

# ロボットの連続的な動作学習の為にフレームワーク

## Framework for Continuous Motion Learning by Robots

岩田 健輔  
Iwata Kensuke

宮澤 和貴  
Miyazawa Kazuki

池田 成満  
Ikeda Narumitu

青木 達哉  
Aoki Tatuya

中村 友昭  
Nakamura Tomoaki

長井 隆行  
Nagai Takayuki

電気通信大学

The University of Electro-Communications

In this paper, we propose a framework for an action learning from the robot's continuous motions. First, the robot performs tasks by user's teleoperation. At that time, the robot accumulates joint angles, images and various information acquired by the teleoperation. We would like to realize the framework that enables the robot to perform tasks autonomously without user's teleoperation by learning behaviors from such information. Moreover, we consider incorporating huge amount of topdown knowledge such as ontology constructed manually.

### 1. はじめに

近年少子高齢化の影響や、計算機の発展により、人間の生活支援を目的とした家庭用ロボットの開発が活発化している。また、徐々にではあるが、それらは家庭環境への導入も試みられている。限定された家庭環境では、ロボットの動作を作り込むことによってロボットが自律的にタスクを実行することは可能である。しかし、環境は家庭によって異なり、あらかじめ全てを作り込むことは困難である。実環境においてロボットが人間の生活を支援するためには、人間の活動や環境に合わせて動作を学習することができる、柔軟なシステムが必要となる。そこで本稿では、ロボットが自身の身体の情報を用いて柔軟に動作を学習するためのフレームワークを検討する。ロボットは学習初期の段階では、家庭内において自律的にタスクを行うことが困難である。そこで、人間の遠隔操作により、タスクを実行することを考える。この時、ロボットは自身の身体情報を含む、環境の情報を収集し、自身のデータベースに蓄積する。そして、蓄積されたデータを用いて動作や行動の学習を行う。ここで、行動とはプリミティブな動作を組み合わせて構成されたものであると定義し、タスクはこの行動を組み合わせて実行することができる。動作の学習には連続的な関節角の情報や、ロボットの周囲にある物体の情報を用いる。我々は動作の対象となる参照点を推定し、連続な身体情報を分節・分類することで動作を学習する手法を提案した [岩田 16]。自身の動作の対象を推定しつつ、タスクの中で行われる基本となる動作を学習することができる。さらに、提案フレームワークを拡張することで、ボトムアップに学習した動作と、トップダウンに与えられる知識を組み合わせることで、行動やタスクの学習を行うことも可能であると考えられる。また、対象となる物体と動作の関係を学習することで、物体に対する適切な動作を学習することも可能である。 [宮澤 16]。このようにして遠隔操作から学習することで、ロボットは徐々に自律的に活動することが可能になると考えられる。本稿は、このフレームワークにおける最初の段階として、提案するフレームワークを用いて、遠隔操作により取得した身体と環境の情報から動作の学習を行う。

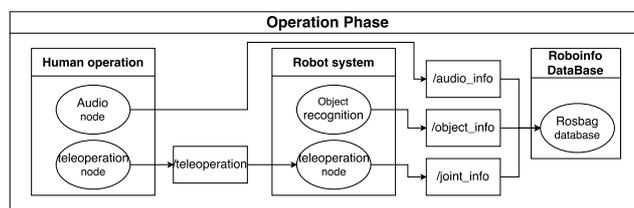


図 1: 遠隔操作時のシステム図

### 2. 関連研究

動作や行動の学習に関する研究として、人間がの動作を模倣し学習する模倣学習 [田淵 06] や、日常生活における行動から、動作を抽出する研究 [Kulic 08] などがあげられる。本研究における重要な点は、人間が目的をもってロボットを直接操作し、ロボットの身体情報や、ロボットが得ることができる環境情報から動作を抽出、学習する点である。人が遠隔操作することで、ロボットが行う行動には、ロボットの身体、他者から与えられる命令、そして周囲の物体を含む環境など様々な情報が作用することになる。そのタスクに含まれる動作を抽出、学習することにより、自律的にタスクを実行することが本研究の目的である。また、文献 [Kulic 08] と本研究は共に日常中での行動を動作ごとに分節・分類することで動作を学習している。しかし、文献 [Kulic 08] では、家庭環境から得られる人の動作を対象としているのに対し、本稿では、人間による操縦から得られる、ロボットの動作を対象としている。本稿における動作の学習には、文献 [岩田 16] において提案された手法を用いている。文献 [岩田 16] では動作の対象となる物体（参照点）の候補は一つだけであった。しかし、環境中には複数の物体があり、参照点の候補は複数存在する。そこで、本稿では複数の参照点候補から、動作の参照点を推定する手法を提案する。さらに文献 [Baris 12] では、遠隔操作による動作学習の利点と問題点が指摘されている。問題点として、動作を教示する上で遠隔操作はインタラクティブではない点があげられている。一方、利点として、ロボットと直接同じ空間にいないとも、ロボットに対して動作の教示を行うことができる点が挙げられている。本研究におけるロボットの動作の学習は、人間の生活支援を行う事を目的としているため、ロボット自身の情報を、よりタス

