

# 統計的行動認識・生成モデルの幾何空間における 原始シンボルの発達と操作

稲邑哲也<sup>†</sup> 谷江博昭<sup>†</sup> 中村仁彦<sup>†</sup>

<sup>†</sup> 東京大学大学院情報理工学系研究科 〒113-8656 文京区本郷 7-3-1  
E-mail: †inamura@jsk.t.u-tokyo.ac.jp, ††{tanie,nakamura}@ynl.t.u-tokyo.ac.jp

あらまし 人間の原始的な見まね学習の能力は、コミュニケーションとシンボル操作の基本的な機能を司ると言われるが故に、人間の高度な知能の根元であると考えられている。このような考え方を提案するミメシス理論に基づき、我々はこれまでに、隠れマルコフモデルを用いた行動模倣と原始シンボルの創発の統合モデルを提案してきている。しかしこの原始シンボルは時系列パターンとの関係を記述する能力は持つが、その原始シンボルを組み合わせたり再構成することによって、より上位の複雑な行動パターンに対応するようなシンボル操作を行うことができなかった。本稿では、シンボル操作を行うための数理的手法の基礎として幾何学的シンボル操作に注目し、それを可能とする原始シンボル空間の構成を目的とする。

キーワード 隠れマルコフモデル, 原始シンボル, シンボル創発, 模倣学習

## Proto-Symbol Development and Manipulation in the Geometry of Stochastic Model for Motion Generation and Recognition

Tetsunari INAMURA<sup>†</sup>, Hiroaki TANIE<sup>†</sup>, and Yoshihiko NAKAMURA<sup>†</sup>

<sup>†</sup> Graduate School of Information Science and Technology, Univ. of Tokyo Hongo 7-3-1, Bunkyo-ku,  
Tokyo, 113-8656 Japan

E-mail: †inamura@jsk.t.u-tokyo.ac.jp, ††{tanie,nakamura}@ynl.t.u-tokyo.ac.jp

**Abstract** Humans' primitive skill of imitative learning is regarded as an origin of human intelligence because it is said that imitation is fundamental function for communication and symbol manipulation. He have proposed "mimesis model" in order to approach to a symbol emergence framework from behavior recognition/generation for humanoid robots. In this paper, we propose a mathematical model for motion recognition and generation as combination of basic motions by proto-symbol manipulation which is abstract expression of motion patterns. In order to describe the proto-symbol manipulation as geometric manipulation, construction of proto-symbol space and geometric proto-symbol manipulation method are established.

**Key words** Hidden Markov Model, Proto-Symbol, Symbol Emergence, Imitation Learning

### 1. はじめに

我々はヒューマノイドロボットにおける運動パターンの認識 / 生成の問題から知能への接近を試みるため、隠れマルコフモデルの確率的な情報処理の枠組みにに着目し、連続的な運動認識・生成と離散的なシンボルの操作の問題を統合する数理モデルの提案を行って来た [1]。このモデルは、発達心理学の分野において注目されているミメシス理論 [2] に基づいている。ミメシス理論は、見まね、すなわち行動理解と行動再現の相互作用を通じてコミュニケーションの能力が高まり、最終的にシンボル操作のような高度な知能を形成するに至ったとする仮説で

ある。

このモデルでは、運動パターンは HMM を用いて抽象化され、HMM のパラメータを原始シンボルと位置づけることで、運動の認識と生成の双方向計算を実現した。しかし、ある一つの原始シンボルは、特定の種類の運動に対応しているのみであり、運動パターン同士の関係性や原始シンボル同士の関係性を扱う事はできなかった。シンボルの持つ側面として、パターン間に存在する関係性を抽象化されたシンボルで記述し、その抽象化された世界でシンボル操作を行うことでパターンの情報処理を行う。という特徴がある [3]。従来までの我々のモデルでは、図 1 左のように、原始シンボルと呼ばれるシンボル表現と運動

の間の記述を行うことはできたが、図の右のように、異なる動作間や、異なる原始シンボル間の関係性を記述することはできなかった。本研究では、これを発展させ、シンボル同士の関係性からパターン同士の関係性を記述し、運動パターンの情報処理に新しい枠組みを提案することを目的とする。

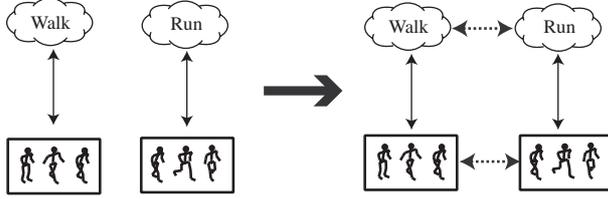


図 1 Conventional Mimesis Model[1] (left side) and proposed model (right side)

