幾何学的シンボル操作による多様な動作パターンの認識・生成を実現する原始シンボル空間の構成法

稲 邑 哲 也^{*1*2} 谷 江 博 昭^{*3} 中 村 仁 彦^{*3}

Construction of the Proto-Symbol Space that Realizes Recognition and Generation of Various Motion Patterns based on Geometric Symbol Manipulation

Tetsunari Inamura^{*1*2}, Hiroaki Tanie^{*3} and Yoshihiko Nakamura^{*3}

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. M.Donald has 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 Space, 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 (Hidden Markov Model: 以下 HMM) の確率的な情報処理の枠組みに着目し、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きた [1] [2]。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仮説 [3] [4] を参考にして提案されている。ミメシス仮説は、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能力が高まり、最終的に言語の使用や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。この考え方は Deacon が主張する、言語能力と脳の構造が共進化したとする考え方 [5] にも合致しており、非常に示唆に富んだ仮説である。

従来提案したモデルでは、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対応づけるこ

とで、運動の認識と生成の双方向計算を実現した。ここで、シンボルの持つ特徴として、パターン間に存在する様々な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を変更したり修正したりするような情報処理が可能であるという点がある。しかし、従来までの我々のモデル [1] [2] (Fig. 1) では、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だけであり、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議論することはできなかった。つまり、Fig. 1 左のような、原始シンボルと呼ばれる抽象化表現と運動パターン間の相互変換だけでなく、Fig. 1 右のような、動作パターン間の関係性、原始シンボル間の関係性を記述することがシンボル操作の重要な要素となる。そこで本研究では、従来までのモデル [1] [2] を発展させ、原始シンボ

Fig. 1 Conventional Mimesis Model [1] [2] (left side) and the proposed model in this paper (right side)

原稿受付 2008 年 10 月 8 日

^{*1}国立情報学研究所

^{*2}総合研究大学院大学

^{*3}東京大学大学院情報理工学系研究科

^{*1}National Institute of Informatics

^{*2}The Graduate University for Advanced Studies

^{*3}The University of Tokyo, Graduate School of Information Science and Technology

■ 本論文は学術性で評価されました。

ル同士の関係性と動作パターン同士の関係性の間に写像関係を持たせ、それを空間的に配置・表現することで、シンボル操作に基づく動作パターンの認識・生成を可能とする手法の提案を行う。

2. 原始シンボル空間の形成

2.1 連続分布型 HMM による原始シンボルの定義

以前に我々が提案していた動作パターンの抽象化手法 [1] では、離散型隠れマルコフモデルを用いていた。しかし、ベクトル量子化のような前処理を行い、動作プリミティブをあらかじめ獲得するプロセスが必要であるという問題があった。本論文で目的とする抽象化手法は新しい動作パターンの認識や生成を可能とするモデルであり、ベクトル量子化のプロセスを避ける必要があったため、連続分布型隠れマルコフモデル (Continuous HMM) を用いることとした。これは通常の離散型 HMM 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。このためあらかじめ離散出力ベクトルを作成する必要がなく、逐次新しい動作に対応可能となった。以下、簡単のため、連続分布型隠れマルコフモデルを単に HMM と記すこととする。

HMM は有限個数の状態ノードの組 $S = \{q_1, \dots, q_N\}$ とそのノード間を結ぶ有限個数のアーク (結合) から成る。また Fig. 2 に示すように、状態ノード間の遷移が確率的に起こり、各遷移ごとに多次元のベクトルが確率的に出力され、最終的にベクトル列が生成される。すなわち、状態遷移とベクトルの出力の 2 箇所所で確率的な挙動を示すモデルである。

i 番目のノード q_i から j 番目のノード q_j への遷移確率は a_{ij} で表され、行列 $A = \{a_{ij}\}$ は状態遷移確率行列と呼ばれる。また、ノード q_i においてベクトル $\mathbf{o}$ が出力される確率 b_i は出力確率と呼ばれ、各ノードに対して独立に存在する。その集合は $B = \{b_i\}$ で表される。本論文で扱う HMM では、出力されるデータは連続空間内の任意のベクトルであり、出力確率の確率密度関数は以下の式のようにガウシアン分布の線形結合の形で表される。

$$b_i(\mathbf{o}) = \sum_{j=1}^M c_{ij} \mathcal{N}(\mathbf{o}; \boldsymbol{\mu}_{ij}, \boldsymbol{\Sigma}_{ij}) \quad (1)$$