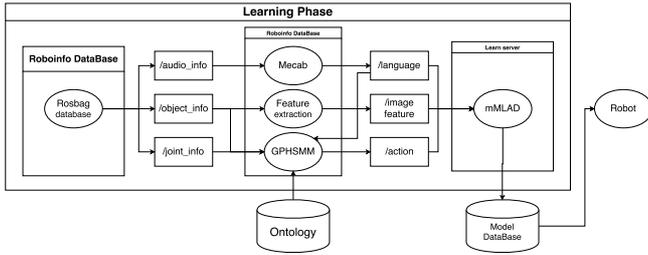


図 2: 学習時のシステム図

ク実行に則した形で取得できることが望ましい., 教示者が遠隔からロボットに干渉せずに, タスクを実行できる, 遠隔操作による動作学習を選択した.

### 3. 提案モデル

#### 3.1 情報取得及び学習のフレームワーク

本研究におけるロボット間の通信及び実装には Robot Operating System(ROS)を用いる. 図 1, 図 2 に本研究で提案するフレームワークのシステム図を示す. 各プログラムはそれぞれノードとして実装されており, 情報を Topic としてやり取りするシステムとなっている. 図 1 は遠隔操作により情報を取得するシステムを示したものである. 遠隔操作ノードと音声認識ノードより, 人から与えられる教示音声の情報と遠隔操作情報を取得する. 遠隔操作情報はロボットへと渡され, ロボットはその情報をもとにタスクを実行する. この時ロボットが取得することのできる関節角情報や, カメラから取得できる画像情報と画像を認識して得られる物体情報, 人間からの教示音声の情報を保存する. データの保存には ROS で広く用いられている Rosbag を用いる. Rosbag は ROS ネットワーク上で流れている情報, Topic の保存に適しており, 各情報をその取得時間と共に保存することが可能である. これらの情報が十分に蓄積された後, これらの情報は図 2 に示す学習部において様々な学習に利用される. Rosbag より取り出された情報は, それぞれ対応したノードへ渡される. 音声情報は Mecab による形態素解析を用いることで, 単語の出現頻度を表わす Bag of Words へと変換される. 検出された物体画像からは, 畳み込みニューラルネットワーク (CNN) を用い, 特徴量が抽出される. 関節情報, 物体情報は参照点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 (GPHSMM) へと送られる. GPHSMM では取得したそれぞれの情報から基本動作を抽出することができる. また, これらの基本動作の抽出時に, その動作の対象となる物体も推定することができる. この情報と, 音声から抽出された単語情報, そしてオントロジーによる大規模な知識の情報を組み合わせることで行動を学習する. 最後に, 抽出された言語, 物体の情報と, 学習された行動の情報を多層マルチモーダル LDA(mMLDA)[宮澤 16] を用いて学習し, 物体に対する最適な行動を学習する. このようにして学習したモデルを用いることで, ロボットが自身の情報をもとに, 自律的にタスクを実行することが可能になると考える.

#### 3.2 多層マルチモーダル LDA

多層マルチモーダル LDA(mMLDA) は, 下位層に物体, 行動, 場所などの下位概念を表現するマルチモーダル LDA(MLDA) を, 上位層にそれらを統合する MLDA を配置した階層的な構造をもつ確率モデルである. これにより行動, 物体, 場所など各々カテゴリ分類を行うと同時に, それらの概念間の関係性を教師なしで学習することができる [Attamimi 14].

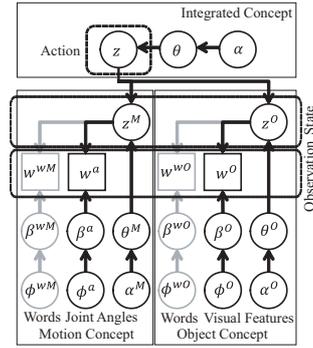


図 3: 多層マルチモーダル LDA

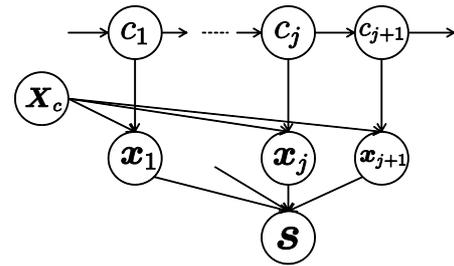


図 4: ガウス過程に基づく隠れセミマルコフモデル

図 3 は mMLDA のグラフィカルモデルである. 図 3 において  $z$  は統合概念を表すカテゴリであり,  $z^O$ ,  $z^M$  はそれぞれ下位概念に相当する, 物体, 行動カテゴリである.  $w^o$ ,  $w^a$  は観測データであり, それぞれ物体情報とロボットの行動情報である.

