

ミメシス理論に基づく見まね学習とシンボル創発の統合モデル

稲 邑 哲 也^{*1} 中 村 仁 彦^{*1*2} 戸 嶋 巖 樹^{*1} 江 崎 英 明^{*3}An Integrated Model of Imitation Learning and Symbol Emergence
based on Mimesis TheoryTetsunari Inamura^{*1}, Yoshihiko Nakamura^{*1*2}, Iwaki Toshima^{*1} and Hideaki Ezaki^{*3}

During the behavior imitation, human being doesn't practice simple coordinates transformation, but acknowledge the others' behavior, understands the behavior after abstraction into symbol information, and generates one's self behavior. A framework "Mimesis" in cognitive science and "mirror neuron" found in biology field show that the behavior generation process isn't independent of behavior cognition process, but generation and cognition process have close relationship each other. Focusing on these facts, we propose a new method which carry out the behavior cognition process and behavior generation process at the same time, and co-evolve these two processes using the proto-symbol and mimesis framework. We also propose a mathematical model based on Hidden Markov Models in order to integrate the behavior cognition and generation process, which has an advantage that the model have three functions; 1) behavior memorization, 2) behavior recognition, and 3) self behavior generation, by itself. Finally, feasibility of this method is shown through experiment in a humanoid simulator.

Key Words: Imitation Learning, Symbol Emergence, Hidden Markov Models, Dynamics Abstraction, Mirror Neurons

1. は じ め に

ヒューマノイドの全身行動の設計は、数多くの自由度を同時に制御する必要があるため、非常に複雑な問題である。開発者がロボットに動作を先天的に埋め込むのではなく、物理的条件を後天的に同定し、人間の動作を真似て新しい行動を獲得するアプローチが多く提案されている [1] [2]。しかしながら、ただ単純に行動を見真似するだけでは、他者の座標系から自己の座標系に変換しているだけに過ぎない。人間が行なっている見まねは、単なる座標変換ではなく、相手の行動を認識し、それを自分の意志として実行するというプロセスである。このためには、まず他人の行動を観測を通じて記憶しシンボルとして認識する。その後シンボル情報から自分の行動を再現する。この大きく分けて 2 つのプロセスから成る。我々はこの行動認知と行動生成の仕組みの中にヒューマノイドの知性の発現のキーが存在していると考えている。

行動認知と行動生成の関係については、認知心理学の分野でも同様の示唆がなされており、ミメシス理論 [3] という枠組が提案されている。ヒトの脳は 300 万年前から進化しているのに対し、音節言語は 5 万 ~ 30 万年前程度の比較的新しい機能である。この事実は言語によるコミュニケーション以前に身振りや行動を介したコミュニケーションが成立していた事を示唆する。つまりミメシスは行動認知と行動生成の循環によるコミュニケーション機能であり、ヒトの知能の根源とも考えられる。これは我々の予想が正しい事を示す一つの布石となっている。

また、生物学の分野からも興味深い事実が発見されている。他人の特定の行動を観測する時に発火し、自分がその行動を行なう時にも発火するミラーニューロンがマカクザルの脳において発見されている [4]。このことから、ミラーニューロンは他人の行動を抽象化した表現形態であると解釈でき、また同時に、自分の行動はミラーニューロンの表現形態を自らの身体に対して展開したものであると解釈する事が可能である [5]。シンボルの生成と脳の情報処理の関係については、言語と脳が共進化するという Deacon の仮説 [6] にも見られる。

我々はこのような表現形態を原始シンボル (Proto Symbol) と呼ぶ。この、他人の行動が抽象化された表現である原始シンボルの概念は、行動認知と行動発達の関係を探る上で重要な概念である。

我々は、このような背景を踏まえ、人間の基本的学習機構の

原稿受付

^{*1} 東京大学大学院情報理工学系研究科

^{*2} 科学技術振興事業団 CREST

^{*3} 川崎重工業株式会社

^{*1} Graduate School of Information Science and Technology, University of Tokyo

^{*2} Japan Science and Technology Corporation, CREST

^{*3} Kawasaki Heavy Industries, Ltd.

