

教示者と学習者の身体差を吸収するミラーニューロンモデル

○稲邑 哲也 (JST/東大) 中村 仁彦 (東大)

Mirror Neurons Models which absorb Difference of Body Conditions between Teacher and Learner

*Tetsunari INAMURA (JST/Univ. of Tokyo), Yoshihiko NAKAMURA (Univ. of Tokyo)

Abstract— An organ in brain named as Mirror Neurons fire when a human watches a motion as well as when he/she acts the motion. This fact shows that the motion recognition and generation are executed by bi-directional computation model, and the model leads to symbol communication. We think that the Mirror Neurons is an important paradigm to the realization of high level intelligence for humanoid because the organ could be regarded as symbol grounding models. In this paper, we propose a new method for acquiring motion elements with absorption of difference of body conditions, in a situation where a learner tries to imitate a teacher’s performance whose body differs from the learner.

Key Words: Imitation Learning, Mirror Neurons, Hidden Markov Models

1. はじめに

見まねがコミュニケーションを通したシンボル生成の源であり、ヒトや類人猿の高度な知能はものまねから形成された、というミメシス理論が発達心理学で注目されている¹⁾。一方、脳神経科学の分野で注目を浴びているミラーニューロンは言語野に位置する部位で、同一行動の生成と認識の双方に使われている²⁾。これらの事実は行動の認識と生成、すなわち見まね学習の機能が脳のハードウェアに埋め込まれており、シンボル操作などの高次知能の基礎となっていることを示唆する。著者らは、これらのパラダイムにヒントを得て、シンボルを獲得、操作して、全身で行動するヒューマノイドの知能の構成論の研究を進めている。

このような工学モデルは、行動の認識と生成を同時に学習し、シンボル表現の創発を同時に行なう必要がある。我々はこれを実現するために、隠れマルコフモデル (Hidden Markov Models, 以下 HMM) を用いた学習モデルを提案してきた³⁾⁴⁾。しかしながら従来のモデルは、行動を表現する基本単位である行動要素の設計手法に問題があり、観察した行動に適応できなかったり、自分自信の身体性と整合性の合わない行動が生成されたりする、などの問題があった。本論文では連続型隠れマルコフモデル (CHMM) と離散型隠れマルコフモデル (DHMM) を組み合わせることで、行動の認識と生成の繰り返しながら行動の要素表現を発達させる枠組を提案する。

2. 運動とシンボルの双方向計算モデル

2.1 システムの概要

本研究で提案する行動認識・獲得システムの概要を Fig.1 に示す。本研究ではミメシスによって獲得されるシンボルの元となる概念を「原始シンボル」(Proto-symbol)と呼ぶ。離散的情報である原始シンボルと、時間的に連続なパターンである行動データを結びつけて表現するために、行動要素 (Motion Elements) を導入した。行動要素とはヒューマノイドロボットの各関節




Fig.1 An Outline of Mimesis System

の角度や角速度などのパラメータで構成された状態ベクトルで、このパラメータ空間を「要素表現」と呼ぶ。観察された他者の行動、および生成する自己の行動は行動要素の時系列データとして表現され、原始シンボルはこの時系列データを抽象化することによって得られる。

システムはまず、人間やヒューマノイドの行動を観察し (Step 1)、観察した行動を行動要素に分解し (Step 2)、その要素列をシンボルに変換することで認識と記憶を行う (Step 3)。またその逆方向のプロセス (Step 4




Fig.2 Motion Sequence and Hidden Markov Models

～6) で行動を生成する。しかし、生成した行動は他者行動の観察に基づくものであり、自己の身体性とは関係ない。そこで生成した行動を自己の身体性の観点から評価し、行動要素や原始シンボルを他者行動の認識と自己行動の生成にともに有用となるように更新する (Step 7)。