## 2. 原始シンボル空間の形成

### 2.1 ミメシモデルと原始シンボル

本研究では、連続的な運動パターンをシンボル表現として抽象化するために、連続分布型隠れマルコフモデル (Continuous HMM: 以下 CHMM) を用いる。CHMM は通常の離散型隠れマルコフモデルと異なり、出力が連続の値を持つ任意次元のベクトルである。この連続の値を持つベクトルを関節角度の情報と対応させることによって、ある一つの行動パターンが一つの CHMM パラメータとして抽象化されることになる [1]。

大きい次元の運動パターンが、少ない次元のパラメータで抽象化されていることから、我々はこの隠れマルコフモデルのパラメータをシンボルの原始的な表現形態、すなわち原始シンボルとして定義した。このモデルに基づき、原始シンボルの創発、行動認識、行動生成を行ってきた。

しかしこのままでは、抽象化された世界の中でシンボルを操作する事で新しい別の概念を形成するような、シンボル特有の特徴を活かしたことにはならない。そこで、原始シンボルの間の関係性を空間的な関係として記述することにより、幾何学的な操作に基づく、シンボル操作能力へのアプローチが必要となってくる。

### 2.2 隠れマルコフモデル間の隔たり量の定義

空間を構成するためには距離情報が必要となる。本研究で原始シンボルとして用いた HMM は確率モデルであるため Kullback-Leibler 情報量を用いて HMM 間の隔たりを表す量を定義する。Kullback-Leibler 情報量は確率分布関数間の隔たりを定量的に表すものである。2 つの確率密度関数  $p_1, p_2$  間の Kullback-Leibler 情報量  $D(p_1, p_2)$  は式 (1) で定義される。

$$D(p_1, p_2) = \int_{-\infty}^{\infty} \left( p_1(x) \log \frac{p_1(x)}{p_2(x)} \right) dx \quad (1)$$

これを HMM に適用する場合は、対象となる 2 つの HMM のパラメータを  $\lambda_1, \lambda_2$  として次の式で表現できる [4]。

$$D(\lambda_1, \lambda_2) = \frac{1}{n} \sum_i \frac{1}{T_i} [\log p(\mathbf{y}_1^{T_i} | \lambda_1) - \log p(\mathbf{y}_1^{T_i} | \lambda_2)] \quad (2)$$

ここで、 $\mathbf{y}_1^{T_i}$  は  $\lambda_1$  の学習に用いた長さ  $T_i$  の時系列データ、 $n$

は観測された時系列データの数である。

この式は一般に、 $D(\lambda_1, \lambda_2) \neq D(\lambda_2, \lambda_1)$  と  $\lambda_1, \lambda_2$  に対して非対称であり、HMM 間同士の距離的な量として用いるには不適切である。そこで式 (2) を対称形にした次式を原始シンボル間の隔たりを表す量として用いることにする。

$$D_s(\lambda_1, \lambda_2) = \frac{1}{2} (D(\lambda_1, \lambda_2) + D(\lambda_2, \lambda_1)) \quad (3)$$

### 2.3 原始シンボル空間の位相構造決定

原始シンボルを隔たり量に基づいて空間に射影し、原始シンボル間の類似情報を保持する原始シンボル空間を構成する。距離的な情報をもとに空間への配置を行うには多次元尺度法 [5] を用いる。多次元尺度法とは対称間の距離に関するデータが与えられた時にその対象の空間上での位置関係を再現する手法である。

対象  $i, j$  間の隔たり量に関する値  $f_{ij}$  をデータとして与え、 $f_{ij}$  に基づいて  $n$  個の対象を空間に射影することを考える。射影された対象  $i$  の空間での位置ベクトルを  $\mathbf{x}^i$  と表し、対象間の射影された空間上での距離を  $d_{ij}$  とする。ただし、 $d_{ij}^2 = |\mathbf{x}^i - \mathbf{x}^j|^2$  である。このとき、多次元尺度法は次式のように  $f_{ij}$  と  $d_{ij}$  の誤差  $S$  を  $\mathbf{x}$  に関して最小化する問題に帰着する。

$$S^2 = \sum_{i,j} (f_{ij} - d_{ij})^2 \quad (4)$$

式 (4) は  $\mathbf{x}$  の多項式で表現できないため、最小二乗法が簡単に適用はできない。そこで

$$T^2 = \sum_{i,j} \frac{(f_{ij}^2 - d_{ij}^2)^2}{4f_{ij}^2} \quad (5)$$

を考える。式 (5) は展開すると  $\mathbf{x}$  の多項式で表現できるため、 $\mathbf{x}$  に関しての最小化が簡単である。また  $T$  は  $f_{ij} \simeq d_{ij}$  のときには、 $T^2 = \sum_{i,j} \frac{(f_{ij} - d_{ij})^2 (f_{ij} + d_{ij})^2}{4f_{ij}^2} \simeq \sum_{i,j} (f_{ij} + d_{ij})^2 = S^2$  となり、 $S$  にほぼ一致する。そこで  $T$  を  $S$  の代わりに用い  $\mathbf{x}$  に関して最小化することで対象を空間に射影する [6]。