一つであり、人間の知性の起源であるとも考えられているミメシス [3] を軸として、他者の行動の観察に基づく動作パターンの抽象化と自己行動の獲得を実現する手法を提案する。このプロセスには記憶、認識、再現の 3 種類のプロセスが含まれている。運動パターンの知覚や認識が、運動生成プロセスと逆のダイナミクスを持つ情報処理過程であるとの仮定を元に、他者行動の認識と自己の行動生成を一つのダイナミクスモデルで表現する事を目標とする。

我々の大きな目標は、ミメシスの見まねの機能とシンボルマニピュレーションの機能をバインドさせることによる、ヒューマノイドにおける統合的知能の実現である。本論文では、動作パターンを観測し、その行動をロボット自身に備わっている基本的行動要素の組み合わせとして表現する。そして、行動要素の組み合わせを学習し、抽象化することによって、シンボルを生成する。またその逆方向として、シンボルから動作パターンを生成するメカニズムの実現法について述べる。

第 2 章ではミメシスモデルによる見まね学習の概要と原始シンボルの概念について述べ、他の模倣システムとの比較を行なう。第 3 章で他者の行動の観察に基づく原始シンボルの生成について述べ、他者の行動を理解するメカニズムについて述べる。第 4 章では、行動を理解した結果である原始シンボルからヒューマノイドの全身行動を生成する手法について述べる。第 5 章では仮想環境のヒューマノイドにおける行動認識、行動生成、原始シンボル獲得、の各実験について述べ、本システムの有効性を示す。最後に第 6 章で結論を述べ、考察を行なう。

2. 他者の行動理解と自己の行動生成を行なうミメシス

本章では今までに提案されてきた見まねシステムと、我々が目指すミメシスの相違点について説明しながら、システムの概要を示す。

鮫島らによって提案された MOSAIC による見まねの枠組 [7] では、運動パターンを予測し制御するための順動力学と逆動力学モジュールが複数存在し、責任信号と呼ばれる変数を導入することで適切なモジュールが活性化され、観測した運動パターンを真似ることができる。しかしながらこの枠組では、明示的に時系列の情報が含まれている運動パターン（または担当モジュールの時系列パターン）を入力として受け取る事が前提となっており、明示的に時系列情報が含まれていないシンボル表現のみから運動パターンを作り出すことが難しい側面がある。時系列データの獲得と生成を実現するために、階層化 MOSAIC [8] も提案されているが、時系列データは責任信号予測器のネットワーク構造の中に獲得されるのであり、時系列データの中に内在するダイナミクスがシンボル表現として抽象化されているわけではない。これに対し、筆者らの提案するモデルでは時系列データのダイナミクスを抽象化する試みを行う。また、MOSAIC では運動の認識を行う予測器と生成を行う制御器は別個用意され、その対がモジュールと呼ばれているが、認識と生成を一つの数理モデルで実現することが筆者らのモデルの特徴の一つでもある。

Morimoto ら [9] は行動のダイナミクスの獲得という観点から、階層型強化学習の枠組を用いて 3 リンクロボットにおける起き上がり行動の学習を行っている。この枠組は時系列デー




Fig. 1 The overview of mimesis model

タのダイナミクスを抽象化する一つの表現形態であると見なすことができる。しかし、Morimoto らの枠組では、時系列データの獲得と再現が主張点であり、観測された運動パターンをあるシンボルとして認識する機能は持ち合わせていない。筆者らのモデルでは前段落で述べたように、認識と再生の統合が目標の一つとなっている点が大きな違いとなっている。

Atkeson らは primitive behavior と呼ばれる抽象化された単純な動作のモジュールを組み合わせ、複雑な行動を表現することによる見まね学習システムを提案している [10]。しかしこの primitive はタスクの文脈に依存してあらかじめ設計されている。これは意味や意図を開発者が与える事になるので、ミメシスを通じてシンボルを創発する枠組からは外れる事となる。

また、Kuniyoshi らの提案した teach by showing [11] と呼ばれる見まねの枠組では、ある程度複雑な行動が抽象化モジュールで表現されており、行動を再現することは容易である。しかしながら、刻一刻と変化して行く運動パターンのダイナミクスの抽象化という観点の考察はなされておらず、行動の移り変わりはほぼシンボル表現のまま記述されて行く。また Schaal らの研究例 [2] と同じく、あらかじめタスクに依存した行動要素が設計されている。

