

逐次記憶化および分類による全身運動知識の自己組織化

Incremental symbol-formation, clustering and self-organization of whole body motion patterns

クリッチ・ダナ (東大) 高野渉 (東大) 中村仁彦 (東大)

Dana KULIĆ, University of Tokyo, dana@ynl.t.u-tokyo.ac.jp
Wataru TAKANO, University of Tokyo
Yoshihiko NAKAMURA, University of Tokyo

This paper describes a novel approach for incremental symbolization and classification of observed human motion. The acquired symbols can be used for both subsequent motion recognition and generation. The resulting representation is a tree structure with the symbol at each node corresponding to its abstraction level.

Key Words: Incremental Learning, Whole Body Motion Patterns, Stochastic Modeling

1. 緒言

人間と類似した身体構造を有したヒューマノイドロボットにとって、人間の行動観察を通じた見まね学習は強力な枠組みであり、これまでに多くの見まね学習モデルが提案されてきた [3, 14]。しかし、これら多くの見まね学習アプローチは設計者によって行動数の指定および学習データの分類作業が必要である。また、学習は一回だけのオフライン処理によって行なわれる。あるいは、すべての動作データがオフラインで取得可能ならば、その動作データに対してクラスタリングを適用することができ、運動プリミティブの最適な数を求め、おのおのの動作データを教師信号として与えることができる。しかし、日常生活において人と共存するロボットは、新たな環境下における未知の運動プリミティブの逐次学習ができなければならない。ロボットは教師である人間と生活を共にし、相互作用する間、提示された行動をオンラインで観察し、分節化し、分類することができなければならない。この学習過程において、運動プリミティブの数は予め決められたものでなく、ロボットは自律的に最適な数の運動プリミティブからなる知識構造を有する必要がある。さらに、観察された動作と学習した運動プリミティブの数が増加するにしたがって、獲得した知識を効率的かつ簡単に検索できる知識体系を築く必要がある。

運動の分類精度と学習データ数にはトレードオフの関係がある。すなわち、分類精度を高めるためには、より多くの学習データが必要である。ロボットが少数の運動観察を通じて適切な運動プリミティブを抽出できる、その運動プリミティブを用いて運動の認識・生成が可能となる。さらに、この運動生成により、学習した運動は他の学習形態 (例えば練習 [1] と教師からのフィードバック [11]) を通してさらに洗練することができる。こうした学習手順は数多くの観察に基づく模倣のみの見まね学習より効率的である。したがって、数少ない運動データから正確にクラスタリングする情報処理は必要である。クラスタリング精度は、分類すべきデータの類似度や用いるモデルに依存する。大きく異なる動作の分類は、単純なモデルを用いても可能である。一方、類似の運動を分類するためには、表現力の高いモデルが要求される。しかし、このような高い表現力を有するモデルは、より多くの記憶容量および学習時間を必要とする。したがって、分類すべき動作の類似度に応じたモデルが選択されるのが好ましい。オンライン観察の間、運動プリミティブを抽出するためには、自動的な運動の分節化、既学習運動の認識、自動的なクラスタリング、未知の動作の学習、および簡単な検索が可能な記憶装置への学習したデータの組織化の問題がある。本論文に

おいて、観察された運動プリミティブの逐次記憶・分類を通じて自己組織的な全身運動の知識構造化を提案する。

BreazealとScasellati [3] とSchaalら[14]は模倣による運動学習を総括している。BreazealとScasellatiによって論じられている見まね学習の多くにおいて、学習動作が人間の手によって予め分節化されており、学習はオフラインで実行されている。たとえば、Billardら [2] は 運動認識および生成可能な見まね学習モデルとして、隠れマルコフモデル (HMM) を適用している。ベイズ情報量基準 (Bayes Information Criterion BIC) はHMMの状態の最適数を選ぶのに用いられている。しかし、学習前に学習する運動データ全てを予め用意し、運動データの分類される数を設計者が決める必要がある。

尾形ら [12] は、長期 (漸次的学習) に適したニューラルネットワークを構築した。この研究において、ニューラルネットワークはパートナーである人間と協調作業における、ナビゲーション作業を学ぶのに用いられる。しかし、彼らのシステムでは、ロボットは 1 つのタスクだけを学び、知識の階層的な組織化は起こらない。

門根ら [6, 7] は、非単調シグモイド関数を用いた連想記憶ニューラルネットワークに基づく人間の動作の自律的な分節化、抽象化および連続的な抽象度での認識が可能なシステムを提案している。しかし抽象化した運動表象は観察された運動の認識にのみ使うことができ、運動を生成することはできない。