ただし、 M は混合させるガウシアン分布関数の総数を表し、 $\mathcal{N}(\mathbf{o}; \boldsymbol{\mu}, \boldsymbol{\Sigma})$ はガウシアン分布関数

Fig. 2 Continuous Hidden Markov models and time series data with the left-to-right-state transition model

$$\mathcal{N}(\mathbf{o}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{\sqrt{(2\pi)^D \det \boldsymbol{\Sigma}}} \exp\left\{-\frac{1}{2}(\mathbf{o}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{o}-\boldsymbol{\mu})\right\} \quad (2)$$

を表す。ただし、 $\boldsymbol{\Sigma}$, $\boldsymbol{\mu}$ はガウシアン分布の共分散行列と平均ベクトルを、 $\mathbf{c} = \{c_{ij}\}$ は分布の混合係数を、 D は出力ベクトル $\mathbf{o}$ の次元数を、 $\det \boldsymbol{\Sigma}$ は行列 $\boldsymbol{\Sigma}$ の行列式をそれぞれ意味している。また、状態遷移を開始させる初期ノードを決定するための初期分布確率 $\boldsymbol{\pi}$ というパラメータも存在する。これらのパラメータについては Baum-Welch アルゴリズム [6] と呼ばれる EM アルゴリズムの一種を用いて算出が可能となっている。

Fig. 2 に示した HMM は、左から右への一方方向に状態遷移が進むその形態から Left-to-Right モデルと呼ばれる。両端のノードを例外として、それぞれのノードには入力側のアークと出力側のアーク、そして自分自身へ遷移するアークの 3 種類の状態遷移アークを持つ。左端のノードには入力アークは存在せず、右端の終端ノードは自分自身へのアーク、出力アークは存在しない。Left-to-Right に対して、一般的な HMM はエルゴディック型と呼ばれ、すべてのノード間にアークが張られており、無限の長さ、あるいは周期的な時系列データを対象として使用される。Left-to-Right モデルでは構造そのものが、時間方向の推移の特徴を抽象化していると解釈できる。そのため、一定の長さを持つ時系列データを対象として活用され、音声認識においてその性能が確かめられている。本論文でも、行動やセンサなどの有限の長さの時系列データを対象とするため、Left-to-Right モデルを採用することとした。

以上より、HMM は $S, A, B, \boldsymbol{\pi}$ でその性質が記述される。ここで本論文では Left-to-Right モデルを採用しており、初期ノードは常に左端のノードであるため、 $\boldsymbol{\pi}$ は定数 $(1, 0, \dots, 0)$ となる。そこで本論文ではパラメータセット $\boldsymbol{\lambda} = \{S, A, B\}$ を用いて HMM の性質について議論を進める。

連続の値を持つベクトル $\mathbf{o}[t]$ を離散化された時刻 t における関節角度のベクトル $\boldsymbol{\theta}(t)$ と対応させることによって、ある一つの行動パターン $\mathbf{O} = [\mathbf{o}[1] \ \mathbf{o}[2] \ \dots \ \mathbf{o}[T]]$ が一つの HMM パラメータ $\boldsymbol{\lambda}$ として抽象化されることになる。