そこで、我々は、全身行動に含まれるダイナミクスをシンボルとして抽象化し、そのシンボルを用いて行動の再現と行動の認識を行なう手法を提案する。もし、行動のダイナミクスを抽象化し、シンボルとして表現することができれば、先に述べたミラーニューロンを工学的に構成することに等しい。このよう

な性質を持つ数理的手段として隠れマルコフモデルを採用した。

2.1 ミメシスモデルの概要

提案するミメシスモデルの概要を Fig.1 に示す。ミメシスモデルは二つの部分から成る。前半では観測された行動パターンは基本的な行動の表現要素によって分割され、その表現要素の時系列データの中に存在するダイナミクスを抽象化し、シンボルとして表現する。本論文では、このようなシンボルを原始シンボルと呼び、基本的な行動モジュールを行動要素と呼ぶことにする。後半のフェーズでは、原始シンボルから全身行動を再現するために、まず自己行動要素の時系列データを復元する。その後、各自己行動要素に対応した関節の動作パターンを再生する。

ミメシスモデルに求められる特性は、行動認識、行動生成、行動のシンボル化、という3つの機能を統合することにある。そこで、隠れマルコフモデル (Hidden Markov Models: 以下 HMM) を用いてミメシスモデルの実装を行なう。HMM は、時系列データを入力とし、その時系列データがどのカテゴリに属するものかを判定するための確率過程モデルで、音声認識の分野では非常に強力なツールとして古くから活用されている数学モデルである [12]。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 $\lambda = (Q, S, A, B, \pi)$ 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 q_i から q_j への遷移確率を示し、 b_{ij} は状態 q_i から出力記号 o_j を出力する確率である。

2.2 自己行動要素の導入

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。行動要素とは微小時間内でのヒューマノイドロボットの各関節角度や角速度などで表現される位相空間上の点 μ に相当する。各要素には、位相空間上の近傍の大きさを決定する共分散行列 Σ も付加されおり、

$$u \stackrel{\text{def}}{=} \{\mu, \Sigma\} \quad (1)$$

のように表現される。位相空間には各関節の角度、角速度の他に、ベースリンクの変位とその速度、ハンドの変位とその速度、あるいは外界情報としての各種センサ信号などを含むことで、より状況に適應した行動を扱うことが可能になる。現実的には計算量等の問題から当面はタスクに依存して位相空間を定義する変数を選択することが適当であろう。

この行動要素を M 個 ($u_1, \dots, u_M$) 用意し、HMM の出力記号 o と

$$o_i = u_i \quad (2)$$

のように対応づけることによって、HMM で扱われる時系列データ

$$O = [o_{k_1} o_{k_2} \dots o_{k_T}] \quad (3)$$

$$k_i \in \{1, 2, \dots, M\} \quad (4)$$

は、観察された他者行動および生成される自己の行動を表現することとなる。ただし、 O は行動要素 o を横に並べた行ベクト

ルで、左から i 番目の要素が離散的な時刻 i における行動要素を意味している。どのような種類の位相空間を行動要素表現に用いるべきか、という問題については、認識し再生したい運動パターンの特性に依存する。本論文では、運動学的な姿勢の時系列データを運動パターンと見なし、以降、位相空間はヒューマノイドロボットの全関節角度 θ を採用することとする。なお、行動要素はあらかじめ設計者が適切な M 個の要素を与える、という前提を設ける。

2.3 原始シンボルの導入

前節で述べた対応付けは時間と関節角に依存したパターンとしての対応付けであり、一連の流れに沿った行動パターンを認識するためには、なんらかのシンボルが必要である。シンボルの定義は様々であるが、本研究では言語情報などのラベル付けをされていない段階の前という意味で、原始シンボルという概念を導入する。この原始シンボルは、他者の行動の認識結果、自己の行動生成をする時の目標、言語獲得やコミュニケーションの際に必要なボトムアップに作成された概念。この3つの側面を兼ね備えた要素である。