高野ら [15] は、HMMに基づいた人間の動作の自動的な分節化、認識および生成ができるシステムを開発している。このアプローチで、自動的に分節化されたデータに基づいて、一組のHMMが逐次学習される競合学習法を適用している。各々の新しい運動パターンは、その運動パターンに最も類似したHMMの教師信号として用いられる。しかし、抽象度の異なるレベル間における、階層化メカニズムは提案されない。

学習モデルのもう一つの重要な問題は、モデルサイズを選択である。BIC [2] または赤池情報量基準[8]の使用は提案されているが、両基準は学習データとの適合度とモデルのパラメータ数のトレードオフに基づいたものであり、最適なモデルサイズの検索に膨大な時間が要する。運動認識に関して、必要なモデルサイズは現在の観察のモデル性能のみならず知識データベースその構造上にも依存する。多くの類似した運動がデータベース中にある場合、運動を簡単に識別するには、よりの確なモデルが必要である。一方、運動が大きく異なる場合は、非常に単純なモデルにより簡単に区別することができる。

そこで、本論文では可変構造隠れマルコフモデルを用いることにより、全身運動の逐次分類および記号化を通じた知

識構造化の枠組みを提案する。運動パターンを観察するにつれて、その運動パターンを抽象化する。個々の運動パターンは距離測度を用いて逐次クラスタリングされる。形成されたクラスタは、運動生成に使われるグループモデルを構築する。モデルサイズは各モデルが必要とする分離度に基づき、自動的にオンラインで調整される。

2. 漸次的な行動学習

本稿では、ロボットが学習した運動を表現するために、運動パターンの階層木構造を逐次的に構築する行動学習の枠組みを提案する。各木構造ノードは、類似的な運動の認識および生成ができる運動プリミティブを表現している。各運動空間の局所で運動プリミティブを分別するために標準クラスタリングが使われる。観察した時系列データを抽象化するためにHMMが使われる。モデルのパラメータはデータの特徴集合を作成する。モデルの特徴はクラスタリングのために使用し、観察した運動の間の距離を定義する。モデルの正確度は、予め決められたサイズのモデルを使うのではなく、各運動空間の領域に基づいて調整される。初期的には各運動例と運動グループは簡単な状態数の少ないHMMによって記号化される。要求されるモデルの複雑性が増えると、力学的なチェーンが追加されたFactorial Hidden Markov Model (FHMM)[4]を採用する(図1)。FHMMsはさらに正確な運動表現ができ、過学習することなく多くの類似する運動間を識別することができる[4, 9]。また、同じ運動に対応するFHMMとHMMは十分に類似していることを示した。したがって、高い識別分解能が必要な運動モデルの密集した領域にのみ、FHMMモデルを用いることとする。図2はHMMとFHMMを併用したモデルの概略図である。




Figure 1: The evolution of a Hidden Markov Model. In a regular HMM (solid lines), at each time step, the hidden state variable is in state p_n , governed by the state transition model, and outputs observation y_n , governed by the output distribution model. In a Factorial HMM (dashed lines added), multiple hidden state variables p_t and q_t evolve, each according to its own state transition model. At each time step, the observation vectors from all states are summed to form the observation y_t .

上述の提案したモデルの構築手順を説明する。まず最初に1つの行動グループ(根ノード)から始まる。教師によって提示された運動はHMMによって記号化され、木検索アルゴリズムにより既存の行動グループと比較し、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、グループの中でローカルクラスタリングが行われている。十分に類似するデータのあるクラスタが見つめられると、幼児グループは、このデータ群で形成される。したがって、ロボットは生涯にわたり観察を通じて、漸次的に運動プリミティブの空間を学習・自己組織化する。この手順に関する疑似コードは図4に示し、記憶構造構築の概略図を図3に示す。

この情報処理の枠組みによって、ロボットは被験者を連続観察する間、行動を漸次的に学び、分類する。学習した行動の階層構造の生成により観察された運動を簡単に検索でき、類

似性および階層関係に基づいて、行動間の関係を自動的に生成することができる。そのうえ、ロボットの知識は観察した運動データに基づき組織化され、ロボットの知識は多くの運動データが観察された行動空間の領域において詳細化されるであろう。




Figure 2: Schematic Comparing an HMM model space and a hybrid HMM-FHMM model space

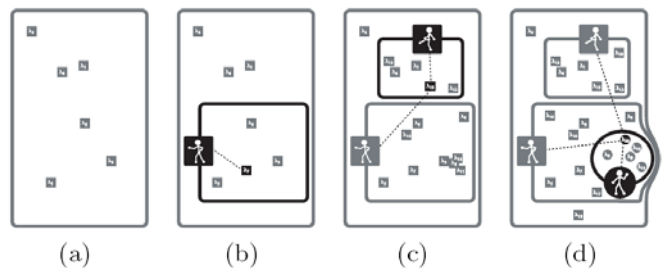


Figure 3: Schematic Illustration of the Segmenting Algorithm. (a) initial state, when only one group is present; (b) a child group forms when enough similar examples are observed; (c) new observations are located into the closest group based on the distance between the new observation and the group model; (d) a higher order model is used in dense areas of the motion space.