2.2 HMM による双方向計算モデル

行動の認識と生成の双方向の計算モデルを表現するために、隠れマルコフモデル (HMM: Hidden Markov Models) を用いている。HMM は状態の有限集合 $Q = \{q_1, \dots, q_N\}$ 、出力記号の有限集合 $S = \{o_1, \dots, o_M\}$ 、状態遷移確率分布 $A = \{a_{ij}\}$ 、記号出力確率分布 $B = \{b_{ij}\}$ 、初期状態確率分布 $\pi = \{\pi_i\}$ 。以上の 5 項組 $M = (Q, S, A, B, \pi)$ で表される。Fig.2 のように、HMM は確率的に状態遷移を繰り返しながら、記号を出力する。 a_{ij} は状態 i から j への遷移確率を示し、 b_{ij} は状態 i から出力記号 j を出力する確率である。通常は状態ノードの集合 Q と出力記号の集合 S は固定するので、HMM の特性は 3 つのパラメータ (A, B, π) で表される。

HMM を使用する際には、観測記号列

$$O = \{o_1, o_1, \dots, o_T\} \quad (1)$$

を出力記号列とみなし、記号列 O が HMM から出力される尤度

$$P(O|A, B, \pi) \quad (2)$$

を計算する。この計算は Viterbi アルゴリズムと呼ばれる手法で実現可能で、最も大きい尤度を持つ HMM がこの観測記号列の認識結果として用いられる。また、HMM の性質を決定するパラメータ (A, B, π) は EM アルゴリズムの一種である Baum-Welch アルゴリズム⁵⁾ で求められる。

ヒューマノイドの全身行動と記号列 O との相互関係は、「行動要素」と呼ばれる微小時間内での関節角度と角速度、および各要素が担当する範囲の大きさで表現される。すなわち、行動要素は、位相空間上の点 μ とその点を中心とする担当範囲を示す共分散行列 Σ で定義される。これはガウシアン分布と同等の性質を持つので、次式によって行動要素を表現する。

$$u_i \stackrel{\text{def}}{=} \mathcal{N}(\mu_i, \Sigma_i) \quad (3)$$

$$\mu_i = \begin{pmatrix} \theta \\ \dot{\theta} \end{pmatrix} \quad (4)$$

ここで、

$$o_i \stackrel{\text{def}}{=} u_i \quad (5)$$

の定義を導入する事で、HMM による全身行動の表現を行なう。全身行動から記号 o への変換の際には、まず、微小時間で全身行動をサンプリングし、その値 x に対して

$$\arg \max_i \frac{1}{\sqrt{(2\pi)^n |\Sigma_i|}} \exp \left\{ -\frac{1}{2} (x - \mu_i)' \Sigma_i^{-1} (x - \mu_i) \right\} \quad (6)$$

の計算を行ない、担当する i 番目の行動要素 u_i を対応付ける。以上の定義によって、HMM は全身行動を抽象化することになるので、これを原始シンボル P_S と呼び、次式で定式化する。

$$P_S \stackrel{\text{def}}{=} (A, B, \pi) \quad (7)$$

2.3 HMM による他者行動の認識

状態ノードの個数については経験則から固定的に 7 個とした。状態遷移図の構造として、通常の音声認識などの時系列パターンマッチングの例では Left-to-Right モデルが主流であるが、人間の行動パターンは周期的である事が多いため、全ノードが互いに結合する Ergodic HMM を採用した。

実際にはミメシスは複数の原始シンボルを保有しており、入力された行動パターンが、どの原始シンボルと対応しているのか、判定を行なう。入力された行動パターンに対応する原始シンボルは高い尤度を示し、入力パターンと関係のない原始シンボルは低い尤度を示すはずである。そこで認識判定指数

$$R = \frac{\max(P(P_S i))}{\text{second}(P(P_S i))} \quad (8)$$

を導入する。ただし、 $\text{second}(x)$ は、集合 x のうち、2 番目に大きい値を意味するものとする。この比の値が大きければ、他の原始シンボルと混乱することなく、他者の行動を認識したとみなす。認識判定指数 R の値が低ければ、認識は失敗、すなわち新しく観測する行動と見なして、原始シンボルの生成フェーズに移る。