ここで、HMM の各パラメータを考えると、本研究で使用する HMM は Left-to-Right モデルであるため、初期状態確率分布 π は一定の値を持つ。状態の集合 Q や出力記号集合 S は行動の時系列データと直接の対応関係はないので、状態遷移確率行列 A と出力確率行列 B の2つのパラメータによって時系列データに影響を及ぼす確率過程の特性が決定する。つまり、この2つのパラメータの内部に行動のダイナミクスが抽出されていると考える事ができるので、次式のようにパラメータの組を原始シンボルとして定義する。

$$p_S \stackrel{\text{def}}{=} \{A, B\} \quad (5)$$

このモデルから出力される記号列 O を自己行動要素と見なし、出力される行動列の尤度 $P(O|A, B)$ を用いて動作パターンと原始シンボルの結合関係を表現する。

HMM を用いた理由は、特徴量の揺らぎに影響を受けずに時系列データを認識できる能力だけにあるのではなく、運動パターンから原始シンボル表現への抽象化、運動パターンの認識、原始シンボルからの運動パターン生成、これらの3種類のプロセスが一つの数学モデルで記述できる点にある。また、HMM は音声認識の分野で非常に有効な手法として確立した手法であるため、高速計算のためのさまざまなアルゴリズムが開発されている側面もある。

3. HMM による行動の記憶・認識

3.1 他者行動の記憶と原始シンボルの生成

原始シンボルの生成は二つのフェーズから成る。第一段階では観察した行動データを記憶のデータベースに格納し、第二段階で行動要素表現に分解し、時系列に並べられた行動要素列の中に存在するダイナミクスを抽象化し、原始シンボル表現に変換する。

観測された行動パターンを行動要素列 $O = [o_{k_1} o_{k_2} \dots o_{k_T}]$ に変換するためには、まず微小時間単位で行動パターンをサンプリングし、その値 x に対して

$$j = \arg \max_i \frac{1}{\sqrt{(2\pi)^D \det \Sigma_i}} \exp \left\{ -\frac{1}{2} (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i) \right\} \quad (6)$$

の計算を行なう．上式は右辺の係数を持つ指数関数を最大にする i を j とおくという意味である．ただし D は要素表現の次元数， $\det$ は行列式， T はベクトルの転置を表す．右辺の指数関数とその係数は全体として平均値 μ ，共分散行列 Σ のガウス分布を意味する．この計算により，位相空間上で x にもっとも近い行動要素 u_j が求まる．これを各微小時間での行動要素とする．これを全ての時刻に対して繰り返し， $[u_{k_1} u_{k_2} \dots u_{k_T}]$ ，すなわち行動要素列 O を求める．

次に自己行動要素の時系列パターンからこれを尤もよく発生させるような HMM のパラメータを作成し，原始シンボルとして登録する (Fig.1 Step 3)．求めるべきパラメータは，2.3 節で述べた通り，状態遷移確率行列 A ，出力確率行列 B ，の 2 つのパラメータである．このパラメータ推定には，EM アルゴリズムの一種である Baum-Welch アルゴリズム [12] を用いる．計算の詳細については付録を参照されたい．状態ノードの個数については経験的に 20 に固定し，左から右のノードの一方方向に遷移する Left-to-Right モデルを採用した．

複数の行動パターンを観測し，それを一つの原始シンボルとして学習させたい場合は，その行動パターン全部を学習データとして使用する．

3.2 HMM による他者行動の認識

他者の行動を認識するために，観測された行動パターン O が原始シンボル p_S によって生成される確率 $P(O|p_S)$ を用いる．この確率は p_S を変数とする尤度であり，Viterbi アルゴリズム [13] によって高速に計算される．詳細については付録を参照されたい．

ミメシスモデル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，尤度の最大値を検出することで認識を行なう．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

$$R(O) = \log \frac{\max \{P(O|p_{S_i})\}}{\text{second}\{P(O|p_{S_i})\}} \quad (7)$$

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し，

$$j = \arg \max_i \{P(O|p_{S_i})\} \quad (8)$$

の j を用いて原始シンボル p_{S_j} を認識結果とする．認識判定指数 $R(O)$ の値が低ければ，認識は失敗，すなわち観測された行動は未知の行動であると見なして，3.1 節で述べた原始シンボルの作成フェーズに移る．

4. 原始シンボルを用いた全身行動の生成

原始シンボルから全身の動作を生成するには，まず，Fig.1 の Step 4 で原始シンボルである隠れマルコフモデルから自己行動要素列を生成する．次に Step 5, 6 で生成された自己行動要素列をスムージングし，関節角の変位に変換する．