- 1: **procedure** INCREMENTALCLUSTER
- 2: **Step1** Encode observation sequence O_i into an HMM λ_i
- 3: **Step2** Search the behavior tree for the closest group λ_{G_j} to the current observation model λ_i , based on the inter-model distance
- 4: **Step3** Place λ_i into the closest group G_c
- 5: **Step4** Perform clustering on all the exemplar motions within G_c
- 6: **Step5** If a sufficiently similar subgroup of motions is found, form a new group G_n , as a child of G_c , containing the observation sequences of the subgroup
- 7: **Step6** Using the observations sequences of the new subgroup, form the group model λ_{G_n}
- 8: **end procedure**

Figure 4: Segmenting Algorithm Pseudocode.

2.1 観察シーケンスの記号化

各々の新しい観察シーケンスは、HMMに記号化される。モデルを学習するために、HMMの構造(例えば状態数、ガウシアン数)決めなければならない。これまでの研究では、最も合致したモデル[8]を選ぶために、Akaike Information Criterion (AIC)を用いられていた。しかし、このアプローチは時間が掛かる問題がある。候補となる各々のモデルのパラメータを最適化することによって、最も合致するモデルをモデル空間上から探索する必要がある。さらに、多くの類似運

動が識別される必要があるとき、AICの使用はより良いモデルの必要性の有無を考慮していない。本論文においては、可変サイズのモデルを提案する。観察された運動時系列データに類似した既知運動データの数に基づいてFHMMのチェーンが追加される。すなわち、類似した運動データが多く存在し、それらの運動を分類する分解能を上げるために力学的なチェーンを追加する。このアプローチで、各々の運動は、まず最初に単純な単鎖、Left-to-Right HMMによって表現される。より良いモデルが必要なら、さらなるチェーンが以下に記すように追加する。

2.2モデル間距離計算

新しく観察された行動がHMMとして記号化されると、既存のグループ（もしあるなら）と比較することができる。ここでは、2つのモデル間の距離は、式(1)によって計算することができる [13]。

$$D(\lambda_1, \lambda_2) = \frac{1}{T} [\log P(O^{(2)} | \lambda_1) - \log P(O^{(2)} | \lambda_2)] \quad (1)$$

$\lambda_1; \lambda_2$ は2つのモデル(F)HMMを表し、 $O(\lambda_2)$ は λ_2 によって生成される運動時系列、 T は運動時系列の長さである。この距離測度は対称形でないため、2つの距離の平均を距離測度として用いる。この測度は2つのモデル間のKullback-Leibler距離を表す。距離は尤度に基づいているため、修正されたForwardアルゴリズム [4] を用いた対数尤度を計算によりFHMMとHMMに適用可能である。そして、この距離でFHMMとHMMを比較できる。

既知の運動に関する知識は木構造で組織されているので、新しい観察された運動時系列はすべての既知の行動と比較される必要はない。比較手順は、木検索として実装される。木の各々のノードで、新しい運動時系列はそのノードの子ノードと比較される。新しい運動時系列と子ノードのうちの1つの間の距離が十分に小さければ（閾値以下）、最も類似した子ノードに対して同様の検索を繰り返す。十分類似した子ノードが存在しない場合、新しい観察シーケンスは現在のノードに加えらる。閾値を式(2)に示す。

$$D_{thresh} = K_{maxGD} D_{max}^G \quad (2)$$

D_{thresh} は新しい運動時系列がノードに含まれるかどうかを示す閾値、 D_{max}^G は各ノードに含まれる観察モデル間の最大距離、 K_{maxGD} は予め決められたゲイン定数である。新しい運動時系列とノードの間の距離が D_{thresh} より大きいならば、このノードは新しい運動時系列に合致するとは考えられない。複数の候補ノードがある場合は、新しい運動時系列に最も近いノードを選択する。候補が存在しない場合、新しい運動時系列は現在のノードに追加される。いかなる既存の運動パターンとも完全に異なる新しい運動時系列が観察された場合、その運動時系列は根ノードに追加される。