文献 [2] と同様に、多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、この HMM のパラメータのうち、動作パターンの種類によって変動する状態遷移確率と出力確率を動作の原始的なシンボル表現としてとらえ、以下のような原始シンボルとして定義する。

$$\mathcal{P} \equiv \{A, B\} \quad (3)$$

しかしこのままでは、抽象化されたシンボルを操作することで新しい別のシンボルや動作パターンを形成するような、シンボル特有の特徴を活かしたことはならない。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、幾何学的な操作によって、シンボル操作を実現して行くアプローチを取ることにした。

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を表現するのに用いた 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 情報量は確率密度関数間の隔たりを定量的に表すものであり, 二つの確率密度関数 $p_1(x)$, $p_2(x)$ 間の Kullback-Leibler 情報量 $D(p_1, p_2)$ は式 (4) で定義される.

$$D(p_1, p_2) = \int_{-\infty}^{\infty} \left(p_1(x) \log \frac{p_1(x)}{p_2(x)} \right) dx \quad (4)$$

これを HMM に適用する場合は, 対象となる二つの HMM のパラメータを λ_1, λ_2 として次の式で計算される [7].

$$D(\lambda_1, \lambda_2) = \frac{1}{N} \sum_i \frac{1}{T_i} \left[\log p(O_i^1 | \lambda_1) - \log p(O_i^1 | \lambda_2) \right] \quad (5)$$

ここで, O_i^1 は λ_1 の学習に用いた i 番目の時系列サンプルデータ, T_i はその時系列データの時間長, n は学習に使用された時系列データの総数である.

この式は一般に, $D(\lambda_1, \lambda_2) \neq D(\lambda_2, \lambda_1)$ となり, λ_1, λ_2 に対して非対称であるので, 計算を行う順序によって結果が異なってしまう. 計算や λ のインデックスの順序に依存しない基準を隔たり量として用いる必要があるため, 次式のような平均

$$D_s(\lambda_1, \lambda_2) = \frac{1}{2} (D(\lambda_1, \lambda_2) + D(\lambda_2, \lambda_1)) \quad (6)$$

を考え, λ_1 に含まれている A, B によって表される原始シンボル P_1 と, λ_2 に含まれている A, B によって表される原始シンボル P_2 の間の擬距離を式 (6) によって定義する.

2.3 原始シンボル空間の位相構造決定

原始シンボル間の類似関係を記述するため, 原始シンボル間の擬距離に基づいて各原始シンボルを空間内の状態点に射影することを考える. このように原始シンボルが状態点として配置された空間を原始シンボル空間と呼ぶ. 擬距離に基づいて原始シンボルを空間内の状態点に射影するために, 多次元尺度法 [8] [9] 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とき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.

ここで対象 i, j 間の隔たり量 f_{ij} を与え, 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ユークリッド距離を d_{ij} とする. すなわち, $d_{ij}^2 = |\mathbf{x}_i - \mathbf{x}_j|^2$ とする. このとき, 多次元尺度法は次式で表される f_{ij} と d_{ij} の誤差 E を $\mathbf{x}$ に関して最小化する問題に帰着する.

$$E^2 = \sum_{i,j} (f_{ij} - d_{ij})^2 \quad (7)$$

式 (7) 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

$$T^2 = \sum_{i,j} \frac{(f_{ij}^2 - d_{ij}^2)^2}{4f_{ij}^2} \quad (8)$$

という変換を考える. 式 (8) 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,

$$\begin{aligned} T^2 &= \sum_{i,j} \frac{(f_{ij} - d_{ij})^2 (f_{ij} + d_{ij})^2}{4f_{ij}^2} \\ &\simeq \sum_{i,j} (f_{ij} - d_{ij})^2 \\ &= E^2 \end{aligned} \quad (9)$$

となり, E にはほぼ一致する. そこで T を E 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 [10].

本研究では f_{ij} として $D_s(\lambda_i, \lambda_j)$ を採用する. 原始シンボルの個数を n とした場合, 空間を構成するために必要な次元数は一般的に $n-1$ となるが, それより少ない次元数で空間を構成しても誤差があまりない可能性もある. そのため, まず, $n-1$ 次元の空間を構成し, その中から重要でない次元を削除するような手順で空間を構成して行く.