前者の，原始シンボル p_S を手がかりとして自己行動要素列 O を出力するプロセスについて説明する．出力する手順は次のようになる．

- (1) 初期条件の設定．開始するノードを q_1 とし，ノードトークン $i = 1$ ，ステップ時刻 $t = 0$ ，時刻 t における行動要素列を O^t とする（初期状態では $O^t = \phi$ とする）
- (2) 現在のノード q_i から次のステップに遷移するノード q_j を遷移確率行列 A を用いて確率的に決定する．
- (3) ノード q_i から遷移する際に出力される行動要素 o_k を出力確率行列 B を用いて確率的に決定する．
- (4) 現在の行動要素列 O^t に出力された行動要素 o_k を追加し， $O^{t+1} = [O^t \ o_k]$ とする．
- (5) ノードが終端ノード q_N に到着すれば終了．そうでなければ $i = j$ とし，ステップ時刻 t を 1 増やして (2) に戻る．

このようにして得られた行動要素列は確率的な出力であるため，一回の試行ごとに，行動の長さや要素列の順序などが異なる．しかしながら， A, B のパラメータは運動のダイナミクスをある形で抽象化している表現なので，おおまかな運動データを再現することは可能である．そこで，このような試行を数回繰返し，それらの運動パターンの平滑化を行なうことで元の運動パターンの復元を行なうこととした．

最終的に，行動要素列を，実際の関節角度のパターンに変換するため，Step 5, 6 で各自己行動要素をつなぎ合わせ，平均化フィルタを用いてスムージングする．

実際に，運動パターンを HMM で認識する研究例は数多く存在するが [14] [15] [16] [17]，HMM を用いて運動パターンを生成するというプロセスを行なっている研究例は皆無である．唯一，音声合成の分野で HMM から時系列の音声パラメータを再現する研究例は存在するが，音声認識の逆モデルとして音声合成を行なっているわけではない．本研究の特徴として，運動認識の逆モデルとして運動生成が実現されていることが重要である．




Fig. 2 Motion Elements and Hidden Markov Models




Fig. 3 Humanoid HOAP-1

5. ヒューマノイドを用いた原始シンボルの有効性の検証

5.1 HMM による原始シンボルの生成実験

実験に用いるヒューマノイドは Fig.3 のような、(株) 富士通製、小型ヒューマノイド HOAP-1 である。このロボットは Fig.3 左に示す通り、片腕 4 自由度、片足 6 自由度、合計で全身に 20 自由度を持つ。このヒューマノイドにおいて Fig.4 に示すようなスクワット運動を設計し、これを原始シンボルとして獲得させる。ヒューマノイドにおける行動は 20[ms] のサンプリングレートで全身の各関節角が指定されており、約 2 秒間の長さの行動となっている。

原始シンボルを生成する際に、ノードの数を 20 個、HMM の構造は Left-to-Right モデル、行動要素の数を 90 個とした。このヒューマノイドは、20 自由度の関節を持つが、本論文では計算時間を短縮するため、右足の股関節ピッチ軸、膝関節、足首のピッチ関節の 3 次元から成る行動要素を採用した。

5.2 全身行動の生成実験

まず、HMM から一回の生成試行で出力された運動パターンを Fig.7 に示す。原始シンボルの学習に用いられた元の運動パターン (Fig.6) と比べて、おおよその関節角度の軌道を再現することができているが、激しくノイズが乗っているように見える。これは、ある程度の粗さに離散化されている行動要素が、各時刻において確率的に選択されているため、その不連続性が目立ってしまったのが原因である。

4 節で述べた手法を用いて 1000 回の生成を行なった際の運動パターンのグラフ表現を Fig.8 に、アニメーション表現を Fig.5 に示す。一回の生成時 (Fig.7) に比べると、動作が滑らかになっている事がわかる。元の運動パターンに比べて若干の誤差が生じているが、この誤差は離散的な行動要素表現に一旦離散化していることが大きな原因として考えられる。

計算時間は、Pentium-III 1[GHz] プロセッサで約 1[sec] であり、リアルタイムには至らないが、オフラインでの行動パターン生成器としては十分な速度を実現していることが確認された。