本研究では  $f_{ij}$  として  $D_s(\lambda_i, \lambda_j)$  を採用する。

## 3. 原始シンボル空間における行動認識・生成

本章では、原始シンボル空間の使用目的の基本的な二つとして、(1) 未知の行動を原始シンボル空間上の状態点として抽象化し、既存の原始シンボルの組み合わせとして認識する機能、(2) 既存の原始シンボルの組み合わせを原始シンボル空間上の状態点と表現し、未知の行動を生成する機能、を実現する手法について述べる。

### 3.1 原始シンボル空間を用いた行動認識

$n$  個の既知の原始シンボルを射影した原始シンボル空間を用いて、未知の運動パターンを認識する手法を考える。観測された未知の運動パターンに対応する HMM を求め、その HMM のパラメータを  $\hat{\lambda}$  とする。この  $\hat{\lambda}$  と既知の原始シンボルのパラメータ  $\lambda_1, \lambda_2, \dots, \lambda_n$  との間の Kullback-Leibler 情報量を求めることにより、原始シンボル空間上での  $\hat{\lambda}$  の状態点を決定することができる。

原始シンボル空間上での  $\hat{\lambda}$  の位置ベクトルを  $\hat{x}$  , 既知の原始シンボル  $\lambda_i$  の位置ベクトルを  $x^i$  とし, Kullback-Leibler 情報量  $D(\hat{\lambda}, \lambda_i)$  と, 原始シンボル空間上での  $\hat{x}$  と  $x^i$  間の距離  $d(\hat{x}, x^i)$  との誤差が最小になるように,  $\hat{x}$  を最小二乗法で求める.

実際には未知の運動パターンが観測される毎に HMM を学習することは, 学習サンプルを用意しなくてはならないこと, 計算に時間がかかることなどから現実的ではない. そこで HMM を学習したと仮定して Kullback-Leibler 情報量を求める. 非対称形  $D_s(\hat{\lambda}, \lambda_i)$  を求めることは困難であるので,

$$\begin{aligned} D(\hat{\lambda}, \lambda_i) &= \frac{1}{n} \sum_n \frac{1}{T_n} [\log p(\hat{y}^{T_n} | \hat{\lambda}) - \log p(\hat{y}^{T_n} | \lambda_i)] \\ &\simeq \frac{1}{T} \log p(\hat{y}^T | \hat{\lambda}) - \frac{1}{T} \log p(\hat{y}^T | \lambda_i) \end{aligned} \quad (6)$$

を求める. ここで  $\frac{1}{T} \log p(\hat{y}^T | \lambda_i)$  は計算することができるので,  $\frac{1}{T} \log p(\hat{y}^T | \hat{\lambda})$  を求めれば Kullback-Leibler 情報量を近似によって求めることができる. "dance", "kick", "squat", "swing", "walk" という行動における  $\frac{1}{T} \log p(y_i^T | \lambda_i)$  と  $\frac{1}{T} \log p(y_i^T | \lambda_j)$  の値を表 1 に示す.  $\frac{1}{T} \log p(y_i^T | \lambda_j)$  の値が -1000 のオーダーなのに対して,

表 1 Result of  $\frac{1}{T} \log p(y|\lambda)$  for each motion and HMM

$y \lambda$	dance	kick	squat	swing	walk
dance	15.00	-3978	-4501	-5471	-6736
kick	-4526	13.41	-2901	-4985	-4312
squat	-6624	-3239	7.05	-8278	-2021
swing	-8810	-7762	-9339	18.86	-13469
walk	-8573	-4498	-1021	-10944	5.49

$\frac{1}{T} \log p(y_i^T | \lambda_i)$  の値は 10 のオーダーである. したがって  $\frac{1}{T} \log p(\hat{y}^T | \hat{\lambda})$  の値も 10 のオーダーであるとして計算しても誤差は少ないという仮定を導入する. これらの仮定を用いて HMM を学習することなく  $D(\hat{\lambda}, \lambda_i)$  を近似によって求め, 未知の行動に対する状態点をオンラインで決定する.

このような原始シンボル空間上での幾何学的操作によって, 観測した運動パターンの認識結果を原始シンボル空間上での状態点として表現することが可能となり, 未知の運動パターンを既知の原始シンボルの組合せとして認識することができるようになる.

