

全身運動のオンライン抽象化と可視化

クリッチ・ダナ, 今川洋尚, 中村仁彦*

On-line Abstraction and Visualization of Full Body Motions

Dana KULIĆ, Hirotaka IMAGAWA and Yoshihiko NAKAMURA

*¹ Tokyo University, Graduate School of Information Science and Technology
7-3-1 Hongo, Bunkyo-ku, Tokyo 113-8656, Japan

This paper proposes an on-line, interactive approach for incremental learning and visualization of full body motion primitives from observation of human motion. The human demonstrator motion is captured in a motion capture studio. The continuous observation sequence is first partitioned into motion segments, using stochastic segmentation. Motion segments are next incrementally clustered and organized into a hierarchical tree structure representing the known motion primitives. At the same time, the sequential relationship between motion primitives is learned, to enable the generation of coherent sequences of motion primitives. A visualization system is also developed to allow the demonstrator to visualize the motion database and the motion primitives learned by the system. An online system and user interface for demonstrating and viewing motion primitives and their relationship is developed and tested. -----

Key Words : incremental learning, motion primitives, motion visualization, humanoid robots

1. 結 言

観察とイミテーションを利用した学習は、人型ロボットにとって重要である。そして、ヒューマノイドロボットと人間の身体構造の類似性の利用は、複雑なロボット動作のプログラミングを不要にできる可能性がある。また、オンライン観察中に動作プリミティブとその遷移を抽出するという重要問題は、学習システムによって解決できるものと考えられる。自律的な動作文節化、既に学習した動作プリミティブの検知、自律的な新しい動作プリミティブのクラスタリングと学習、そして、各動作プリミティブをどのようにシーケンス結合し、新しい行動を生成するかの学習である。さらに、デモンストレータは何がここまで学習されたかを視覚的に確認することも、学習のためのデモンストレーションにおいて重要である。

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)。Taylorらは⁽³⁾、Conditional Restricted Boltzmann Machine (CRBM) を使って、人間の動作をモデル化するためのアプローチを提案した。学習したモデルは連続動作シーケンスを生成でき、別の動作への遷移も学習できる。JenkinsとMataric⁽⁴⁾は、ST-Isomap 寸法縮小⁽⁵⁾に基づく人間のモーションキャプチャデ

ータの分析アプローチを提案した。Calinonらは⁽⁶⁾、隠れマルコフモデル (Hidden Markov Model – HMM) に基づく Programming by Demonstration (PbD) のシステムを提案した。中岡らは⁽⁸⁾、ダンス動作のプリミティブの分析、生成と可視化システムを提案した。しかし、大部分のアプローチはオフラインの学習を前提としている。データは予めデザイナーによって採取され、分節化、類似する動作グループへの分類も、オフラインで学習過程に渡される。しかし、人間の環境で働くロボットは、常に稼働中の連続学習を要求される。ロボットは人間と共存、協調して動作しながら、オンラインで観察した行動を分節化し、分類、学習し、その知識を自己組織化しなければならない。

我々の研究のゴールは、人間の環境で働き、人間と交流している間、観察から連続的に学ぶことができるロボットを開発することである。学習過程は教師にとって単純で直観的でなければならず、教師は手で動作プリミティブか動作構成要素であるかを示すことなしに、ロボットはそれらを自動抽出できなければならない。Kulićら^(7,11)は人間の全身動作プリミティブのオンラインでの分節化、クラスタリング、およびプリミティブ間の関係を漸次的に学習するアプローチを提案してきた。観察した時系列データは最初に適切な長さの時系列データに確率的に分節化される。分節化された動作は、漸次的にクラスタリングされる。

*原稿受付 2008年10月24日

¹正員, 東京大学 (〒112-8656 東京都文京区本郷 7-3-1)
E-mail: {dana,imagawa,nakamura}@ynl.t.u-tokyo.ac.jp




Fig. 1 - Overview of the integrated system. $[x,y,z]$ marker position data is first converted to joint angle data for the humanoid kinematic model using on-line inverse kinematics. The joint angle data is next segmented using on-line stochastic segmentation (Section 2.1). Segments are incrementally clustered and organized in a tree-structure (Section 2.2). At the same time, the temporal relationships between segments are learned via the motion primitive graph (Section 2.3). Walks on the motion primitive graph can be used to generate command trajectories for the humanoid robot.




Fig. 2 - 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.

