で，細い線はパラメータを変更した際に得られた軌道である．FFJ3 は指を内側に曲げる方向の動きを生成することから，大きな関節角は物体を強く押




Fig. 5 Trajectories of FFJ3. Thick line: teaching trajectory, Thin line: examples of generated trajectory

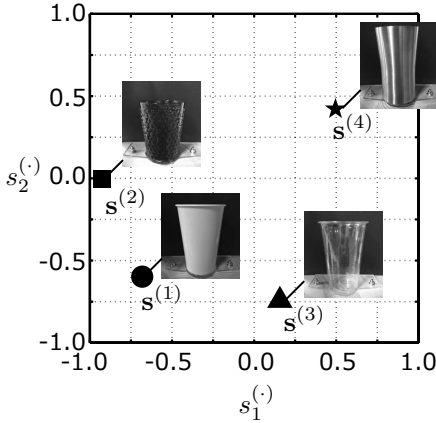


Fig. 6 Result of object manifold learning

すことに対応する．同様に FFJ4 の軌道も DMP によりパラメータ化することで，物体の探索行動の変化と行動パラメータ  $x$  を対応付けることができる．

**触覚情報** BioTac センサは圧力・振動・温度に関する情報を取得することができる．本実験では，Robot Operating System (ROS) 上で取得できるデータのうち  $d_y = 5$  次元分<sup>1</sup>を用いる．このとき，1 個の行動パラメータ  $x$  は 1 個の軌道（時系列データ）を与えるため， $y$  は一回の探索行動で得られたセンサ時系列データの平均値とする．これにより，1 個の触覚情報に時系列情報を集約する．

本実験では， $x$  をガウスノイズにより 500 個生成した．すなわち， $N_\ell = 500$ ， $\ell = 1, 2, 3, 4$  であり，それにより得られた計  $N = 2000$  個の訓練データ  $D$  を用いて， $d_s = 2$  次元の特徴抽出を行い，検証実験を行った．

## 4.2 物体の多様体学習結果

物体の多様体学習を行った結果を Fig. 6 に示す．Fig. 6

<sup>1</sup>振動（2次元），圧力，熱流束，温度に対応するデータを取得している．




Fig. 7 Transitions of mean and standard deviation by active learning

ではそれぞれの物体が距離をあけて配置されていることから，それぞれの物体を識別するに十分な特徴が抽出できていることが確認できる．特に物体 4 (Stainless Cup) に関しては遠い位置に配置しており，他の 3 物体とは特に違う触覚情報が得られていることが読み取れる．物体 4 は特に熱伝達に関して他の 3 物体と異なる特性を持つことから，この多様体学習結果は妥当であると考えられる．

## 4.3 識別シミュレーション実験

得られたモデルを用いて，識別シミュレーション実験を行った．式 (8), (9) の  $\mu_0$  は  $S$  の平均値とし， $\Sigma_0 = 5I_2$  ( $I_2$  は  $2 \times 2$  の単位行列) とした．本実験では真の物体を物体 1 (Paper cup) とし，得られた GP モデルを用いて  $y_t^{obs}$  を得た．このときの物体の特徴を表すパラメータの推移を，能動学習の場合と受動学習の場合とで比較する．なお，本実験において能動学習による最適行動設計では，ランダムに  $x$  を 100 個生成し，その中で相互情報量が一番大きいものを最適行動パラメータとした．また，受動学習では，ランダムに  $x$  を 1 個生成し，それを行動パラメータとした．これを最大更新回数  $T = 15$  としてパラメータ更新を繰り返した．ここで，能動学習を行った場合の  $\mu_t, \Sigma_t$  の推移を Fig. 7 に示す．Fig. 7 において，太い実線が平均値，平均周りの灰色の範囲が  $\pm\sigma$  ( $\Sigma_t$  の対角要素の平方根に対応) の範囲を示している．また，黒い点線は物体の多様体学習により得られた真値  $s^{(1)}$  であり，灰色の一点鎖線は他の物体の値  $s^{(2)}, s^{(3)}, s^{(4)}$  に対応する．この図から，能動学習による物体識別で正しい物体が識別結果として得られることが確認できる．受動学習においても，同様に正しい物体が識別結果として得られるが，ここで  $\Sigma_t$  の推移を Fig. 8 に示し能動学習と受動学習を比較する．Fig. 8 において，能動学習により推定分散がより早く小さくなっていることから，受動学習に対する能動学習の有効性が確認できる．今回の実




