

家庭用ロボットの遠隔操作に基づく動作の学習と生成

Learning and Generation of Actions from Teleoperation for Domestic Service Robots

岩田 健輔^{*1}
Iwata Kensuke

青木 達哉^{*1}
Aoki Tatuya

堀井 隆斗^{*1}
Horii Takato

中村 友昭^{*1}
Nakamura Tomoaki

長井 隆行^{*1}
Nagai Takayuki

^{*1}電気通信大学

The University of Electro-Communications

In this paper, we propose a method for motion learning aimed the execution of autonomous household chores by domestic service robot in real environments. For autonomous activity by robots in home environment, it needs to define appropriate actions for the environment. However, it is difficult to define these actions manually. Therefore, body motions that are common to plural actions are defined as primitive motions. Complex actions can then be learned by combining these primitive motions. For learned primitive motions, we propose a reference-point and object dependent Gaussian process hidden semi-Markov model (RPOD-GP-HSMM). For confirmation, a robot perform actions included in several domestic household chores by tele-operation. The robot then learns the associated primitive motions from the robot's physical information and object information.

1. はじめに

近年サービスロボットの開発が活発化しており、実験室や商店などの限定された環境下ではロボットが自律的に活動することができる。しかし、一般家庭など事前に詳細な情報を把握できない環境下ではユーザのサポートを行うことは未だ困難である。

実環境で活動するためには、その環境に適した行動が定義されている必要がある。文献 [1] では、行動の中に出現する共通した身体の動きを基本動作とし、基本動作を学習して行動を表現する研究が行われている。日常的な活動が一連のタスクであると仮定すると、各タスクは一連の行動により構成され、行動は基本動作の組み合わせによって表現されるものと定義することができる。一方でこの研究は人間の行動を対象としており、ロボットに直接適用することは困難である。

そこで、本研究では、ロボットを遠隔操作し家事を行わせることで、観測した身体情報と物体情報を元に、家事に含まれる基本動作の学習を試みる。また学習した基本動作を組み合わせ行動の生成を行う。遠隔操作により取得した時系列情報はばらつきが多い。よって、取得した情報を類似した基本系列に分節分類することで、基本動作の学習を試みる。動作学習のみならず、分節分類を行う手法は多く存在する [2]。中でもガウス過程に基づく隠れセミマルコフモデル (GP-HSMM) は高い性能を発揮している [3]。しかし、家庭内のタスクに適用するにあたり、GP-HSMM の利用に2つ問題が存在する。1つは、系列情報を表現する座標系が固定されている為、物体との位置関係を考慮できない点。2つ目は、扱う物体によって軌道の変位量が異なることである。

本稿では、GP-HSMM を拡張し参照点と操作対象に依存した GP-HSMM (Reference-point and object dependent Gaussian process hidden semi-Markov model: RPOD-GP-HSMM) を提案する。同時に、学習した基本動作を組み合わせ行動を生成する手法を提案し、実環境下においてそれぞれの手法を評価したので報告する。

2. 参照点と操作対象に依存した動作学習

この章では、GP-HSMM を家庭内の基本動作を学習できるモデルへと拡張するために、2つの問題に対する解決策と提案モデルの説明を行う。

2.1 参照点

従来の GP-HSMM は1つの座標系による動作軌道を学習の対象としていた。従って、物体に対して手を伸ばす動作を表現する場合、その位置関係に応じて異なった軌道が学習されていた。しかし、この動作で重要なのは、軌道の形状ではなく対象の位置である。そこで、動作を表現する座標系を推定する参照点の概念を適用することでこの問題の解決を図る [4]。