2.4 HMM による全身行動の生成

まず Step 4 で、原始シンボルから行動要素の列を出力する。HMM はパターン認識の分野で広く用いられている手法であるが、HMM から行動パターンを生成する手法を導入し、行動の認識と生成の双方向の計算モデルを実現した³⁾。

尤度 $P(O|P_S)$ の計算を行なう事で、ある行動要素列に対応する HMM を選択し認識する事は可能であるが、HMM から最も良く出力される行動要素列を求める事は難しい。これは、行動列 O が取り得る空間全体に対して探索を行い、もっとも大きい尤度を持つ行動列を見つけ出すことと同等であるが、行動列の取り得る組合せは膨大なものになり、最尤法を適用する事もできない。そこで遺伝的アルゴリズム (GA) を用いた探索法を導入する³⁾。

HMM から出力される行動要素列の長さはあらかじめ一定の長さ l を取ると仮定し、一つの遺伝子を一つ



Fig.3 Motion Capturing System: step motion for learning data



Fig.4 A generation result of step motion on a humanoid robot




Fig.5 Transposition of gene




Fig.6 Continuous Hidden Markov Models

の行動要素と対応させ、 l 個の遺伝子で O を表現する。個体に対する適合度として、尤度 $P(O|A, B, \pi)$ を用いる。突然変異の戦略としては、一つの遺伝子を変化させるのではなく、転置を用いる事によって探索の効果を上げている。転置とは Fig.5 のように個体をブロック状に分割し、位置を入れ換える操作である。一つの遺伝子を変化させる場合に比べて、隣あう遺伝子の時系列方向のつながりになるべく変化させない効果がある。ある場所の一つ遺伝子が変わると、一連の動作の流れが大きく変わることになるが、転置であれば、動作の流れはあまり変わることはない。このため、収束する時間が通常より早くなる効果を得ている。

最終的に、行動要素の時系列パターンを実際の関節角度のパターンに変換し、関節角度のリミットや、トルク限界の特性、力学的整合性などをチェックし、ヒューマノイドの身体で実現可能な行動が出力される。

この手法に基づいて生成したロボットの動作パターンを Fig. 4 に、その元となった人間の参照行動を Fig. 3 に示す。

3. 行動の生成・認識のループによる行動要素の学習

先に説明した行動要素は、要素表現の平均値と共分散行列が与えられていたが、これらは観測した行動データから生成し、自己(ヒューマノイド)の身体性に適合させる必要がある。そのために、混合連続分布型 HMM によるパラメータ学習と、行動認識/生成のループによ

る学習構造を導入する。

混合連続分布型 HMM (Continuous HMM, 以下 CHMM) は Fig.6 に示すように、連続値のベクトルを出力する HMM で、離散型 HMM (Discrete HMM, 以下 DHMM) と比べてデータの表現能力が高い。また、EM アルゴリズムによってパラメータ学習を行なう際、出力される連続値のベクトルの平均値と共分散行列、すなわち行動要素を学習データに対して最適化させることができる。CHMM をそのまま行動の認識/生成モデルに使用すると、行動生成の際の計算量が膨大となるため、CHMM は行動要素を決定するためだけに使用し、行動の認識と生成は DHMM で行なうような、ハイブリッド型 HMM を提案した⁶⁾。

行動要素と原始シンボルの獲得には、対象となる行動のデータベースが必要であるが、初期のデータベースの状態は教示者の行動のみが含まれていることになる。この状態で行動要素や原始シンボルを決定すると、学習者の身体特性とは異なる性質が抽出されるため適切ではない。そこで、次のように、行動の認識と生成を繰り返し、データベースを操作する。