### 3.2 原始シンボル空間を用いた行動生成法

道の行動の生成例として, 二つの既知の行動が混合したような運動パターンを生成することを考える. この既知の行動の組合せを原始シンボル空間上の幾何学操作として解釈すると, 二つの状態点を結ぶ線分の内分点に相当する行動を生成することと同等となる. HMM のパラメータ  $\lambda_1 = \{a_{ij}^{(1)}, b_i^{(1)}(\cdot)\}$  と  $\lambda_2 = \{a_{ij}^{(2)}, b_i^{(2)}(\cdot)\}$  で抽象化されている行動の状態点を  $\alpha : (1-\alpha)$  の比で内分する状態点に対応する HMM のパラメータ  $\hat{\lambda} = \{\hat{a}_{ij}, \hat{b}_i(\cdot)\}$  を次のように定義する.

$$\begin{aligned} \hat{a}_{ij} &= \alpha a_{ij}^{(1)} + (1-\alpha) a_{ij}^{(2)} \\ \hat{b}_i(o) &= \sum_{m=1}^M \alpha c_{im}^{(1)} \mathcal{N}(\mu_{im}^{(1)}, \sigma_{im}^{(1)}) \end{aligned} \quad (7)$$

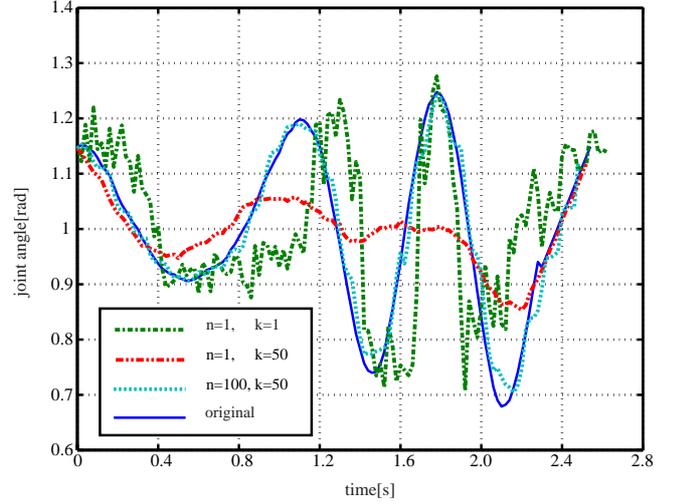


図 2 Comparison between each generated motion with several conditions

$$+ (1-\alpha) c_{im}^{(2)} \mathcal{N}(\mu_{im}^{(2)}, \sigma_{im}^{(2)}) \quad (8)$$

ただし,  $b_i(o)$  は  $b_i(o) = \sum_{m=1}^M c_{im} \mathcal{N}(\mu_{im}, \sigma_{im})$  で表せる混合ガウス分布である. 混合率  $\alpha$  を原始シンボル空間上の各基本行動の状態点との距離から求めることで空間の任意の点から  $\hat{\lambda}$  を得ることができる.

運動パターン生成は HMM の持つ遷移確率, 出力確率に従って時系列データを生成することによって行う. このデータ生成法は確率的なゆらぎのために, 試行ごとに運動の周期が異なり, 関節角度にもノイズが大きく含まれる. そこで以下のような方法により複数回の生成試行の平均を取ることによってこの問題を解消させる.

step1 遷移確率に従って状態遷移試行を 1 回行い, 状態遷移系列  $Q$  を得る.

step2 step1 を  $n$  回繰り返して,  $Q_1, \dots, Q_n$  を得る. それらの平均を取って状態遷移系列の平均  $\hat{Q}$  を得る.

step3  $\hat{Q}$  から各状態ノードから出力ベクトルを出力させ, 出力時系列パターン  $O$  を得る.

step4 step1 ~ step3 を  $k$  回繰り返して,  $O_1, \dots, O_k$  を得る. それらの平均を取って最終的な出力時系列パターン  $\hat{O}$  を得る.

ただし, この  $m, k$  の値は実験的に求めた結果,  $n = 100, k = 50$  とした. 系列長が異なり, かつ離散値の状態に対する平均の求め方については文献 [7] を参照されたい. この方法で HMM のパラメータ  $\lambda$  から運動パターンを生成した様子を図 2 に示す. グラフは全身の関節角のうち 1 次元分のデータを示している. グラフから分かるように, 一回の生成試行 (一点鎖線), 出力時系列のみに対する平均化 (二点鎖線) では正しい時系列データが生成されないが, 状態遷移系列と出力時系列パターンに対して平均化を行う (点線) ことで元のデータ (実線) とほぼ同等のデータを再現していることが分かる.

以上の方法を用い, 空間上の点から HMM  $\hat{\lambda}$  を求め, 得られた  $\hat{\lambda}$  から運動パターンを生成する. これにより原始シンボル空間での幾何学的な原始シンボルの操作による運動パターンの操