3. 原始シンボル空間における行動認識・生成

本章では, 原始シンボル空間を用いた幾何学的シンボル操作の二つの例として, (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, および (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, の二つ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法

n 個の既知の原始シンボル $\{P_1, \dots, P_n\}$ 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 O を認識する手法を考える. ここで認識とは未知の動作パターンを原始シンボル空間上の状態点に変換することを意味する. まず, 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. 次に, この $\hat{\lambda}$ と既知の原始シンボルに対応する $\lambda_1, \lambda_2, \dots, \lambda_n$ との間の擬距離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未知の動作に対応する状態点の位置ベクトルを $\hat{\mathbf{x}}$, 既知の原始シンボル P_i の位置ベクトルを $\mathbf{x}_i$ とし, 式 (6) で定義した擬距離 $D_s(\hat{\lambda}, \lambda_i)$ と, 原始シンボル空間上での $\hat{\mathbf{x}}$ と $\mathbf{x}_i$ 間のユークリッド距離 $d(\hat{\mathbf{x}}, \mathbf{x}_i)$ との誤差が最小になるように, $\hat{\mathbf{x}}$ を最小二乗法で求め, 認識結果とする.

しかし, 未知の運動パターンが観測されるごとにそのパターンに対する HMM のパラメータを推定することは, 大幅な計算量の増加を伴い, リアルタイムで動作認識を実現するには現実的ではない. そこで, 計算量を抑えた認識処理手法を以下のように導入する.

まず, $\hat{\lambda}$ と既知の原始シンボル $\lambda_1, \lambda_2, \dots, \lambda_n$ との間の擬距離を $D(\hat{\lambda}, \lambda_i)$ で求めることとする. ここで, 未知動作パターン O の観測は 1 回しか行われていないので, 式 (6) からこの擬距離は

$$D(\hat{\lambda}, \lambda_i) = \frac{1}{T} \left[\log p(O|\hat{\lambda}) - \log p(O|\lambda_i) \right] \quad (10)$$

となる. さらにここで, 式 (10) 第一項の $\log p(O|\hat{\lambda})$ を計算

Table 1 Result of $\frac{1}{T} \log p(\mathbf{O}|\hat{\lambda})$ for each motion and HMM

$\hat{\lambda}$	$\hat{\lambda}_1(\text{walk})$	$\hat{\lambda}_2(\text{stretch})$	$\hat{\lambda}_3(\text{kick})$	$\hat{\lambda}_4(\text{squat})$	$\hat{\lambda}_5(\text{throw})$	$\hat{\lambda}_6(\text{stoop})$
$\mathbf{O}$						
$\mathbf{O}_1(\text{walk})$	22.8718	-133.138	-153.309	-337.286	-325.268	-154.967
$\mathbf{O}_2(\text{stretch})$	-321.907	21.5817	-162.89	-387.889	-384.279	-114.705
$\mathbf{O}_3(\text{kick})$	-237.246	-318.907	18.4539	-345.803	-329.061	-129.544
$\mathbf{O}_4(\text{squat})$	-494.074	-548.137	-229.21	21.3967	-367.938	-255.102
$\mathbf{O}_5(\text{throw})$	-320.964	-362.541	-100.204	-251.775	19.0278	-124.624
$\mathbf{O}_6(\text{stoop})$	-392.811	-246.426	-178.344	-287.221	-347.842	24.7976

する際に、 $\hat{\lambda}$ を求めることなく計算を実行するための近似を考える。この値の意味は、ある動作パターン $\mathbf{O}$ から推定される HMM $\hat{\lambda}$ によって出力される動作パターン $\mathbf{O}$ の尤度であり、定性的に考えると、この尤度の値は $\mathbf{O}$ が取り得るすべての空間の中において $\hat{\lambda}$ が表現する $\mathbf{O}$ の部分空間の割合を意味する。よって、 $\hat{\lambda}$ の推定が十分うまく行われていれば、この尤度の値はあまり変動しないことが予想される。そこでいくつかの動作パターンに対して $\frac{1}{T} \log p(\mathbf{O}|\hat{\lambda})$ を求めた結果を **Table 1** に示す。