参照点による動作学習では、参照点となる物体を推定することで動作の学習が行われる。しかしながら、どの軌道に対してどの座標系が適切であるかは定まっていない。よって、動作軌道に対応した座標系を設計することが重要である。座標系を設計するためにデータベース [5] を使用して、家の中の日常的な行動を分類する。ここではデータベース内の258の行動を対象とする。これらの258の行動を、1500の動作に分割し参照点の座標系の設計を行う。この時分割する動作は、動作の対象物と軌道の形状に基づき手動で分割を行った。1500の動作を以下の8つの動作軌道に分類を行った。

- a) リーチング動作: 手先を対象物に近づける動作
- b) 離す動作: 手先を対象物から遠ざける動作
- c) 並進動作: 手先を自身の軸に沿って平行に動かす動作
- d) 掴む動作: 手先の開閉を行う動作
- e) 設置動作: 物体を床や平面に置く動作
- f) 静止動作: 動作軌道の開始位置と終了位置が一致する動作
- g) 回転動作: 手先姿勢の回転を行う動作
- h) 移動: 手先の動作ではなく台車の動きを表現する動作

連絡先: 岩田 健輔, 電気通信大学, 東京都調布市調布ヶ丘 1-5-1,
042-443-5000, iwata@apple.ee.uec.ac.jp




図 1: RPOD-GP-HSMM により設計された参照点座標系

移動は、自身が作業する環境を変えることを目的とする為、座標系の設計には考慮しない。従って、7つの分類された軌道を表現する座標系を考慮し、以下の3つの座標系を設計し分類を行った。

1. 2つの軸を回転し対象間の距離を強調する座標系 (a,b)
2. 1つの軸を回転し対象間の高さを強調する座標系 (e)
3. 物体固有の姿勢に基づく座標系 (c,d,f,g)

図1に座標系の例を示す。まず、物体にはそれぞれ固有の3軸の姿勢があると仮定する。座標系1は、その中の高さを表す軸と左右のずれを表す軸を回転し、手先と物体間の距離を強調できるように設計された座標系である。物体との距離が重要となるa,bの動作が分類される。座標系2は、高さを表す軸のみを回転させ、物体と手先との間の高さを強調した座標系である。物体との高さの差が重要となるcの動作が分類される。座標系3は、軸の回転を行わず、軌道の形状を強調した座標系である。物体を操作するc,d,f,gの動作が分類される。これらの座標系は、学習された各基本動作それぞれに設定され、基本動作の動作軌道は参照点を基準とした座標系により表現される。

2.2 操作対象

従来のGP-HSMMでは、学習データ全てを対象に一つのモデルで学習を行っていた。その為、リーチング動作などの変位の大きい動作は、分節分類が容易であった。しかし、物体操作に関する動作軌道は変位が小さく、他の軌道と合併する可能性が高く学習が困難である。例えば、ドアノブを捻る動作は、軌道の変位が小さい。しかし、正確にドアノブを捻ることができなければ、扉を開けることが不可能である。この動作は特に物体を操作する動作に出現する。また、対象となる物体に対して固有に出現する動作である。そこで、この問題を解決するために、物体ごとにその検出区間を対象に基本動作の学習を図る。

2.3 Reference-point and object dependent GP-HSMM

従来のGP-HSMMは、観測された時系列データ全体を一度に分節化する。ここで、 c_j ($j = 1, 2, \dots, J$) はガウス過程によって生成された j 番目の分節 $\mathbf{x}_j$ のクラスを表す。

$$c_j \sim P(c|c_{j-1}), \quad \mathbf{x}_j \sim \mathcal{GP}(\mathbf{x}|\mathbf{X}_{c_j}), \quad (1)$$

$\mathbf{X}_c$ は $\mathbf{x}_c$ の集合を表しており、ガウス過程 $\mathcal{GP}$ を表現するためのパラメータに用いられる。