この間に学習した動作から木構造が形成され、おのこの動作タイプを生成できるモデルに抽象化する。これに並行して、動作プリタイプの連続関係を表現するグラフモデルが構築される。グラフは学習した動作プリタイプとそれらの関係に基づいて、ロボットの新しい動作シーケンスを生成するために使用される。全ての手順を、図 1 に示す。これら漸次的学習と動作抽象化に加え、トレーニング中、教師がシステムの学習度に応じた教示を施すためには、それまでの学習の状態を教師に示すための仕組みが必要である。本研究では、動作プリタイプのデータベースと動作プリタイプのグラフを可視化するためのシステムを提案する。この可視化システムにより、人間のデモンストレータ、またユーザーは、現状のロボットの知識に対するより良い洞察を得られるだろう。教示が対話的になることで、更なる学習の効率化が期待できる。第 2 節は、文節化、クラスタリングと動作プリタイプグラフの構造プロセスを概説する⁽⁷⁻¹¹⁾。第 3 節は、可視化アプローチを述べる。第 4 節は実験の結果を示して、第 5 節で結論を述べる。

2. 分節化、動作プリタイプの学習と動作プリタイプグラフの構成

2.1 確率的な分節化

Kohlmorgen と Lemm の分節化のアルゴリズム^(12,8)は、同じ動作プリタイプに属するデータは、潜在的に共通する確率分布を持つという発想に基づいている。入力された時系列データは、まず、より高次元のスペースに格納される。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上

のデータの密度分布が得られる。観察、蓄積された多量のデータにより、連続したデータウィンドウ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、ヴィテル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で得られる。全てのヴィテルビアルゴリズムによって、同じ状態に属すると考えられるウィンドウは、同じ部分に置かれる。したがって、ウィンドウサイズ W は、分節化の最小単位である。 W が予想された最も短い動作プリタイプより小さくなるように、選ばなければならない。十分に小さい W が選ばれる限り、ヴィテルビアルゴリズムで測定される部分が複数のウィンドウを含むので、 W のサイズが与えるアルゴリズムへの影響は小さい。

2.2 漸次的な動作プリタイプの学習

入力された時系列データがプリタイプに分節化されると、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^(7,9)を用いて、ロボットが学習した動作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動作プリタイプを代表するので、似ている動作を認識でき、そのうえロボットのために対応する動作を生成するためにも利用できる。動作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⁽¹³⁾を用いて、

動作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ために使われる。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に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。教師の動作が観察されるたびに、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。観察された動作のHMMは単純なleft-to-rightタイプである、6ノードがあるモデルを使用する。グループのHMMは単純なモデルかFactorialHMMが選択される⁽⁹⁾。

HMMの学習は全てオンラインで行う。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が実行される。クラスタリングの方法にはcomplete link hierarchical clusteringを使う⁽¹³⁾。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より、次第に動作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図2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、観察した動作を学び、分類する。学習した階層構造から、類似性と履歴に基づいて簡単な検索を行うことで、自動的に動作を生成することができる。また、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動作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、そのノードは動作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動作軌道を生成するには、決定論的な動作生成方法を採用した⁽¹⁴⁾。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イポリシーによって選ばれる。出力観察ベクトルは、その後出力モデルからグリーデイ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。

2・3 動作プリミティブのグラフ 動作プリミティブを表す階層木構造の構築と同時に、プリミティブ間で観察された動作の遷移を表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。動作

プリミティブのグラフノードは動作プリミティブを表し、それらの間のエッジは2つの動作プリミティブ間で観察された遷移を表している。

最初は、動作プリミティブが存在しないため、グラフは空集合から始まる。新しい動作プリミティブが葉ノード（第2.2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、対応するノードは動作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は、動作認識の際にも実行される。新しく観察された動作部分が木構造の既存の（非ルート）ノードに置かれるとき、ノードと一致した動作プリミティブとして認識されたことを示す。2つの連続的な動作プリミティブの移行が起り、動作プリミティブの遷移モデルが次第に構築されてゆく。動作プリミティブへの移行が新たに起きる度に、エッジは増加する。このようにして、ロボットは漸次的に動作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動作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動作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動作プリミティブとそれらの関係に基づいて新しい動作を生成することができる。また、動作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ができる。

提案したアプローチは、グラフィックスキャラクターアニメーション⁽¹⁵⁻¹⁶⁾のために使用される動作グラフ手法と類似している。しかし、動作グラフ手法との重要な違いは、グラフが個々の姿勢ではなく動作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。動作プリミティブが一つの連続的な動作を記号として抽象化するため、動作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。

3. 可視化

デモンストレーションプロセス中（オフライン時も同様に）、システムがこれまで学習した内容の可視性は重要である。可視性があれば、教師は更なるデモンストレーションをシステムの現在の知識に合わせて与えることができる。この目的のために、可視化システムを提案する。開発し