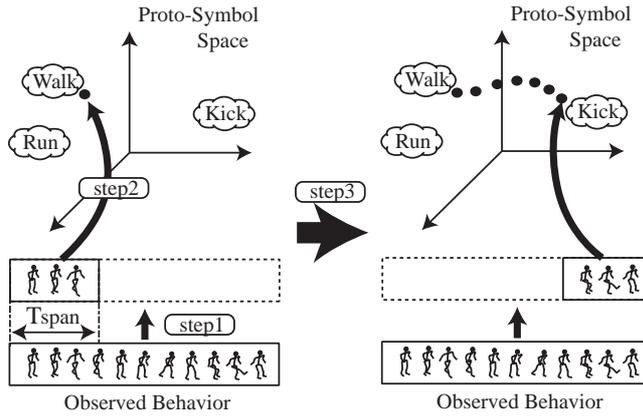


図3 Procedure of projecting motion in proto-symbol space

作が可能となる。

### 3.3 原始シンボル空間における連続的状态遷移系列としての行動の認識

人間の行動は複雑であり、原始シンボルとして獲得されている既知の行動以外の行動を常にとり続けていると言っても過言ではない。また、常に人間の行動を観察するシステムにとって、観測時系列の始点と終点が必ずしも与えられるわけではない。すなわち、現在行われている運動パターンを常に原始シンボル空間の状態点として記述することが必要となり、その結果、一般的な運動パターンは原始シンボル空間上の状態点の遷移として表現されることとなる。

本節では関節角度の時系列データ  $\theta(t)$  から原始シンボル空間上の状態点の遷移を得るプロセスの概要を図3に示す。観察した関節角度  $\theta(t)$  を微小時間単位  $dt$  でサンプリングし、 $i$  番目の微小区間での関節角度ベクトルを  $o[i]$  で表すと、運動の時系列データは  $O[t] = [o[1] o[2] \cdots o[T]]$  となる。ただし、 $T$  は運動の時間長を示すパラメータ、 $(t)$  は連続の時系列データ、 $[t]$  は離散的にデータが並んでいる時系列データを意味する。ここで、全体の運動のうち長さ  $T_{span}$  の部分に注目する (Step1)。注目した部分を  $O_1 = [o[1] o[2] \cdots o[T_{span}]]$  と表す。  $O_1$  を前節の手法を用いて原始シンボル空間の状態点  $x[1]$  として射影する (Step2)。

この注目する部分を  $T_{step}$  ずつずらしていき、 $k$  番目に注目する部分的な時系列データは

$$O_k = [o[1 + (k-1) \cdot T_{step}] \cdots o[T_{span} + (k-1) \cdot T_{step}]]$$

となり、これを原始シンボル空間に射影して、 $x_k$  を得る。この変換は合計  $\left\lceil \frac{T - T_{span}}{T_{step}} \right\rceil + 1$  回行われる事になるので、

$$n = \left\lceil \frac{T - T_{span}}{T_{step}} \right\rceil + 1$$

$$k = 1, 2, \dots, n \quad (9)$$

と少しずつずらしながら随時射影を行う ( $[a]$  は  $a$  を越えない最大の整数) これにより、関節角度データ  $\theta(t)$  から行動の遷移の様子を表す原始シンボル空間上の状態点の遷移