1. 原始シンボルから行動を生成
2. 生成した行動が適切なものかどうかを判定
3. 適切ならば、学習用データベースに生成した行動




Fig.7 Acquired motion elements without loop structure




Fig.8 Acquired embodied self-motion elements

を追加

4. 行動要素のパラメータを再学習し、1に戻る

これによって、データベース内に教示者と学習者の双方の行動が共存する事になり、次第に学習者に適切な行動要素が獲得されて行く。

2) の評価の基準として、生成した行動を自ら再認識した場合の認識率 R 及び、生成した行動と観察した行動の関節角度の誤差の時間積分によって行った。

3) のデータベースへの追加の部分においては、自ら生成した行動（学習者の行動）と他人の身体で実現された行動（教示者の行動）とは差別化されるべきである。ここで、学習者身体で実現した行動は鮮明なデータとして蓄積され、教示者の行動はおぼろげにしかデータとして蓄積されない。というデータベースの操作を行なう。これによって、教示者からの学習は鮮明な情報が少ないため難しく、かつ学習者自身のデータが学習に大きい影響を及ぼす、という効果を狙う。

その結果ヒューノイドの身体性に適した行動がデータベース中に増加し、行動要素や原始シンボルを抽出すより正確に求めることが可能となる。実際には、「鮮明な」データを構築するために、データベースには行動

の時系列データとその分散値のペアが蓄積される。教示者の分散は大きく、学習者の分散を小さく設定し、学習時にはデータベース内のサンプル数を分散値によって操作している。

4. 行動要素の発達実験

前節までで述べたシステムで実際の人間の行動を観察し、行動要素を獲得させる実験を行った。ここで、行動要素として全身の自由度の角速度成分を、股関節のピッチ成分、膝関節、足首関節のピッチ成分、の3自由度で表したものをを用いた。リアルタイムに行動を計測できるモーションキャプチャシステム⁷⁾を用いて、スクワット動作を観察して行動要素を決定し、その後、自己の身体で実行した行動を用いて、行動要素を再決定した。教示者の行動データのみで決定した行動要素をFig. 7に、学習者の身体を介した行動データも含めたデータベースから求めた行動要素をFig.8に示す。実線で示された曲線が観察した行動を行動要素と同じ位相空間で表現した軌跡で、各点が行動要素を示している。観察した行動の軌跡に近い場所に行動要素が集まってくる、観察した行動に適応した行動要素が獲得されていることがわかる。また、教示者の行動データのみを用いた場合に比べ、学習者の行動データを考慮した場合、学習者の身体特性に適合した行動要素が獲得されていることが分かる。

5. 結論

ヒューノイドロボットのための行動認識・獲得システム：ミメシスループにおいて、DHMMとCHMMの利点をハイブリッド的に用いることを提案し、行動要素の発達と、身体性に適した行動生成を実現した。

本研究は科学技術振興事業団の戦略的基礎研究推進事業「自律的行動単位の力学的結合による脳型情報処理機械の開発」（代表：中村仁彦）の支援を受けた。

参考文献

- 1) M. Donald. *Origins of the Modern Mind*. Harvard University Press, Cambridge, 1991.
- 2) V. Gallese and A. Goldman. Mirror neurons and the simulation theory of mind-reading. *Trends in Cognitive Sciences*, Vol. 2, No. 12, pp. 493-501, 1998.
- 3) T. Inamura, Y. Nakamura, H. Ezaki, and I. Toshima. Imitation and primitive symbol acquisition of humanoids by the integrated mimesis loop. In *the Proc. of IEEE Int'l Conf. on Robotics & Automation*, pp. 4208-4213, 2001.
- 4) T. Inamura, I. Toshima, and Y. Nakamura. Acquisition and embodiment of motion elements in closed mimesis loop. In *the Proc. of IEEE Int'l Conf. on Robotics & Automation*, pp. 1539-1544, 2002.
- 5) S. Young et al. *The HTK Book*. Microsoft Corporation, 2000.
- 6) 戸嶋, 稲邑, 中村. 連続・離散ハイブリッドHMMによる行動認識・獲得の同時学習モデル. ロボティクスメカトロニクス講演会'02講演論文集, 2002.
- 7) K. Kurihara, S. Hoshino, K. Yamane, and Y. Nakamura. Optical motion capture system with pan-tilt camera tracking and realtime data processing. In *the Proc. of IEEE Int'l Conf. on Robotics & Automation*, 2002.