たシステムでは、デモンストレーション中常時、またはオフラインで、ここまで得られた動作プリミティブのアニメーション、およびデータベースの現在の木構造図と動作プリミティブグラフの現状を、教師自身が視認できる。獲得プロセスの進行中に教師が与え続ける動作が、システムが獲得した既知の動作だと認識すると、画面の木構造図が直ちに更新される。

この可視化システムは、モーションキャプチャシステムから直接マーカータータを受け取り、アニメーションキャラクターの運動学モデルに基づいて、オンライン逆運動学⁽⁷⁾により関節角度データに変換される。使用するアニメーションキャラクターの体形と自由度数は目的によって選択できる。与える動作は人間動作の分析のために利用する場合、タスクの必要条件に応じて設定するが、人型ロボットの動作生成のために学習する場合は、ロボットの運動学構造に応じて設定する。教師の現在の動作は、アニメーションキャラクターにリアルタイムで反映される。この機能は、教師にとって、逆運動学が適切に動作し、動作が正しくヒューマノイドロボットの関節角度に変換されているかを確かめるのに役に立つ。

関節角度データは、第2節で記述された文節化、クラスタリング、動作プリミティブのグラフの学習アルゴリズムモジュールに渡される。新しい動作プリミティブが抽象化される度に、知識データベースの現在の状態を表す木構造にノードが追加され、画面に表示される。これにより、教師はデモを完了するか、学ばせる次のタスクに移るべきかを判断できる。またシステムは、学習されたそれぞれのプリミティブを必要に応じて再生する機能を持つ。これにより、教師は動作が正しく学ばれたかどうか、あるいは、更なるデモンストレーションが必要かどうか決定できる。

二つの既知の動作のシーケンスが観察されるたびに、動作プリミティブのグラフが更新される。同時に、動作プリミティブのグラフは、可視化システムによって更新され表示される。

現在のデモンストレーションの前に学習した動作プリミティブが認識されると、可視化システムは、実行された動作がシステムに機知であると教師に通知する。これは、動作プリミティブのグラフの上で認められた動作プリミティブの色の变化で示される。このように、教師は個々の動作プリミティブと動作プリミティブのシーケンスがシステムによって正しく認められているかどうか追跡することができる。

4. 実験

合同の文節化、クラスタリングと動作プリミティブのグラフ抽出化アルゴリズムを、オンラインデモンストレーションにより、可視化システムとモーションキャプチャシステムを使用しテストした。複合システムをテストするために、モーションキャプチャスタジオにおいて様々な全体動作シーケンスをキャプチャした。教師は34個の反射マーカを装着している。サンプルレートは10msで、各々のマーカ[x,y,z]位置は、オンラインでモーションキャプチャシステムによって検出する。マーカ位置と実験セットアップを図3、4に示す。教師は、片手と両手の上げ下げ、前屈、しゃがみ動作を実行した。教師は、各々の動作タイプを6回程度繰り返した。



Figure 3 - Experimental Setup.




Fig. 4 - Marker setup and positioning during the motion capture experiments.

可視化システムはキャプチャーシステムから受け取ったマーカ位置データを、オンライン逆運動学によりアニメーションキャラクターに反映し、その動作を文節化およびクラスタリングと動作プリミティブの抽出化を行うモジュールに渡す。分節化とクラスタリングに用いられたデータベクトルは関節角度である。図5に実行中のシステムスクリーンショットを示す。

動作プリミティブが抽象化されると、動作プリミティブのグラフ画面に現れる (図 6) . さらに多くの動作が抽象化されると、それらの関係も同時に学習され、動作プリミティブのグラフが漸次的に変化する (図 7) . 動作が学習された後、それと同様の動作を認識すると、動作プリミティブのグラフの上でハイライトされる (図 8) .




Fig.5 - Screen shot of the visualization system during on-line motion playback.




Figure 6 - Screen shot of the visualization system when the first motion primitive is abstracted and placed in the motion primitive graph (shown on the left hand side window).




Figure 7 - Screen shot of the visualization system when a transition between motion primitives is acquired and displayed on the motion primitive graph (shown on the left hand size window).

デモンストレーションの終了後、ユーザーは学習した動作プリミティブを再生し、学習結果を確認することができる (図9) .

デモンストレーション (約 2.5 分) の後、システムは示された 10 の動作のうちの 8 つを学習した (図 10) .