一方提案手法であるRPOD-GP-HSMMは、まず物体情報に基づいて分節を行い、適切な参照点をもつ基本動作の学習を行う。各基本動作は参照点を持つ。その為、時系列データ $\mathbf{x}_j$ の各分節は、選択された参照点 ℓ に基づき座標変換が行われ $\bar{\mathbf{x}}_j$ に変換される。従って、物体カテゴリ o のガウス過程 $\mathcal{GP}_o$ は以下のように表すことができる。

$$\bar{\mathbf{x}}_j = T(\mathbf{x}_j, \ell), \quad \bar{\mathbf{x}}_j^o \sim \mathcal{GP}_o(\mathbf{x}|\bar{\mathbf{X}}_c^o), \quad (2)$$

$T(\mathbf{x}, \ell)$ は選択した参照点 ℓ により定義される座標変換の関数を表す。 $\bar{\mathbf{X}}_c^o$ は物体カテゴリ o のクラス c に分類された分節を表す。

提案されたRPOD-GP-HSMMは従来のモデルと同様に forward filtering-backward sampling を行う。forward filtering では、観測された情報 $\mathbf{s}_o$ のタイムステップ t より、 $\mathbf{s}_{t-k:t}^o$ の分節がクラス c となる前向き確率 α_o を求める。

$$\alpha_o[t][k][c] = P(T(\mathbf{s}_{t-k:t}^o, \ell) | \bar{\mathbf{X}}_c^o) \times \sum_{k'} \sum_{c'} p(c|c') \alpha_o[t-k][k'][c'], \quad (3)$$

$p(c|c')$ はクラス間の遷移確率を表す。また $t-k < 0$ となる区間においては、前向き確率を $\alpha_o[t][k][*] = 0$ とし、初期状態における前向き確率は $\alpha_o[0][0][c] = p_0(c)$ とする。 $p_0(c)$ は初期状態の遷移確率を表しており以下の式で表現される。

$$p_0(c) = \frac{N_{0c}^o + \delta}{\sum_c (N_{0c}^o + \delta)}, \quad (4)$$

ここで N_{0c}^o と δ は $\mathbf{s}_o$ の最初の分節がそれぞれクラス c となった回数と平滑化パラメータを表す。 $P(T(\mathbf{s}_{a:b}^o, \ell) | \bar{\mathbf{X}}_c^o)$ は分節 $\mathbf{s}_{a:b}^o$ が $T(\cdot, \ell)$ によって変換されたものであり、物体カテゴリ o のクラス c におけるガウス過程から生成される確率である。

$$P(T(\mathbf{s}_{t-k:t}^o, \ell) | \bar{\mathbf{X}}_c^o) = \mathcal{GP}_o(T(\mathbf{s}_{t-k:t}^o, \ell) | \bar{\mathbf{X}}_c^o) P_l(k|\lambda) \\ \ell = \operatorname{argmax}_{\ell_i} \mathcal{GP}_o(T(\mathbf{s}_{t-k:t}^o, \ell_i) | \bar{\mathbf{X}}_c^o), \quad (5)$$

P_l は分節長の確率分布である λ の平均を持つポアソン分布である。参照点の候補となる対象 ℓ_i は複数存在しており、ガウス過程の出力確率を元に、最も可能性の高いものを選択する。

3. RPOD-GP-HSMMに基づく行動生成

この章では学習された基本動作を組み合わせ、行動を生成する方法を説明する。また、生成した行動を実行するうえで必要な、現在位置を考慮した軌道の生成や力を考慮した生成の方法についても本章で説明を行う。

3.1 基本動作の選択

学習されたRPOD-GP-HSMMを用いて、基本動作を組み合わせ行動を生成する。生成するためには、動作の接続順序を決定することが必要である。そこで、学習したクラス間の遷移確率 $p(c_j|c_{j-1})$ に従って、動作の接続順序を求める。

$$c_t = \operatorname{argmax}_c P_{\mathbf{x}_h}(c|c_{t-1}) = \operatorname{argmax}_c (P_{\mathbf{x}_h}(c)P(c|c_{t-1})), \quad (6)$$