$$X[t] = [x[1] x[2] \cdots x[n]] \quad (10)$$

を得ることができる (Step3)。

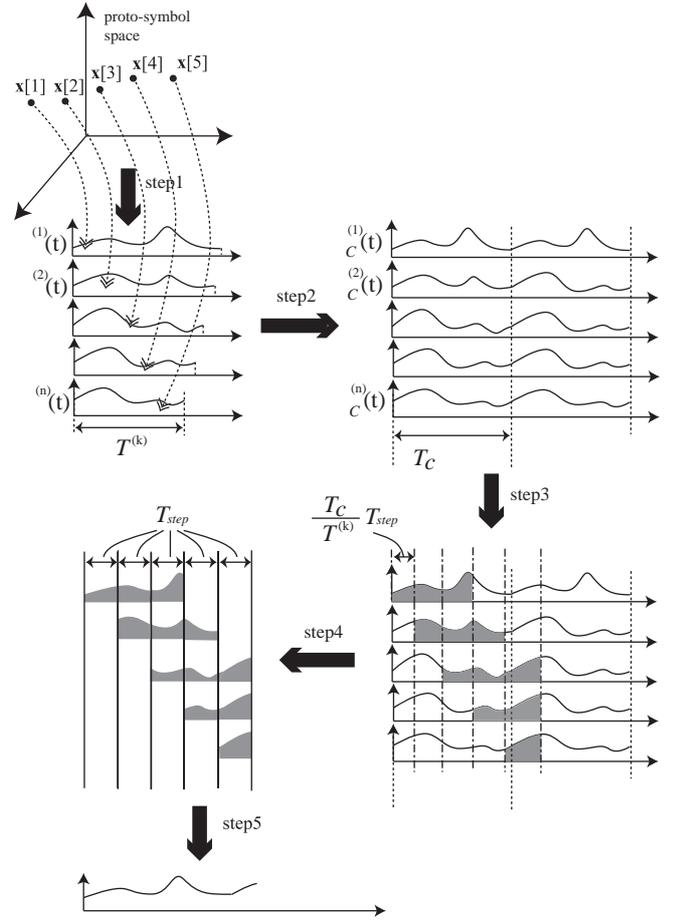


図4 Procedure of motion generation

### 3.4 原始シンボル空間における連続的状态遷移による行動の生成

3.2節では、静止している状態点  $x$  から、運動パターン  $\theta$  を生成する手法について説明した。本節では、状態点の遷移データ  $X[t]$  から運動パターンを生成する手法について説明する。このような生成を行うには、各状態点で生成される運動パターンを重ね合わせる必要が生じる。そこで、各状態点から出力される運動パターンを正規化し、位相のずれが発生しないような生成手法を実現させた。この生成プロセスの概要を図4に示す。原始シンボル空間上の時系列データの  $k$  番目の状態点を  $x[k]$  とし、この点から上記の方法で生成される関節角空間の時系列データを  $\theta^{(k)}(t)$  とする (Step 1)。この時系列データの時間長は原始シンボル空間上の位置によって異なるため (行動の種類が異なるため)、 $k$  によって行動の時間長は変動する。そこで、運動パターン  $\theta^{(k)}(t)$  の長さを  $T^{(k)}$  と表す。これを合成するために、それぞれの運動パターンをの時間長を次式のように  $T_c$  に揃えて正規化する (Step 2)。

$$\theta_c^{(k)}(t) = \theta^{(k)}\left(\frac{T^{(k)}}{T_c}t\right) \quad (11)$$

正規化を行った後、時間幅  $\frac{T_c}{T^{(k)}} \cdot T_{step}$  ごとに運動パターンを Step3 のようにブロック分けする。各運動パターン  $\theta_c^{(k)}(t)$  ( $k = 0, 1, \dots, n$ ) から3つのブロックを抽出し、それらを各時間帯に応じて重ね合わせるように平均を取る (Step

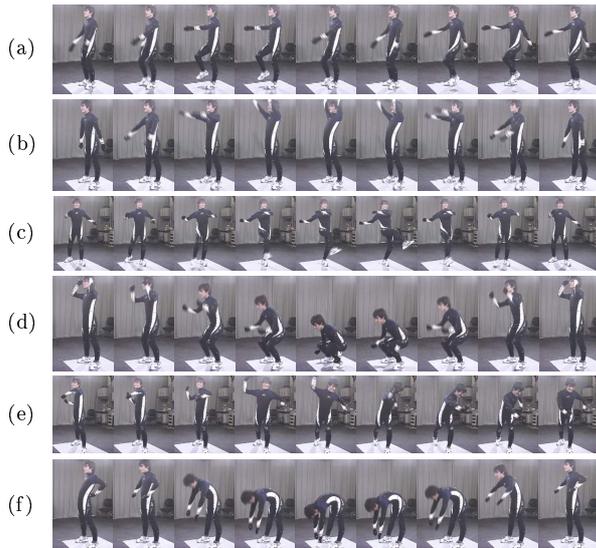


図 5 Six motions performed by human

4) . これらをつなげたものが最終的に生成される関節角の時系列データである (Step 5) .

#### 4. 階層型ミメシスモデルを用いた行動の認識・生成の実験

前節までで述べたシステムで実際の行動を観察し, 行動の認識・生成を行った. 行動の観察にはモーションキャプチャシステムを使用した. このシステムは全身の関節自由度数が 20 であるという仮定のもとに, 20[ms] ごとに 20 次元の関節角度データを獲得する事ができる. 図 5 のような walk, kick, squat, stoop, stretch, throw の 6 種類の行動を対象とし, それらを配置した 10 次元の原始シンボル空間を事前に用意した.

##### 4.1 行動認識実験

図 6 に示すように, まず最初に walk の行動を行い, 途中で次第に kick に移行するという未知の行動を観察させた. 行動認識の結果は原始シンボル空間上の状態点の遷移として出力される. この結果を図 7 に示す. 図 7 の各軸はそれぞれ原始シンボル空間の主要な 3 次元を示しており, 三角形や四角形のマークは各原始シンボルの状態点を示している. 点列として示されているのが, 認識された状態点系列  $[x[1] \cdots x[n]]$  である. この点列を見ると, 原始シンボル空間上を walk から徐々に kick へ遷移していくのが分かる.

HMM による行動認識の研究は数多く存在する [8] [9] [10] が, 既知の行動の認識を行うのが主な機能であり, 本研究のように幾何学的な関係性を利用して未知の行動の認識を試みる例は無い.

##### 4.2 行動生成実験

次に, 既知の行動の組み合わせによって未知の行動を生成させる実験を行った. walk の状態点から kick の状態点へ線分を引き, その結果得られる状態遷移列  $X[t]$  から行動を生成した結果を図 8 に示す. 観察した行動と同様に walk した後に kick するという行動が滑らかに生成されているのが確認できる.