5.3 他者の行動の認識実験

多種類の行動の認識実験のため、Fig.9 に示すような、テニスのスイング ((a):swing)、歩行 ((b):walk)、コサックダンス




Fig. 6 Original motion pattern




Fig. 7 Motion pattern using only one time generation




Fig. 8 Motion pattern using 1000 times generation

((c):dance)、キック ((d):kick)、後ろ歩き ((e):back)、腹ばい歩き ((f):crawl)、荷物の持ち上げ動作 ((g):pickup) の 7 種類の行動を用意した。ただし (a) ~ (f) までの 6 種類は学習済みの既知の行動、(g) の行動については学習していない未知の行動として扱った。認識結果を Table.1 に示す。

表の数値は $P(O|A, B)$ の対数である。縦に並んでいる行動の名前が認識対象となる行動で、横に並んでいる行動の名前が既に学習してある原始シンボルに相当する。この対数の値が小さければ原始シンボルに良くマッチした行動であると判断できる。ここで、表の対角成分に注目すると良く分かるが、観測された行動と同じ行動に対する原始シンボルの尤度が高くなっている。また、学習されていない未知の行動 (unknown) に対する尤度はどれも同じような値を示しており、経験的に識別判定指数 R の値を 1000 と設定しておけば、間違う事なく認識できる事が分かった。

6. おわりに

本論文では、見まね学習を通じてシンボルを獲得し、高次の知能処理を実現するための基礎となるミメシスの概念を提案し、その工学的モデルの構成法を示した。(1) 運動パターンのダイナミクスの抽象化と原始シンボル化、(2) 原始シンボルからの自然な動作パターンの生成、(3) 原始シンボルを用いた他者の行動の認識、これら 3 つの機能を同時に実現するために、行動要素と隠れマルコフモデルによる原始シンボル表現法を導入し、その実現可能性をシミュレーション実験を通じて示した。



Fig. 4 Original motion for proto-symbol creation



Fig. 5 Generated motion from proto-symbol

Table 1 Recognition result of others' motion using HMMs.

Input Behavior	Proto-symbol						R
	swing	walking	dance	kicking	backward walking	crawling	
swing	-429.716	-3914.88	-4076.52	-3939.54	-4113.95	-4006.83	3485
walking	-3048.29	-225.048	-3070.79	-1645.7	-3099.05	-3018.69	1420
dance	-1656.08	-1602.96	-143.965	-1612.76	-1683.2	-1577.17	1433
kicking	-2543.15	-1573.54	-2561.72	-198.866	-2585.34	-2518.53	1374
backward walking	-2395.31	-2317.99	-2412.72	-2332.38	-201.504	-2372.13	2117
crawling	-4083.22	-3950.63	-3814.98	-3975.52	-4151.54	-487.833	3327
unknown behavior	-1914.81	-1853.22	-1928.48	-1864.63	-1946.33	-1896.36	11

本論文では、身体構造が全く同じロボット同士における行動の認識と生成を対象としており、また適切な行動要素の設計指針については述べていない。この問題に対処するためには、他人の行動の観察から適切な自分自身の行動要素を獲得する必要がある。現在、筆者らはこのような問題に取り組み、研究を進めている[18][19]。これについては別の論文にて詳述することとした。

一方で、対象とする自由度の問題については、直接ヒューマノイドの自由度と同じ次元での行動要素を採用すると計算時間が膨大になるというデメリットが発生する。これに対しては、20自由度を超える多自由度の全身運動を低次元化し、3次元情報で表現する手法[20]が提案されているので、その手法と組み合わせることで計算時間の短縮を図ることが可能であると考えている。

このミメシスモデルが持つ最大の特徴は、単純な動作パターンの認識、記憶、再生ではないところにある。他者の行動を既知の原始シンボルと比較し認識するプロセスと、原始シンボルから行動パターンを出力するプロセスが、同一の数学モデルを用いて記述されており、順方向と逆方向の計算手順の関係にある。そしてこの順逆変換を行なうモデルそのものを原始シンボルと定義することで、見まね学習とシンボル創発を統合させるものである。関連研究として川人ら[21][22]による双方向性理論がある。そこでは、運動の軌道パターンとトルクを互いに変換する順動力学と逆動力学の双方向の計算が脳内で実現されているとしている。また川人らはその計算原理がコミュニケーションや言語などの問題につながる、との卓見を述べている。筆者らは時系列情報が抽象化された原始シンボルと運動の時系列パターンとの間の統一的な統計的モデルに基づいて順逆計算モデ

