

東大 IRT 研究機構における制御システム研究

人間の全身運動プリミティブの漸次的な学習

クリッチ・ダナ、李東姫、オット・クリスチアン、○中村仁彦(東京大学)

Control System Study at IRT Research Initiative of University of Tokyo

Incremental Learning of Whole Body Motion Primitives of Humans

Dana Kulić, Dongheui Lee, Christian Ott, *Yoshihiko Nakamura (University of Tokyo)

Abstract — This paper describes an approach for incremental learning of full body motion primitives from observation of human motion. An on-line approach for segmentation, clustering and sequential relationship learning of motion primitives is proposed. The approach is implemented and tested on the IRT humanoid robot.

Key Words: incremental learning, humanoid robots, whole body motion primitives

1. はじめに

観察とイミテーションを通しての学習は、人型ロボットのための有益な能力である。それはロボットがヒューマノイドロボットと人間の身体構造の類似性を利用することを可能にし、複雑なロボット動作のプログラミングを不要にする。これまで多くの見まね学習のアルゴリズムが提案されてきた[1] [2]。大部分のアプローチはオフラインの学習を前提としてきた。データは最初に集められて、分節化されて、類似な運動グループに分類されて、オフラインの学習過程に使われる。しかし、人間の環境で働くロボットは、その全ての動作時間にわたって連続学習をしなければならない。ロボットは人間と共存、協調して動作しながら、その一方でオンラインで示された行動を分節化し、分類し、学習し、その知識を自己組織化しなければならない。

本研究では、人間の全身運動プリミティブのオンラインで分節化、クラスタリング、およびプリミティブの間の関係性の漸次的な学習アプローチを提案する。観察した時系列データは最初に適切な長さの時系列に確率的に分節化される。分節化された運動は、漸次的なクラスタリング方法を通して。この間に学習した運動から木構造が形成され、おのこの運動タイプを生成するモデルに抽象化する。これに並行して、運動プリミティブの連続関係を表現するグラフモデルを構築される。グラフは学習した運動プリミティブとそれらの関係にもとづいて、ロボットの新しい運動シーケンスを生成するのに使うことができる。運動プリミティブのグラフが人間の運動の観察されたパターンを抽象化したものであるため、運動プリミティブのグラフは人間の運動の理解に使うことができる。運動プリミティブのグラフは、人間の運動を観察して、通常の運動か、通常でない運動かの判定に用いることができる。また、観察の履歴に基づいて、近い将来の人間の運動を予測するのに用いることもできる。

2. 確率的な分節化

Kohlmorgen と Lemm の分節化のアルゴリズム [3] [4] は、同じ運動プリミティブに属しているデータは根底に共通するある確率分布を持つという発想に基づく。入力された時系列データは、まずより高い次元のスペースに最初に組み込まれる。次に、多変量ガウスカーネルをもつ標準的な確率密度モデルを用いて、長さ W のスライディングウィンドウの上のデータの密度分布が推定される。多くの観察、蓄積されたデータを用いて、連続したデータウィンドウの間の距離は既知確率密度関数の成分で表した二乗エラーとして計算することができる。この距離は、混合ガウス型確率密度関数の場合、解析的に計算することができる。解析計算はスライディングウィンドウに関して隠れマルコフモデルを定義することによって行われる。各々のウィンドウは、HMM の状態と一致し、各々の状態に対して観察確率分布は、状態と観察の間の距離を表す。分節結果は、ヴィタービアルゴリズムによって最適な状態遷移系列を計算することによって得られる。

3. 漸次的な運動プリミティブの学習

入力された時系列データがプリミティブに分節化されると、それらはクラスタリングモジュールに順番に渡される。これまでに提案されたクラスタリングアプローチ[5] [6]を用いて、ロボットが学習した運動を表現する階層的な木構造が漸次的に作られる。木の各々のノードは運動プリミティブを代表するので、似ている運動を認識でき、そのうえロボットのために対応する運動を生成するためにも用いられる。運動を表す空間の各々の領域の中で、標準的なクラスタリング技術 [7]を用いて、運動プリミティブを再分割することができる。HMM は観察系列を抽象化するのに使われる。モデルのパラメータは、データセットの特徴を形成する。これらの特徴は、観察系列の間でクラスタリングで使う距離を定義するのに用いられる。