以上の実験より, 観察した行動を原始シンボル空間上の状態

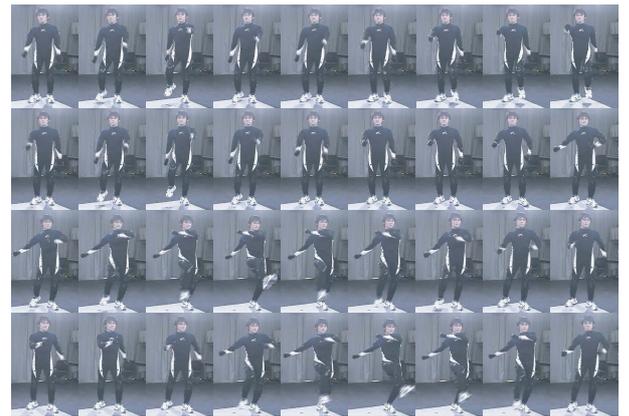


図 6 An novel motion: from walking to kicking

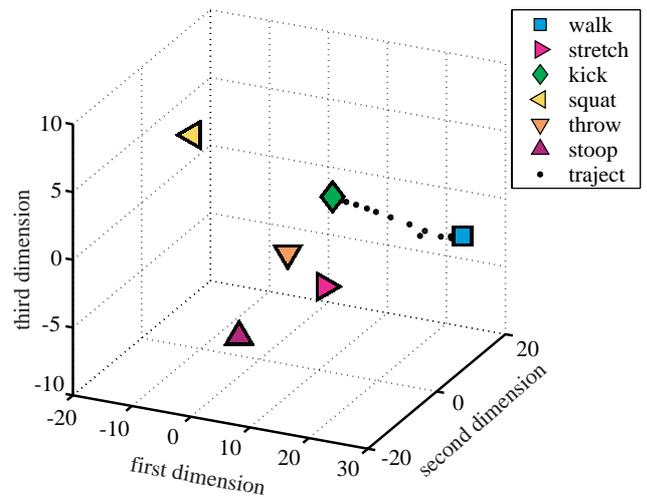


図 7 A result of motion recognition in the proto-symbol space

点の遷移に変換することで行動間の遷移を認識することができ, また原始シンボル空間上の状態点の遷移から行動を生成することで既知の行動を任意に組み合わせた行動を生成することが確認できた.