$P_{\mathbf{x}_h}(c)$ は、ロボットの現在の手先位置 $\mathbf{x}_h$ に対して選択されるクラス c の確率を表し、次式のように求めることができる。

$$P_{\mathbf{x}_h}(c) = \int_{\mathbf{x}_h - \mathbf{r}}^{\mathbf{x}_h + \mathbf{r}} \mathcal{GP}_o(\mathbf{x} | \bar{\mathbf{X}}_c^o) d\mathbf{x}. \quad (7)$$

この確率 $P_{\mathbf{x}_h}(c)$ は物体とロボットとの位置関係を表し、学習したガウス過程 $\mathcal{GP}_o(\mathbf{x} | \bar{\mathbf{X}}_c^o)$ を用いることで計算することが可能である。 $\mathbf{x}_h$ は現在の手先位置 $\mathbf{x}_h$ によって定義される単位系列を表し、 $\mathbf{x}_h - \mathbf{r}$, $\mathbf{x}_h + \mathbf{r}$ の範囲で積分することにより確率を計算する。 $\mathbf{r}$ は微小区間を表し、ロボットの移動速度と自己位置の推定精度により決定される。初期動作 c_0 の選択には、式4において学習された初期遷移確率 $p_0(c)$ を用いる。

$$c_0 = \operatorname{argmax}_c (P_{\mathbf{x}_h}(c)p_0(c)). \quad (8)$$

動作の終了は、次の確率 $p_e(c)$ を用いる。

$$P_e(c) = \frac{l_c}{n_c} (1.0 - 2\delta) + \delta, \quad (9)$$

ここで、 n_c は学習された時系列データ s^o においてクラス c が出現した回数を表しており、 l_c は終端に現れた回数を表す。 δ は平滑化パラメータであり、 $P_e(c) > 0.5$ の場合行動が終了となる。

3.2 現在位置を考慮した動作軌道の生成

選択された動作軌道同士の接続部は、滑らかであるとは限らない。そこで、現在の手先位置から学習軌道に対して、近づけていく軌道を求めることにより、現在位置を考慮した動作軌道を生成する。この軌道 x はクラス c のガウス過程 $\mathcal{GP}_o(x|\bar{X}_c^o)$ と現在の手先位置の系列 x_h を用いたガウス過程 $\mathcal{GP}(x|x_h)$ により表現することができる。

$$x \sim \mathcal{GP}_o(x|\bar{X}_c^o)\mathcal{GP}(x|x_h). \quad (10)$$

ガウス過程 $\mathcal{GP}(x|x_h)$ の平均 $\mu_{h,i}$ と分散 $\sigma_{h,i}$ は、 x_h と移動速度に基づいて決定されます。平均 $\mu_{h,i}$ は時間 i にかかわらず一定であるが、分散 $\sigma_{h,i}$ は移動速度を基準に増加する。この値を元に時間 i の動作軌道 $x(i)$ を求めたものが次式である。

$$\begin{aligned} x(i) &\sim \mathcal{N}(x|\mu_{c,i}, \sigma_{c,i}^2)\mathcal{N}(x|\mu_{h,i}, \sigma_{h,i}^2) \\ &\approx \mathcal{N}\left(x \middle| \frac{\sigma_{c,i}^2 \mu_{h,i} + \sigma_{h,i}^2 \mu_{c,i}}{\sigma_{c,i}^2 + \sigma_{h,i}^2}, \frac{\sigma_{c,i} \sigma_{h,i}}{\sigma_{c,i}^2 + \sigma_{h,i}^2}\right). \end{aligned} \quad (11)$$