アルゴリズムは、最初に 1 つのグループ (ルートノード) で始まる。教師の運動が観察されるたびに、




Fig.1 - Overview of the Incremental Clustering Algorithm (A square represents a data sequence, and a circle represents a group). (a) a new observation sequence is observed and encoded as an HMM; (b) the observation sequence is compared to existing groups via tree search; (c) the new sequence is placed in the closest existing group; (d) local clustering is performed on the modified group (zoomed in view of modified group); (e) a new subgroup is formed from similar motions in the modified group; (f) the subgroup is added to the tree as a child of the modified group.

それを HMM に記号化し、木検索手法による既存のグループと比較し、最も近いグループに入れられる。グループが修正されるたびに、グループの例の中でローカルなクラスタリングを実行される。十分な数の類似なクラスタが見つかった場合には、子グループがデータサブセットとしてつくられる。このようにして、アルゴリズムはロボットの観察に基づいて、次第に運動プリミティブのスペースを学んでゆき、知識として自己組織化する。アルゴリズムの木構造化プロセスを Fig. 1 に示す。

この方法によって、ロボットは教師を連続観察する間、観察した運動を学び、分類する。学習した階層構造から、簡単な検索を類似性と履歴に基づいて行うことにより、自動的に運動を生成をすることができる。そのうえ、ロボットの知識は観察したトレーニングデータのタイプに基づいて組織化されるため、ロボットの知識はデータが多く観察された運動の領域でより詳細化される特徴を持つ。

クラスタノードが形成されると、そのノードは運動プリミティブを抽象化したものを表している。抽象化されたノードからロボットの運動軌道を生成するには、決定論的な運動生成方法を採用した[8]。この方法では、各々の時刻で、一つの状態が担当する時間は状態遷移モデルから最初に推定される。以降の状態はグリーディポリシーによって選ばれる。出力観察ベクトルは、それから出力モデルからグリーディポリシーによって生成される。結果として軌道は不連続な変化をしがちになるが、力学的な安定性を満たすようにローパスフィルターを通したのちに、コントローラに目標値として与えられる。

4. 運動プリミティブのグラフ

運動プリミティブを代表する階層的な木構造の構築と同時に、プリミティブの間で観察された運動の遷移を表わすグラフを構築することによって、プリミティブの関係性を学習する。運動プリミティブのグラフノードは運動プリミティブを代表し、それらの間のエッジは 2 つの運動プリミティブの間で観察された遷移を表している。

最初は、運動プリミティブが存在しないため、グラフは空集合からはじまる。新しい運動プリミティブが葉ノード（第 III 節で記述される）としてクラスタリング方法によって抽象化されるたびに、対応するノードは運動プリミティブのグラフに加えられる。漸次的なクラスタリング方法は、運動認識の際にも実行される。新しく観察された運動部分が木構造

の既存の（非ルート）ノードに置かれるとき、ノードと一致した運動プリミティブとして認識されたことを示す。2 つの連続的な運動プリミティブの移行が起こり、運動プリミティブの遷移モデルがしだいに構築されてゆく。運動プリミティブへの移行が新たに起きるたびに、エッジは増加する。このようにして、ロボットは漸次的に運動プリミティブを増やし、それらがどのように結合できるかを学習してゆく。

構築したグラフは、エッジでつながったノードを連結することによって運動プリミティブの系列を生成するのに用いられる。グラフは、観察されたことのない新しい運動プリミティブのシーケンスを生成することもできる。このように、ロボットはその既知の運動プリミティブとそれらの関係に基づいて新しい運動を生成することができる。また、運動グラフは観察された人間行動の抽象化モデルを表現しているため、このシステムは人間の活動をモニターして、観察された人間の将来の動作を予測するのに用いることもできる。