#### 3.3 ガウス過程に基づく隠れセミマルコフモデル

ガウス過程隠れセミマルコフモデル (GPHSMM) は, 連続値である動作系列を連続値のまま教師なしで分節化することで, 単位動作の学習が可能手法である [岩田 16]. 隠れセミマルコフモデルにおける出力分布を, ガウス過程とすることで, 一つの状態が, 一つの連続的な基本動作を表現するモデルとなっている. 図 4 が GPHSMM のグラフィカルモデルである. 図 4 における  $c_j (j = 1, 2, \dots, J)$  が基本動作のクラスを表しており, クラスと対応した  $X_c$  をパラメータに持つガウス過程から分節  $x_j$  が生成される. また, 分節にはそれぞれ基準となる参照点が存在しており, 分節は参照点を基準とした座標系へと変換される. 本稿では物体と自身の身体の 2 つを参照点として考えている.

$$c_j \sim P(c|c_{j-1}) \quad (1)$$

$$x_j \sim \mathcal{GP}(x, \text{landmark} | X_{c_j}) \quad (2)$$

ただし,  $X_c$  はクラス  $c$  に分類された分節の集合である. 文献 [岩田 16] ではこの landmark の候補として一つの対象物体しか取り扱う事が出来なかった. 本稿では, 対象物体基準の動作に対しては, その動作の対象となる物体の推定も行う. GPHSMM では観測系列が基本動作ごとに分節される確率  $\alpha$  からサンプリングすることで, 観測系列を分節・分類することができる.

$$\begin{aligned} \alpha[t][k][c] &= P(s'_{t-k:k} | X_c) \\ &\times \sum_{k'=1}^K \sum_{c'=0}^C p(c|c') \alpha[t-k][k'][c'] \quad (3) \end{aligned}$$

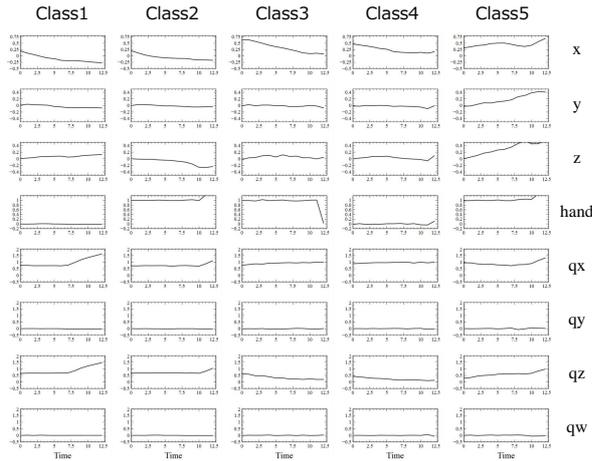


図 5: 学習された基本動作

この式において  $t, k, c$  はそれぞれ、分節位置、分節幅、分節のクラスとなっている。  $C$  はクラス数、  $K$  は単位系列の最大の長さとなる。  $P(s'_{t-k:k} | \mathbf{X}_c)$  は、クラス  $c$  から、  $s'_{t-k:k}$  が生成される確率であり、この確率に従い対象物体を分節毎に決定する。

$$\begin{aligned}
 P(s'_{t-k:k} | \mathbf{X}_c) &= \mathcal{GP}(s'_{t-k:k}, \text{landmark} | \mathbf{X}_c) P_{len}(k | \lambda) \\
 \text{landmark} &= \underset{\text{landmark}_i}{\operatorname{argmax}} (\mathcal{GP}(s'_{t-k:k}, \text{landmark}_i | \mathbf{X}_c))
 \end{aligned}
 \tag{4}$$

対象物ごとの確率値を計算し、最も高い確率となる物体を対象物体としてを選択する。

## 4. 実験

提案フレームワークによって、ROS による情報の取得と、その情報を用いた動作学習を行った。実験では、家庭内における片づけタスクを対象とした。遠隔操作によりロボットは、環境内を移動し探索し、物体を拾い、物体を置くという動作を行い、その間発見した物体の位置と自身の手先の情報を保存し、その情報を基に動作を学習した。