5. 結 語

本論文は、人間の教師の観察から得られる全身動作プリミティブを通じて生成された動作プリミティブ、および、その構造化により、オンラインで連続的に動作を学習するアプローチを提示した。また、教示中、教師を支援するための可視化システムも提示した。観察された人間の動作は、最初にオンライン逆運動学⁽¹⁷⁾を通してロボット関節角度データに変換される。関節角度データは、確率論的な文節化を使って、潜在的な動作プリミティブに自律的に分節される^(12,8)。この文節化された動作プリミティブの候補は、漸次的にクラスタリングされ、動作プリミティブを生成できるモデルに抽象化される^(7,9,10)。各々の動作プリミティブが学習されると、それらは動作プリミティブのグラフにも追加される。グラフは、動作プリミティブ群の関係を学習することにより徐々に更新されることも確認した⁽¹¹⁾。




Figure 8 - Screen shot of the visualization system when an existing motion is recognized by the system during the performance of that motion (shown in the left hand size window).

可視化システムにおいては、新しい動作の学習時、既知の動作の認識時、および、動作の新しい関係の生成時これらを画面に表示することで、トレーニングプロセスの効率化の可能性を確認した。また、デモンストレーション終了後、ユーザーがシステムの学習を様々な可視化機能により評価し、将来のデモンストレーションに生かすことができた。




Figure 9 - Motions learned by the system can be uploaded and played back on the visualization system to verify the learning process.

なお、本研究は科学研究費補助金基盤研究 (S) 「全身動作と言語を統一した人間・機械コミュニケーションの成立」(20220001, 代表者: 中村仁彦) の支援を受けた。またモーションキャプチャ作業をサポートしてくれた村井昭彦氏に感謝する。




Figure 10 - Final tree structure of the learned motions primitives. “BAR”= Both Arms Raise, “BAL”= Both Arms Lower, “BOW”= Bow Motion, “SQD”= Squat down, “SQU”= Squat Up, “LAR”= Left Arm Raise, “LAL”= Left Arm Lower, “RAL”= Right Arm Lower. Note that the program does not know the motion name labeling, these are assigned manually following inspection of the clustered motions.

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) G. W. Taylor, G. E. Hinton, and S. Roweis, “Modeling human motion using binary latent variables,” in *Conference on Neural Information Processing Systems*, 2006, pp. 1345–1352.
- (4) O. C. Jenkins and M. Mataric, “Performance-derived behavior vocabularies: Data-driven acquisition of skills from motion,” *International Journal of Humanoid Robotics*, vol. 1, no. 2, pp. 237–288, 2004.
- (5) O. C. Jenkins and M. Mataric, “A spatio-temporal extension to isomap nonlinear dimension reduction,” in *International Conference on Machine Learning*, 2004, pp. 441–448.
- (6) S. Calinon, F. Guenter, and A. Billard, “On learning, representing and generalizing a task in a humanoid robot,” *IEEE Transactions on Systems, Man and Cybernetics, Part B*, vol. 37, no. 2, pp. 286–298, 2007.
- (7) 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.
- (8) D. Kulić and Y. Nakamura, “Scaffolding on-line segmentation of full body human motion patterns,” in *IEEE/RJS International Conference on Intelligent Robots and Systems*, 2008, pp. 2860–2866.
- (9) D. Kulić, 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.
- (10) D. Kulić, W. Takano, and Y. Nakamura, “Combining automated online segmentation and incremental clustering for whole body motions,” in *IEEE International Conference on Robotics and Automation*, 2008, 2591–2598.
- (11) D. Kulić, D. Lee, Ch. Ott and Y. Nakamura, “Incremental Learning of Full Body Motion Primitives for Humanoid Robots,” in *IEEE International Conference on Humanoid Robots*, 2008.
- (12) 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.
- (13) 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.
- (14) 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.
- (15) L. Kovar, M. Gleicher, and F. Pighin, “Motion graphs,” in *ACM SIGGRAPH*, 2002, pp. 473–482.
- (16) Y. Yamaguchi, K. Yamane, and Y. Nakamura, “A large-scale human motion database and its application to character animation,” in *JSME Conference on Robotics and Mechatronics*, 2008, pp. 1P1–J18, in Japanese.
- (17) K. Yamane and Y. Nakamura, “Natural motion animation through constraining and deconstraining at will,” *IEEE Transactions on Visualization and Computer Graphics*, vol. 9, no. 3, pp. 352–360, 2003.
- (18) S. Nakaoka, A. Nakazawa, K. Yokoi, and K. Ikeuchi, “Leg Motion Primitives for a Humanoid Robot to Imitate Human Dances,” *Journal of Three Dimensional Images*, Vol. 18, no. 1, pp. 73–78.