提案されたアプローチは、グラフィックスキャラクターアニメーション [9] [10] のために使用される運動グラフ手法と類似している。しかし、運動グラフ手法との大きな違いは、グラフが個々の姿勢ではなく運動プリミティブから成るということである。これは、結果として生じるグラフが小さく、したがってより簡単に検索でき、適当なシーケンスを生成するためにより少ない計算で実現できることを意味する。運動プリミティブが一つの連続的な運動を記号として抽象化するため、運動プリミティブのグラフはより高い抽象化レベルにあるといえる。

5. 実験

提案した方法をテストするために、大きなデータセットをいろいろな全身運動の長い連続シーケンスとして収集した。Fig. 2 は、モーションキャプチャシステムのセットアップとマーカーの取り付け位置を表す。34 のマーカーが使われた。データセットは、一つの人間の 20 分の連続全身運動データから成る。

モーションキャプチャシステム[11]は、10ms のサンプリングで体に取り付けられたマーカーの三次元座標を計算し、リアルタイムでデータを関節角度に変換するために、逆運動学計算を実行する。32 の 1 自由度回転関節と 6 次元の自由度を持つベースボディがあるロボットの運動学モデルを使った。

ロボットベースボディと関節角度の連続時系列デ

ータは、運動プリミティブと運動プリミティブのグラフの学習に用いられた。結果として得られた運動プリミティブの木構造を Fig. 3 に示す。運動プリミティブに付けられたラベルは、抽出されたプリミティブを確認することによって、あとで手作業で付けたものである。抽出されたプリミティブから構築した運動プリミティブのグラフを Fig. 4 に示す。

運動プリミティブと運動プリミティブのグラフ抽出の後で、えられた動作軌道は 38 自由度をもつ IRT 人型ロボットのコントローラに目標値として出力され、ロボットの運動制御に使われた。実験では、頭の 3 関節、各腕の 7 関節、各脚の 6 関節だけを使い、指とつま先の 8 関節は使われなかった。

現在のハードウェア実装のために、脚運動（例えば、歩く）を必要とする動作は、運動シーケンスを生成する前に、運動グラフから手作業で取り除いた。これらの運動プリミティブを取り除いた後、運動シーケンスを運動プリミティブのグラフの上で各々の以降のノードから出力端の無作為抽出によって発生させた。各々の運動プリミティブは、関連 HMM モデルから決定論的な方法を使って生成した。連結されたシーケンスは、それから、目標軌道としてロボットに渡される前にローパスフィルターに通された。ロボットの速度制限のために、生成した軌道は、人間と比較して半分程度の速度となった。

Fig. 5 は、ロボットで実行された運動プリミティブのシーケンスから得た結果の映像をフレームで表したものである。ロボットはプリミティブとして以下のシーケンスを実行した：「左腕上げ」「左腕下げ」「前屈下げ」「前屈上げ」「右腕上げ」「右腕下げ」「前屈下げ」「前屈上げ」「右腕上げ」「右腕下げ」「しゃがみ下がる」「しゃがみ上がる」「左腕上がる」「左腕下げ」「前屈下げ」「前屈上げ」「両腕上げ」「両腕下げ」「右腕上げ」。

連続的でなければならないプリミティブの情報を正しく抽出できたことが、Fig. 4 から分かる。たとえば、「前屈上げ」はいつも「前屈下げ」の後に来る。二番目の重要な結果は、提案した分節化とクラスタリングの方法は十分正確なプリミティブを抽出できたことである。これらは学習した運動プリミティブのグラフによって連結されて、ロボットのなめらかな、連続的な運動を生成するために使われる。

6. 結論

本論文では、人間の観察を通して、全身運動プリミティブと称される運動プリミティブの順番をオンラインで連続的に学習するためのアプローチを提案した。観察された人間の運動は、オンライン逆運動学を通してロボット関節角度データに最初に変換される。その後、関節角度データは確率的な分節化[3][4]によって、運動プリミティブに自律的に分けられる。分節化された運動プリミティブの候補は、より抽象化された運動プリミティブ[5]のモデルを得るためにクラスタリングされる。新たな運動プリミティブ