D_{max}^G は、運動時系列を記号化するために必要なモデルの複雑度合を決定する指標としても使用される。新しい運動と最も類似したノードにおいてそのノードでの D_{max}^G が閾値以下の場合、モデルの識別・表現能力を改善するために、モデルにチェーン構造を追加する。

2.3クラスタリングと新しいグループの形成

新しい運動時系列があるノードに加えらるるとき、子ノードが形成されるかどうか決定するために、クラスタリングを適用する。運動時系列が加えられたノードの下位に階層的な木構造を生成するために Complete Link Hierarchical

Clustering [5] が使用される。クラスタ（子ノード）は、2つの基準に基づいて作られる。すなわち、クラスタに含まれる運動データ数とそのクラスタ内の最大距離である。最大距離が最大距離基準 D_{cutoff} 以下であり、クラスタに含まれる運動データ数が予め設定された数以上である場合、そのクラスタは子ノードとなる。最大距離基準を計算するためにノードの運動距離の平均と標準偏差を計算する：

$$D_{cutoff} = K_{cutoff} \mu \quad (3)$$

μ はノードに含まれる全運動パターン間の平均距離である。

2.4新しい行動の例示

新しい子ノードがステップ 5 で生成されれば、その子ノードを表現するモデルはその子ノードに含まれるすべての運動時系列を使って求められる。新しく生成された子ノードに相当するモデルの構造は、それに含まれる運動時系列から計算できる最大観察距離 (D_{max}^G) に基づいて決定される。構築されたモデルは、ロボットの運動生成に用いることができる。新しいクラスタに割り当てられる要素のうちの1つがすでに複数の運動時系列を記号化したモデルであれば、そのモデルに基づいて生成した運動時系列が学習データとして使われる。この場合、通常モデルパラメータの推定式に変更を加えたもの [13] を用いる。変更を加えた推定式は、クラスタ要素に相当するモデルが複数の運動時系列を保存することに基づいて修正される。すなわち要素モデルに重み付けすることによって修正する。したがって、個々の運動時系列と比較して、重みに応じた影響が子ノードのモデルは受けることとなる。

2.5運動の生成

ノードの階層構造が形成されると、各ノードが運動パターンの記号を表す。ノードに相当する(F)HMMからロボットの運動軌道を生成するために、決定論的な運動生成方法が使われる [9]。この方法では、各状態の滞在時間が状態遷移確率から推定され、状態遷移系列が求められる。各状態から出力される運動ベクトルは、各状態の確率密度関数から計算できる。このようにして求められた参照軌道は、ローパスフィルターで処理され、安定化コントローラへ入力される。

3. 実験

モーションキャプチャシステム [10, 6] によって計測された一連の9つの異なる人間の運動の観察シーケンスからなるデータセットを用いて提案したモデルの有効性に関して検証した。モーションキャプチャシステム [10] にて体に付けられたマーカの位置を計測し、リアルタイムに逆運動学を通じてマーカ位置情報から関節角情報を取得する。本稿では、20自由度ヒューマノイドロボットモデルを逆運動学計算に用いた。データセットは、歩く (WA - 28 の観察)、万歳 (CH - 15 の観察)、ダンス (DA - 7つの観察)、キック (KI - 19 の観察)、パンチ (PU - 14 の観察)、しこ (SL - 13 の観察)、しゃがむ (SQ - 13 の観察)、投げる (TH - 13 の観察)、前屈 (BO - 15 観察) の運動に関する関節角時系列から構成される。

運動シーケンスは、ランダムな順番で提示される。提示された運動に対して、漸次的なクラスタリングを実行する。結果として生じる葉ノードがオフラインの方法で得られたグループを表すように、アルゴリズムは正しく行動を分類する。実行された100のシミュレーションでは、誤った分類のケースが葉ノードにはなかった。これは、最終的な分節化が運動データを提示する順番には関係ないことを示している。HMMモデルだけを使った場合とHMMとFHMMを併用した場合の

クラスタリングの性能比較を図 5 に示す。可変なモデルは類似な運動THとPUを区別することができる。一方、通常のHMMだけが使われると、それらの動作は同じ数の例を与えられた場合、識別されることができない。ただし、階層構造は運動の提示される順番によって異なる。

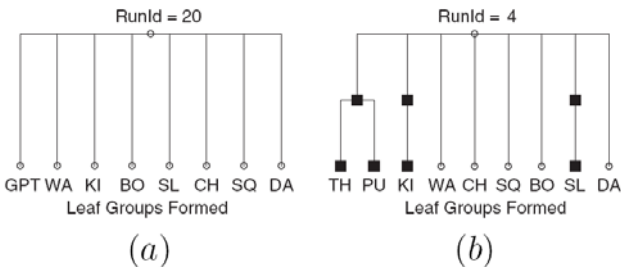


Figure 5 : Sample Segmentation Results: (a) using only single-chain model, most motions are segmented correctly, but punch and throw cannot be distinguished and are grouped together in group GPT; (b) using adaptable models, all motions can be correctly distinguished (black squares indicate branches where higher accuracy models have been applied by the algorithm)




Figure 6 : Comparison of Generation Results of the HMM and FHMM (two chains for the Knee Joints during a Walking Motion, prior to applying any post processing).