### 4.1 基本動作の抽出

家庭内タスクより抽出された手先の基本動作を図 5 に示す。GPHSM による学習には事前にクラス数を設定する必要がある。ここでは、5 つに設定し、動作の分節分類を行った。図に示された遷移は、それぞれ参照点に対する手先の動きを表している。分節分類には手先の  $x, y, z$  座標、手先の開閉、手先の姿勢のクォータニオンを用いた。それぞれの分節に対して、対象となる物体の位置は明示的には与えていないにもかかわらず、抽出された動作は、自身を基準とした移動時の手先の動きと、物体を対象とした動きが適切に抽出された。Class1,2 の動作は、それぞれ自身を参照点とした身体基準の動作である。この二つのクラスに対しては、物体を対象としない、移動の動作が分類、表現された。Class3, 4, 5 の動作はそれぞれ、物体に接近する動きが分類された。Class3, 4 の動作は物体を拾う動作、置く動作が分類された。Class5, の動作は物体を置い

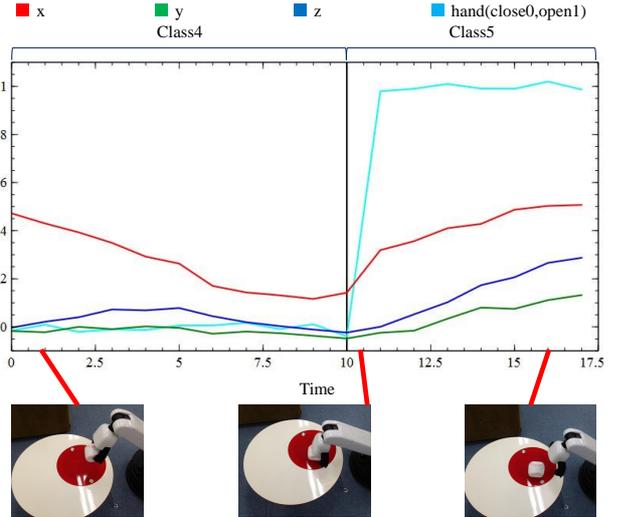


図 6: 同一物体を対象にした基本動作の組み合わせ

た後の腕を戻す動きが分類された。また、分節された動作系列と、その参照点を確認すると、Class4, 5 の動作はそれぞれ連続して出てくることが多く、また、その動作が対象とする物体は同一の物を示すことが多かった。この二つの動作を連結したものが、図 6 である。これらの動作は規則的に出現しており図に示すようにこの二つの動作を結合することで、ハンドを開き物体を離し、腕を戻す、物体を置くという行動を構成できると考えることができる。動作を行動へと自律的に発展させることも可能ではないかと考えられる。

## 5. まとめ

本稿では、ロボットにおける ROS を使用した動作学習のフレームワークを提案した。まだ基礎的な検討段階ではあるが、ロボットの身体情報や環境情報の取得を行い、それらの情報を用いた動作の抽出を行った。連続的な手先位置の位置と動作の対象となる物体の推定も同時に行うことで、より家事タスクに則した基本的な動作の抽出を行うことができた。また、抽出された基本動作とその動作が対象としていた物体を比較することで、同一の物体への動作を組み合わせる事で行動の学習ができる可能性を示した。今後の課題としては、オントロジー等の大規模なデータベースと、言語情報を組み合わせることによる、行動の自動生成を行うことがあげられる。また、今回のモデルでは、分類のクラス数を事前に与えていたが、このクラス数の推定をノンパラメトリックな手法を用いて自動推定することが今後の課題である。

## 謝辞

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

---

## 参考文献

- [岩田 16] 岩田 健輔, 中村 友昭, 長井 隆行, 持橋 大地, 小林 一郎, 麻生 英樹 “参照点に依存したガウス過程隠れセミマルコフモデルに基づく連続動作の分節” 第 34 回日本ロボット学会学術講演会, RSJ2016AC3Z2-07
- [宮澤 16] 宮澤 和樹, 青木 達也, 日永田 智絵, 中村 友昭, 長井 隆行 “多層マルチモーダル LDA と強化学習による行動学習”, 第 34 回日本ロボット学会学術講演会, RSJ2016AC3Z1-06
- [田淵 06] 田淵 一真, 谷口 忠太, 樫木 哲夫 “模倣学習と強化学習の調和による効率的行動獲得’ The 20th Annual Conference of the Japanese Society for Artificial Intelligence, 2006, 3C1-2.
- [Kulic 08] D.Kulic, W.Takano and Y.Nakamura, “Incremental learning clustering and hierarchy formation of whole body motion patterns using adaptive hidden markov chains” International Journal of Robotics Research, Vol.27, No.7, pp.761-784, 2008
- [Baris 12] Baris Akgun, Kaushik Subramanian and Andrea L. Thomaz, “Novel Interaction Strategies for Learning from Teleoperation” AAAI Publications, 2012 AAAI Fall Symposium Series, AAAI Technical Report, FS-12-07
- [Attamimi 14] M. Attamimi, M. Fadlil, K. Abe, T. Nakamura, K. Funakoshi, and T. Nagai “Integration of Various Concepts and Grounding of Word Meanings Using Multi-layered Multimodal LDA for Sentence Generation”, IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.2194-2201, 2014