Fig. 8 Update number  $t$  vs. variance norm  $\|\sigma_t\|$ , where  $\sigma_t = \text{diag}(\Sigma_t)$

験設定では能動学習を行った場合も受動学習を行った場合も、共に識別結果は物体 1 ( $\ell^* = 1$ ) であり、これは  $t = 1$  の時点で達成されているため、識別率の意味での違いは確認できなかった。今後は、物体数の多い問題設定 ( $L \geq 10$ ) において実験を行い、識別率への影響を検証する。

## 5 結言

本稿では、行動・触覚情報に基づく物体の多様体学習により識別対象物体の特徴を抽出するモデル学習法を提案し、それをを用いた能動的物体識別システムを構築した。提案するモデル学習法は、識別対象物体の特徴を GPLVM の考え方に基づく多様体学習法により抽出する。またこのシステムの有効性を、実機から得たデータによりモデルを構築し識別シミュレーション実験を行うことで確認した。

今後の検討課題を以下に挙げる。ロボット分野における能動学習は、予め設計された行動セットから最適な行動を能動的に選択する手法 (例えば [6]) と、より自由に最適な行動を設計する手法 (例えば [2–5]) とに大別され、本提案法は後者に分類される。これら能動学習の手法間での詳細な比較検討は今後行いたい。また、現在行動パラメータは DMP に基づくため、時系列データと対応する。これに対して、触覚情報は平均操作を取ることにより時系列データを 1 個のデータに集約している。これは、最適化問題を簡略するが、一方で、探索行動中の触覚情報の変化を考慮できないことを意味する。今後、このような変化を考慮できる手法への改良を目指したい。さらに、今回は予め教示軌道を与えることで DMP のパラメータ  $\theta_{\text{teach}}$  を決定し、その周りで新たな動作を生成した。今後は教示軌道周りではなく自由な動作を行わせるような改良も行いたい。

## 参考文献

- [1] Z. Pezzementi et al.: Tactile-object recognition from appearance information, *IEEE Transactions on Robotics*, 27, 3, 473/487 (2011)
- [2] H. P. Saal et al.: Active sequential learning with tactile feedback, *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics*, 677/684 (2010)
- [3] N.F. Lepora et al.: Active touch for robust perception under position uncertainty, *Proceedings of 2013 IEEE International Conference on Robotics and Automation*, 3020/3025 (2013)
- [4] B. Browatzki et al.: Active object recognition on a humanoid robot, *Proceedings of 2012 IEEE International Conference on Robotics and Automation*, 2021/2028 (2012)
- [5] S. Caselli et al.: Efficient exploration and recognition of convex objects based on haptic perception, *Proceedings of 1996 IEEE International Conference on Robotics and Automation*, 4, 3508/3513 (1996)
- [6] A. Schneider et al.: Object identification with tactile sensors using bag-of-features, *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems*, 243/248 (2009)
- [7] N. Lawrence: Probabilistic non-linear principal component analysis with Gaussian process latent variable models, *Journal of Machine Learning Research*, 6, 1783/1816 (2005)
- [8] D. Lewis et al.: Heterogeneous uncertainty sampling for supervised learning, *Proceedings of the 11th International Conference on Machine Learning*, 148/156 (1994)
- [9] N. Roy et al.: Toward Optimal Active Learning through Sampling Estimation of Error Reduction, *Proceedings of 18th International Conference on Machine Learning*, 441/448 (2001)
- [10] C. E. Rasmussen et al.: Gaussian processes for machine learning, MIT Press (2006)
- [11] J. M. Wang et al.: Multifactor Gaussian process models for style-content separation, *Proceedings of the 24th Annual International Conference on Machine Learning*, 975/982 (2007)
- [12] A. J. Ijspeert et al.: Learning attractor landscapes for learning motor primitives. *Advances in Neural Information Processing Systems 15*, 1547/1554 (2003)