ルを提案した。双方向性理論では時系列データの抽象化については言及していない。川人らの指摘のように、言語の問題への具体的アプローチが今後の重要課題である。本論文で提案したシンボルのモデルは時系列情報を内包する点でより言語やシンボルとの親和性が高いと考えている。

謝辞 本研究は科学技術振興事業団(JST)、戦略的基礎研究推進事業(CREST)研究領域「脳を創る」(領域代表：甘利 俊一)「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. Mataric. Getting humanoids to move and imitate. *IEEE Intelligent Systems*, pp. 18–24, 2000.
- [2] S. Schaal. Is imitation learning the way to humanoid robots? *Trends in Cognitive Sciences*, Vol. 3, No. 6, pp. 233–242, 1999.
- [3] M. Donald. *Origins of the Modern Mind*. Harvard University Press, Cambridge, 1991.
- [4] 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.
- [5] 小嶋. ミラーニューロンと言語の起源. 岩波科学, Vol. 69, No. 4, pp. 404–408, 1999.
- [6] T. W. Deacon. *The symbolic species*. W.W. Norton & Company, Inc., 1997.
- [7] 鮫島, 片桐, 銅谷, 川人. モジュール競合による運動パターンのシンボル化と見まね学習. 電子情報通信学会論文誌, Vol. J85-D-II, No. 1, pp. 90–100, 2002.
- [8] 川人, 銅谷, 春野. モザイクの拡張とコミュニケーション. 科学, Vol. 71, No. 6, pp. 839–843, 2001. 岩波書店.
- [9] J. Morimoto and K. Doya. Hierarchical reinforcement learning for motion learning: learning “stand-up” trajectories. *Advanced Robotics*, Vol. 13, No. 3, pp. 267–268, 1999.
- [10] D. C. Bentivegna, A. Ude, C. G. Atkeson, and G. Cheng. Humanoid robot learning and game playing using pc-based vision.




Fig. 9 Target behaviors (a) tennis swing, (b) walking, (c) Cossack dance, (d) kicking, (e) backward walking, (f) crawling, (g) unknown behavior.

- In *Proceedings of the 2002 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'02)*, pp. 2449–2454, 2002.
- [11] Y. Kuniyoshi, M. Inaba, and H. Inoue. Learning by Watching: Extracting Reusable Task Knowledge from Visual Observation of Human Performance. *IEEE Transaction on Robotics and Automation*, Vol. 10, No. 6, pp. 799–822, 1994.
- [12] 中川. 確率モデルによる音声認識. 電子情報通信学会, 1988.
- [13] S. Young et al. *The HTK Book*. Microsoft Corporation, 2000.
- [14] K. Ogawara, J. Takamatsu, H. Kimura, and K. Ikeuchi. Modeling manipulation interactions by hidden markov models. In *Proc. of 2002 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 1096–1101, 2002.
- [15] 吉池, 近野, 長嶋, 稲葉, 井上. 人間の演技によるヒューマノイドの動作生成基礎実験. 日本機械学会論文集 (C編), Vol. 65, No. 632, pp. 1565–1570, 1999.
- [16] 和田, 佐藤, 松山. 選択的注視に基づく複数対象の動作認識. 電子情報通信学会論文誌 D-II, Vol. J82-D-II, No. 6, pp. 1031–1041, 1999.
- [17] J. Yamato, J. Ohya, and K. Ishii. Recognizing human action in time-sequential images using hidden markov model. In *Proc. of CVPR*, pp. 379–385, 1992.
- [18] 稲邑, 中村. 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. 第 20 回日本ロボット学会学術講演会予稿集, p. 3H18, 2002.
- [19] 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.
- [20] 多谷, 中村. ヒューマノイドロボットの複数の全身運動パターンの共通空間の獲得. 第 20 回日本ロボット学会学術講演会予稿集, p. 1C37, 2002.

- [21] 川人. 脳の計算理論. 産業図書, 1996.
 [22] Y. Wada and M. Kawato. A neural network model for arm trajectory formation using forward and inverse dynamics models. *Neural Networks*, Vol. 6, No. 7, pp. 919–932, 1993.