$\frac{1}{T} \log p(\mathbf{O}_i|\hat{\lambda}_j) (i \neq j)$ の値がおおよそ -100 のオーダーなのに対して、表の対角線上に示された $\frac{1}{T} \log p(\mathbf{O}_i|\hat{\lambda}_i)$ の値はおおよそ 20 の値を示している。したがって式 (10) の値を支配的に決めるのは第 2 項であり、 $\frac{1}{T} \log p(\mathbf{O}|\hat{\lambda}_i)$ の値を 20 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 $\hat{\lambda}$ を計算することなく $D(\hat{\lambda}, \lambda_i)$ を近似によって求め、既知の原始シンボルに対する未知の行動の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み合わ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

未知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み合わ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、二つの原始シンボル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。原始シンボル $\mathcal{P}_1 = \{a_{ij}^{(1)}, b_i^{(1)}\}$ と $\mathcal{P}_2 = \{a_{ij}^{(2)}, b_i^{(2)}\}$ で抽象化されている状態点を $\alpha : (1 - \alpha)$ の比で内分する状態点に対応する原始シンボル $\hat{\mathcal{P}} = \{\hat{a}_{ij}, \hat{b}_i\}$ を考える。ここですべての原始シンボルに対応する HMM はノード数が等しいという前提を用いる。このとき、生成される原始シンボルは以下のように、それぞれのパラメータを $\alpha : (1 - \alpha)$ の比で内分するような計算で実現される。

$$\hat{a}_{ij} = \alpha a_{ij}^{(1)} + (1 - \alpha) a_{ij}^{(2)} \quad (11)$$

$$\begin{aligned} \hat{b}_i &= \sum_{m=1}^M \alpha c_{im}^{(1)} \mathcal{N}(\mu_{im}^{(1)}, \Sigma_{im}^{(1)}) \\ &\quad + (1 - \alpha) c_{im}^{(2)} \mathcal{N}(\mu_{im}^{(2)}, \Sigma_{im}^{(2)}) \end{aligned} \quad (12)$$

混合率 α 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 $\hat{\mathcal{P}}$ を得ることができる。

式 (11), (12) で示した方法は生成させたい原始シンボルの

状態点が、二つの原始シンボルの状態点を結ぶ直線上にあった場合にのみ有効であるが、一般的には、生成させたい原始シンボルは、二つ以上の原始シンボルを合成することになる。そこで、 $L (> 2)$ 個の原始シンボルを合成に用いる際、新規に生成させる原始シンボルの状態点と、既存の原始シンボル $\mathcal{P}_l = \{a_{ij}^{(l)}, b_i^{(l)}\}$ との距離 d_l の逆数に比例した混合比で合成することを考え、

$$\hat{a}_{ij} = \frac{1}{d_l \sum_l \frac{1}{d_l}} a_{ij}^{(l)} \quad (13)$$

$$\hat{b}_i = \sum_{m=1}^M \frac{1}{d_l \sum_l \frac{1}{d_l}} c_{im}^{(l)} \mathcal{N}(\mu_{im}^{(l)}, \Sigma_{im}^{(l)}) \quad (14)$$

という計算を使って新しい原始シンボルを作成する。

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過程のため、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でこの問題を解消させる。

Step 1 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 $\mathbf{Q} = [q[1] \ q[2] \ \cdots \ q[T]]$ を得る。