図 6 は、歩くノードの FHMM および HMM によって生成される運動の比較を表す。図 6 で分かるように、運動を表現するために利用できる状態の数が多いため、FHMM は HMM モデルと比較してより良い空間的な正確さを有している。PU と TH 動作を抽象化する中位のノードの例は、図 7 に示される。抽象化した運動は、2 つの動作を平均化したものである。

4. 結論

本論文は、全身運動プリミティブのオンラインで長期漸次的学習と階層的組織化に関する新しいアプローチを展開した。運動プリミティブは Factorial Hidden Markov Models を使って抽象化され、より詳細なモデルを観察された運動パターンが密集した領域でのみ使うように、モデル構造は動作の類似性に基づいて構成される。学習した動作は観察された動作の集合であり、オンライン漸次的な観察において、自律的にクラスタリングした。観察された新しい運動と運動パターンの記号モデルとの距離に基づいて、観察された運動は最も近い運動パターンの記号モデルに追加される。新規の運動データが追加された運動パターン記号モデルは、子ノード（すなわち新しい、より特定の運動プリミティブ）を抽出するためにクラスタリングを通じて分析される。クラスタリングした動作はそれによって階層的な木構造に漸次的に組織され、根により近いノードは広い運動記述を表現し、葉ノードはより特定の運動パターンを表現する。木構造と識別分解能は、ロボットの動作観察の履歴に基づく。結果として生じる知識構造は

認識のため簡単に検索することができ、ロボットが学習した動作を生成するために利用されることもできる。




Figure 7 : Generated Hybrid Punch/Throw Motion.

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、」代表者：中村仁彦の支援を受けた。

文 献

- [1] D. C. Bentivegna, C. G. Atkeson, and G. Cheng. Learning similar tasks from observation and practice. In *International Conference on Intelligent Robots and Systems*, pages 2677-2683, 2006.
- [2] A. Billard, S. Calinon, and F. Guenter. Discriminative and adaptive imitation in uni-manual and bi-manual tasks. *Robotics and Autonomous Systems*, 54:370-384, 2006.
- [3] C. Breazeal and B. Scassellati. Robots that imitate humans. *Trends in Cognitive Sciences*, 6(11):481-487, 2002.
- [4] Z. Ghahramani and M. I. Jordan. Factorial hidden markov models. *Machine Learning*, 29:245-273, 1997.
- [5] A. K. Jain, M. N. Murty, and P. J. Flynn. Data clustering: A review. *ACM Computing Surveys*, 31(3):264-323, 1999.
- [6] H. Kadone and Y. Nakamura. Symbolic memory for humanoid robots using hierarchical bifurcations of attractors in nonmonotonic neural networks. In *International Conference on Intelligent Robots and Systems*, pages 2900-2905, 2005.
- [7] H. Kadone and Y. Nakamura. Segmentation, memorization, recognition and abstraction of humanoid motions based on correlations and associative memory. In *IEEE-RAS International Conference on Humanoid Robots*, pages 1-6, 2006.
- [8] 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.
- [9] 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.
- [10] K. Kurihara, S. Hoshino, K. Yamane, and Y. Nakamura. Optical motion capture system with pan-tilt camera tracking and realtime data processing. In *IEEE International Conference on Robotics and Automation*, volume 2, pages 1241-1248, 2002.
- [11] M. N. Nicolescu and M. J. Mataric. Task learning through imitation and human-robot interaction. In K. Dautenhahn and C. Nehaniv, editors, *Imitation and social learning in robots, humans and animals: behavioral, social and communicative dimensions*. Cambridge University Press, 2005.
- [12] T. Ogata, S. Sugano, and J. Tani. Open-end human-robot interaction from the dynamical systems perspective: mutual adaptation and incremental learning. *Advanced Robotics*, 19:651-670, 2005.
- [13] L. R. Rabiner. A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2):257-286, 1989.
- [14] 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*, 358:537 - 547, 2003.
- [15] W. Takano and Y. Nakamura. Humanoid robot's autonomous acquisition of proto-symbols through motion segmentation. In *IEEE International Conference on Humanoid Robots*, pages 425-431, 2006.