付録 A. 隠れマルコフモデルの計算アルゴリズム

付録 A.1 Viterbi アルゴリズム

尤度 $P(O|A, B, \pi)$ の計算は以下の Viterbi アルゴリズムにて行なわれる.

$$\alpha_1(i) = \pi_i b_i(o_1) \quad (\text{A.1})$$

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(o_{t+1}) \quad (\text{A.2})$$

$$P(o_1^T|M) = \sum_{i=1}^N \alpha_T(i) \quad (\text{A.3})$$

付録 A.2 確率パラメータの学習

出力記号列 O が与えられた際に, HMM のパラメータ $A = \{a_{ij}\}$, $B = \{b_{ij}\}$, π を求める場合, まず

$$\gamma_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \alpha_T(i)} \quad (\text{A.4})$$

$$\gamma_t(i) = \sum_{j=1}^N \gamma_t(i, j) \quad (\text{A.5})$$

を定義し, 次式の EM アルゴリズムによって新しいパラメータの推定を行なう.

$$\hat{\pi}_i = \gamma_1(i) \quad (\text{A.6})$$

$$\hat{a}_{ij} = \frac{\sum_{t=1}^{T-1} \gamma_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (\text{A.7})$$

$$\hat{b}_{i(k)} = \frac{\sum_{t:o_t=k} \gamma_t(i)}{\sum_{t=1}^T \gamma_t(i)} \quad (\text{A.8})$$

この後に, 次式でパラメータの更新を行ない, 収束するまで式 (A.6) (A.7) (A.8) の推定を続ける.

$$\pi = \hat{\pi} \quad (\text{A.9})$$

$$a_{ij} = \hat{a}_{ij} \quad (\text{A.10})$$

$$b_{i(k)} = \hat{b}_{i(k)} \quad (\text{A.11})$$

以上を Baum-Welch アルゴリズムと呼ぶ.

中村 仁彦 (Yoshihiko Nakamura)

1954 年 9 月 22 日生. 1977 年京都大学工学部精密工学科卒業. 1982 年同大学大学院博士課程退学. 同年より 1987 年まで同大学助手. 1987 年より 91 年 3 月までカリフォルニア大学サンタバーバラ校助教授, 準教授. 同年 4 月, 東京大学工学部機械情報工学科助教授. 現在, 同大学大学院情報理工学系研究科知能機械情報学専攻教授, 工学博士. 運動学的冗長性, 複数のロボット機構の協調, 宇宙ロボットの制御, 外科手術ロボットシステム, 非ホロノミックな拘束を受ける機械の運動制御などに興味を持つ. 計測自動制御学会, システム制御情報学会, 日本機械学会, 日本コンピュータ外科学会, IEEE, ASME などの会員 (日本ロボット学会正会員)

戸嶋 巖樹 (Iwaki Toshima)

1976 年 4 月 4 日生. 2002 年東京大学大学院工学系研究科機械情報工学専攻修士課程修了. 現在, 日本電信電話株式会社 NTT コミュニケーション科学基礎研究所. ロボットを用いた人間の知覚特性解明の研究に従事. 日本音響学会および日本バーチャリアリティ学会会員 (日本ロボット学会正会員)

江崎 英明 (Hideaki Ezaki)

1975 年 12 月 24 日生. 1998 年 3 月東京大学工学部機械情報工学科卒業. 2000 年同大学大学院工学系研究科機械情報工学専攻修士課程卒業. 同年川崎重工に勤務. 非ホロノミックシステムなど非線形系の設計・制御, ロボットブレインなどに興味を持つ

稲邑 哲也 (Tetsunari Inamura)

1973 年 1 月 23 日生. 1995 年東京大学工学部卒業. 1997 年度日本学術振興会特別研究員 (DC1). 2000 年同大学院工学系研究科情報工学専攻博士課程修了. 博士 (工学). 同年科学技術振興事業団 CREST 研究員. 2003 年東京大学大学院情報理工学系研究科知能機械情報学専攻講師. ヒューマンロボットインタラクション, 脳の情報処理機構の開発等の研究に従事. 人工知能学会, 電子情報通信学会, IEEE 各会員 (日本ロボット学会正会員)