また、近似は $\mu_{c,i}$ と $\mu_{h,i}$ が十分近い時に成立する。これにより、現在位置を考慮した滑らかな軌道を生成が可能となる。

3.3 力を考慮した動作の実行

物体を操作する上で力を制御することは非常に重要である。物体に力を加える動作の場合、ある量の反力が手先に加わる。ドアノブを捻る動作などは、瞬間的にある程度の大きさの力を要求される。物体を押す動作などは、力を加え続ける必要がある。しかし、過剰な力が加わる場合は力を逃す必要がある。そこで、加えられた力の大きさとその分散から3つの力の加え方があると考えられる。我々は、ロボットの手首に配置された力センサの値に基づき、腕部のインピーダンスパラメータを設定する方法を提案する。力の値は基本動作の分節の力の集合 $\bar{X}_c^o$ より算出される。この系列の平均と分散が計算され、インピーダンスパラメータを決定する。腕部のコントロールは3つの段階 N, H, S を設定する。各段階は、加わった力の平均と分散の値とそれらの閾値 M, Σ に基づき決定される。この M, Σ の値は、オペレータが経験的に決定する。 N は力の平均が大きく、分散が小さい動作を示し、一定の力を加える動作を表す。従って、位置制御により動作を実行する。 H は力の平均が大きく、分散が大きい動作を示し、瞬間的に力が加わる動作を表す。その為、関節への過負荷を防ぐため、一定以上の力を逃す硬い制御を行う。 S は力の平均が小さい動作であり、力が加わることを想定していない動作である。よって、力を逃す制御を行うのが適切である。それぞれのパラメータを表1に示す。

4. 実験

提案手法を用いた動作学習が可能であることを示すために、図2に示すような複数の行動を内包したタスクを実行した。実験にはトヨタ自動車(株)が開発した、Human Support Robot(HSR)を使用した。本研究では、HSRの関節を遠隔操作し、タスクを14回実行してそれぞれの身体情報と物体情報

表 1: インピーダンス条件・設定値

名前	平均	分散	力制御	慣性	粘性	ばね性
N	$\geq M$	$< \Sigma$	$\times$	-	-	-
H	$\geq M$	$\geq \Sigma$	$\bigcirc$	25.0	50.0	200.0
S	$< M$	-	$\bigcirc$	25.0	100.0	600.0




図 2: 片付けタスク:行動, 物体, 環境

を取得した。そして、取得した情報を用いて基本動作の学習と、行動の生成を行った。取得した情報は、身体情報として手先の姿勢7次元(位置:(x,y,z), 姿勢:(qx,qy,qz,qw))に、開閉情報(open:1,close:0)を含めた8次元の系列である。物体情報は、物体の姿勢7次元(位置:(x,y,z), 姿勢:(qx,qy,qz,qw))とその認識結果(etc:box,door)を用いた。また、比較のため参照点のみを用いた場合と操作対象のみを用いた場合の分節分類との比較と、力を考慮しない場合の行動の成否の比較を行った。

4.1 動作の分節化と分類結果

図3には、人手による正解と、RPOD-GP-HSMMと参照点のみを用いたGP-HSMM(RPD-GPHSMM)、操作対象のみを用いたGP-HSMM(OD-GP-HSMM)との分節分類結果を示した。図3のラベルは、動作軌道を確認し妥当と思われるものを人手でつけたものである。RPODとRPDはそれぞれ正解の分節位置と近い分節を学習できている。しかし、RPDではドアノブの操作を学習することができず、異なった軌道が学習されてしまった。一方、RPODではドアノブを押す動きと結合してしまっていたが、ドアノブを捻る軌道を学習できていることが確認できた。ODでは、ドアノブを捻る動きを学習することは出来ていた。しかし、ドアノブまでの軌道が物体を基準としていないため、動作の実行が位置関係に依存してしまっている。これらのことから、提案手法による基本動作の分節分類により適切な動作が学習できていると考えられる。

4.2 行動生成

図4はドアを基準として学習されたガウス過程を表す。図4,3の色は対応している。ここでは8次元の内、手先位置(x,y,z)と開閉(1:開,0:閉)の4次元の情報を示した。図中の青い線はGPの平均を表し、赤い幅は分散を表す。手先を近づける動作は、固定された座標系で学習されてしまった。これは、扉との位置関係に大きな変化がなかったためだと考えられる。学習された基本動作を用いて行動の生成を行い、行動を実行可能な基本動作が学習されたか確認を行う。