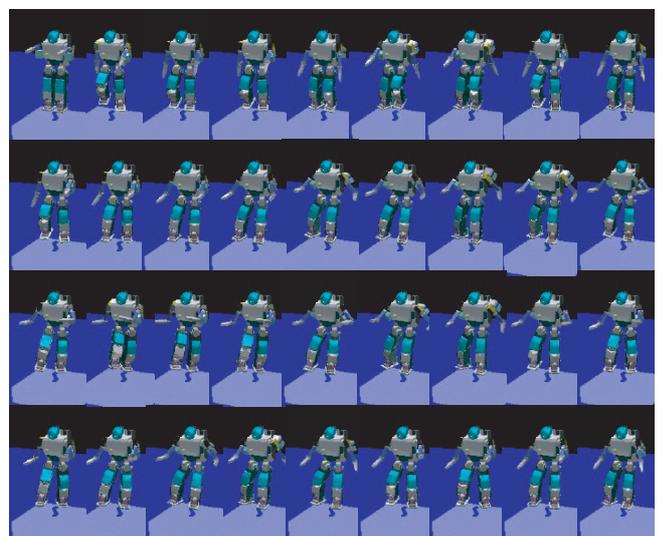


図 8 Generated motion by continuous proto-symbol manipulation

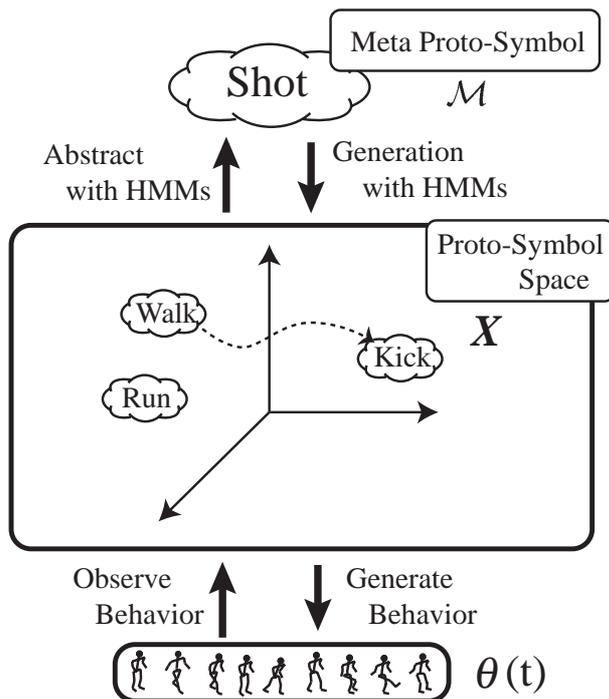


図 9 Outline of a hierarchical mimesis model

### 5. 階層構造の導入による知能への接近

今回提案したモデルでは、ロボットや人間の運動パターン  $\theta(t)$  を隠れマルコフモデルを用いて抽象化し、原始シンボル空間上の状態点  $x$  と表した。つまり、静的な状態点  $x$  は時系列の運動パターン  $\theta(t)$  と対応していた。この状態点は空間上のベクトルでもあるので、状態点の時系列データ  $X[t] = [x[1] x[2] \dots x[n]]$  もまた、同等の隠れマルコフモデルを用いて抽象化できる。このように、階層的に隠れマルコフモデルを適用することで、多段階の抽象化を目指す。これを階層型ミメシスモデルと呼ぶ。原始シンボル空間上の状態点系列  $X[t]$  を抽象化したものを原始シンボルの上位の概念という意味でメタ原始シンボルと呼ぶ。例えば図 9 のように、walk から kick へと移り変わる行動をメタ原始シンボル  $M(\text{shot})$  として抽象化可能である。逆にメタ原始シンボルから原始シンボル空間上の状態点の遷移を生成し、その遷移を関節角の時系列データ  $\theta(t)$  に変換することで行動の生成を行う。このような階層型の抽象化モデルを用いることによって、低レベルな運動パターンから段階的な抽象化プロセスを通じ、最終的に高次元のシンボル表現までを同一の枠組みで表現することが可能となる。

このように隠れマルコフモデルを階層的に積み重ねる事で、低レベルな関節角度の時系列データ  $\theta(t)$  から、離散的なシンボル情報  $M$  へと進化していく形態が望ましい。しかし、単純な階層構造ではメタ原始シンボルの上にメタメタ原始シンボルが形成されるだけである。そこで、メタ原始シンボルに対しては空間を形成しない戦略を取る。そしてメタ原始シンボルの時系列  $M(t)$  に対して抽象化を行う際には、いったん原始シンボル空間上の状態点系列  $X[t]$  として展開した後、新しいメタ原始シンボル  $M'$  として抽象化する。このような操作によって、

メタ原始シンボルという離散的な情報表現で単純な運動、その組み合わせによる複雑な運動、などの様々な運動を抽象化することが可能となる。

### 6. おわりに

本研究では原始シンボル空間を用いた階層型ミメシスモデルを提案した。人間の行動は複雑であり、原始シンボルとして獲得されている既知の行動以外の行動を常にとり続けている。また常に人間を観察することを考えると、定期的に運動データが入力されることになり、認識のための時系列データの始点終点は与えられないまま、リアルタイムに認識結果を出力することが必要となる。本稿では、このような状況における未知の行動の認識および未知の行動の生成を行うための数理モデルの拡張を行い、原始シンボル空間における状態点系列の幾何学的操作により、より複雑な行動の認識・生成が実現できることを確認した。

またさらに、階層構造を重ねることでより高次元のシンボル操作へと発展させるためのメタ原始シンボルの概念を提示し、隠れマルコフモデルによる階層的な運動認識・生成が可能となることを示した。

階層構造を重ねるにあたっては、メタ原始シンボルを再帰的に抽象化しつつ、階層の数が発散しないようなモデルの実現が必要となる。この問題に対しては現在取り組みを進めている所である。また、本稿で示した原始シンボル空間は情報幾何の概念と密接な関連があると考えている。今後は情報幾何の特性を考慮して、より高機能のシンボル創発モデルへと発展させて行く予定である。

### 文 献

- [1] Tetsunari Inamura, Iwaki Toshima, and Yoshihiko 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.
- [2] Merlin Donald. *Origins of the Modern Mind*. Harvard University Press, Cambridge, 1991.
- [3] Terrence W. Deacon. *The symbolic species*. W.W. Norton & Company, Inc., 1997.
- [4] L.R.Rabiner B.H.Juang. A probabilistic distance measure for hidden markov models. In *AT&T Technical Journal*, Vol. 64, pp. 391-408, 1985.
- [5] 高根芳雄. 多次元尺度法. 東京大学出版会, 1980.
- [6] 奥村晴彦. パソコンによるデータ解析入門. 技術評論社, 1986.
- [7] 稲邑哲也, 谷江博昭, 中村仁彦. 連続分布型隠れマルコフモデルを用いた時系列データのキーフレーム抽出とその復元. 日本機械学会ロボティクスメカトロニクス講演会 '03, 2003.
- [8] Toshikazu Wada and Takashi Matsuyama. Appearance based behavior recognition by event driven selective attention. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 759-764, 1998.
- [9] J. Yamato, J. Ohya, and K. Ishii. Recognizing human action in time-sequential images using hidden markov model. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 379-385, 1992.
- [10] P.K. Pook and D.H. Ballard. Recognizing teleoperated manipulations. In *IEEE International Conference on Robotics and Automation*, pp. 578-585, 1993.