が加わると、それは運動プリミティブのグラフにも加えられる。グラフは運動プリミティブの関係と順番を学習するために漸次的に更新される。構築した運動プリミティブのグラフは、運動プリミティブから生成した動作をつなぎ合わせて運動シーケンスを生成するのに用いられる。

本研究は科学研究費補助金基盤研究 18.06754 と (S) 「知能の力学的情報処理モデルの展開、20220001」代表者：中村仁彦)の支援を受けた。



Fig.2 Motion Capture and Marker Setup

参考文献

- [1] C. Breazeal and B. Scassellati, "Robots that imitate humans," *Trends in Cognitive Sciences*, vol. 6, no. 11, pp. 481-487, 2002..
- [2] S. Schaal, A. Ijspeert, and A. Billard, "Computational approaches to motor learning by imitation," *Philosophical Transactions of the Royal Society of London B: Biological Sciences*, vol. 358, pp. 537 - 547, 2003.
- [3] J. Kohlmorgen and S. Lemm, "A dynamic HMM for on-line segmentation of sequential data," in *NIPS 2001: Advances in Neural Information Processing Systems*, T. G. Dietterich, S. Becker, and Z. Ghahramani, Eds., vol. 14, 2002, pp. 793-800.
- [4] B. Janus, "On-line motion segmentation algorithm for imitation model," Master's thesis, University of Tokyo, 2006.
- [5] D. Kulić, W. Takano, and Y. Nakamura, "Incremental on-line hierarchical clustering of whole body motion patterns," in *IEEE International Symposium on Robot and Human Interactive Communication*, 2007, pp.1016-1021.
- [6] D. Kulić, W. Takano, and Y. Nakamura, "Towards life-long learning and organization of whole body motion patterns," in *International Symposium of Robotics Research*, 2007, pp.113-124.
- [7] A. K. Jain, M. N. Murty, and P. J. Flynn, "Data clustering: A review," *ACM Computing Surveys*, vol. 31, no. 3, pp. 264-323, 1999.
- [8] D. Kulić, W. Takano, and Y. Nakamura, "Representability of human motions by factorial hidden markov models," in *IEEE International Conference on Intelligent Robots and Systems*, 2007, pp. 2388-2393.
- [9] L. Kovar, M. Gleicher, and F. Pighin, "Motion graphs," in *ACM SIGGRAPH*, 2002, pp. 473-482.




Figure 3 Tree diagram of the extracted motion primitives following 15 minutes of observation. 'LKR' = Left Kick Raise, 'MMID' = March mid step, 'MRL' = March Right Leg Raise, 'BAR' = Both Arms Raise, 'BAD' = Bow Down, 'BAU' = Bow Up, 'RAR' = Right Arm Raise, 'LAR' = Left Arm Raise, 'LAL' = Left Arm Lower, 'RAL' = Right Arm Lower, 'BAL' = Both Arms Lower, 'AR' = Arms Ready, 'RKR' = Right Kick Re-tract, 'LPR' = Left Punch Retract, 'SQD' = Squat Down, 'MLR' = March Left Raise, 'SQR' = Squat Raise.




Figure 4 Generated Motion Primitive Graph. The node label corresponds to the tree node in Figure 6, while the number in brackets indicates the node formation order.




Figure 5 Frames from the video capturing the experiment. A frame is extracted once for every 2s of the video sequence.

[10] 山口よしふみ、山根克、中村仁彦、大規模モーションデータベースの構築とアニメーション制作技術への応用、ROBOMEC2008, 1P1-J18.K.

[11] Kurihara, S. Hoshino, K. Yamane, and Y. Nakamura, "Op-

tical motioncapture system with pan-tilt camera tracking and realtime data processing," in IEEE International Conference on Robotics and Automation, vol. 2, 2002, pp. 1241-1248.