図 5: 基本動作の組み合わせによるドア開けの行動




図 3: 条件の異なる GP-HSMM との比較




図 4: ドアを対象としたガウス過程の平均と分散

図 5 はドアを対象とした基本動作を、提案した基本動作の選択確率に従い組み合わせ、実行したものである。それぞれの動作は表 2 に示した、インピーダンスパラメータに従い実行した。ここでは、インピーダンスパラメータの閾値 $M = 0.5, \Sigma = 1.5$ とした。図 5 上段のグラフはドアノブから見た手先の軌道を表しており、下段のグラフは、動作時に手先に加わった力を示している。ドアノブを把持し、捻るタイミングで大きな力が加わっていることが確認できる。力を考慮しない場合、このドアノブを捻る力を逃すことができず、関節に負荷がかかり、行動を実行することができない。一方、力を考慮したドアノブを捻る動作では、ドアノブを捻る方向である y 軸方向へ力をかける制御を行い、ドアを開けている。インピーダンスパラメータでは、ドアノブを捻る Class2 の動作のインピーダンスパラメータは H となっている。これには 2 つの原因があると考えられる。一つは、前段階の Class3 の動作において、ある程度ドアノブを捻る動きが観測されたこと。2 つ目は押し開ける動きが結合されてしまった為、力の分散が大きくなったことである。いずれにしても、ドアノブを開けるに際して適切な制御が行われており、組み合わせることで行動が生成可能な動作軌道が学習されていると示せている。また、動作選択により、適切な基本動作が組み合わせたり、力の考慮により、ドアを操作する複雑な動作も実行可能となることを示せた。

表 2: ドアを対象とした基本動作のインピーダンス

Class	x 軸	y 軸	z 軸
Class1	N	S	H
Class2	S	H	S
Class3	S	N	S
Class4	S	N	S
Class5	S	S	S

5. まとめ

本稿では、サービスロボットの動作学習の手法として参照点と操作対象に依存したガウス過程に基づく隠れセミマルコフモデル (RPOD-GP-HSMM) を提案した。提案した手法を用いることで、ロボットを遠隔操作することで、複数の行動を内包した家庭内タスクを実行し、その行動に含まれる基本動作の学習を行った。学習された基本動作は、対象を基準とした軌道で学習されており、位置関係によらず実行可能である。また、ドアノブを捻るなどの細かい軌道も学習することが可能であることを示した。同じく提案された選択確率とインピーダンスの決定により、実際にタスク内に出現した行動を実行可能であることを示した。しかし、扉が開いたことの検知や、ドアノブを正確に把握できたことの認識が行えていない。今後は、対象の状態を認識した、より高度な動作の選択を課題とする。

謝辞

本研究は、JST, CREST(JPMJCR15E3) の支援を受けたものである。ここに感謝の意を表する

参考文献

- [1] M. Sanzari *et al.* Human motion primitive discovery and recognition. arXiv preprint arXiv:1709.10494, 2017.
- [2] T. Tagniguchi *et al.* Unsupervised segmentation of human motion data using sticky hdp-hmm and mdl-based chunking method for imitation learning. *Advanced Robotics*, pp. 2143–2172, 2011.
- [3] T. Nakamura *et al.* Segmenting continuous motions with hidden semi-markov models and gaussian processes. *Frontiers in neurorobotics*, pp. 67, 2017.
- [4] K. Sugiura *et al.* Learning, generation and recognition of motions by reference-point-dependent probabilistic models. *Advanced Robotics*, pp. 825–848, 2011.
- [5] 一般社団法人 人間生活工学研究センター HQL データベースサイト 高齢者身体機能データベース. <https://www.hql.jp/database/cat/senior/funcdb>.