Step 2 **Step 1** を n_q 回繰り返し、 $\mathbf{Q}_1, \dots, \mathbf{Q}_{n_q}$ を得る。それらの平均を取って状態遷移系列の平均 $\hat{\mathbf{Q}}$ を得る。ここで平均を計算する際には、各時系列データの T の平均を取った上で正規化し、離散時間における $q[t]$ を連続時間における $q(t)$ と変換し、 $q(t)$ の平均をもって $\hat{\mathbf{Q}}$ を計算することとする。

Step 3 $\hat{\mathbf{Q}}$ に従って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 $\mathbf{O}$ を得る。

Step 4 **Step 1**~**Step 3** を n_o 回繰り返し、 $\mathbf{O}_1, \dots, \mathbf{O}_{n_o}$ 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 $\hat{\mathbf{O}}$ を得る。

ただし、この n_q, n_o の値は実験的に求めた結果、 $n_q = 100, n_o = 50$ とした。この方法で原始シンボル $\mathcal{P}$ から運動パターンを生成した様子を **Fig. 3** に示す。なおこのグラフは後出の Fig. 7(a) に示した足踏み動作における右肩 roll 軸の関節角度を示している。グラフから分かるように、1 回の生成試行 ($n_q = 1, n_o = 1$: 一点鎖線)、出力時系列のみに対する平均化 ($n_q = 1, n_o = 50$: 波線) 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 ($n_q = 100, n_o = 50$: 点線)。

以上の方法を用いることで、原始シンボル空間上の状態点か

Fig. 3 Comparison between each generated motion with several conditions

Fig. 4 Generated motion from mixed HMMs

ら HMM $\hat{\lambda}$ を求め、 $\hat{\lambda}$ 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作が可能となる。

Fig. 4 は式 (11), (12) の混合率 α を 0 から 1 まで、0.1 きざみで変化させながら、 $\mathcal{P}_1$ に walk、 $\mathcal{P}_2$ に kick を対応させて、二つの動作の中間的運動を生成させた結果である。図の横軸は時間、縦軸は右股関節のピッチ軸の関節角度を示している。混合率 α を徐々に変化させることで生成される行動がモーフィング効果のように変化して行く様子が分かる。このように原始シンボル空間での幾何学的シンボル操作が、運動パターンの操作に有効であることが示された。

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。

Fig. 5 Procedure of projecting motion in proto-symbol space

Fig. 6 Processes of motion generation

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 Fig. 5 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 $\mathbf{o}[i]$ で表すと、運動の時系列データは $\mathbf{O}[t] = [\mathbf{o}[1] \ \mathbf{o}[2] \ \cdots \ \mathbf{o}[T]]$ となる。ただし、 T

は運動の時間長を示すパラメータ, (t) は連続時間の時系列データ, $[t]$ は離散時間の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 (Fig. 5: 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 (Fig. 5: Step2).

この注目する部分を T_{step} ずつずらしていく. 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 $\left\lceil \frac{T-T_{span}}{T_{step}} \right\rceil + 1$ 回行われることになるので,

$$\begin{aligned} n &= \left\lceil \frac{T-T_{span}}{T_{step}} \right\rceil + 1 \\ k &= 1, 2, \dots, n \end{aligned} \quad (15)$$

と少しずつずらしながら随時射影を行う. ただし, $[a]$ は a を超えない最大の整数とする. 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

$$X[t] = [x[1] \ x[2] \ \cdots \ x[n]] \quad (16)$$

を得ることができる (Fig. 5: Step3).

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, 静止している原始シンボルの状態点 x から, 運動パターン $\theta(t)$ を生成する手法について説明した. 本節では, 原始シンボルの状態点の軌跡 $X[t]$ 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 Fig. 6 に示す. 原始シンボル空間上の状態点の軌跡のうち 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度の時系列データを $\theta^{(k)}(t)$ とする (Fig. 6: 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, 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 $T^{(k)}$ とし, これを合成するために, それぞれの運動パターンの時間長を次式のように定数 T_c に揃えて正規化する (Fig. 6: Step 2).

$$\theta_c^{(k)}(t) = \theta^{(k)}\left(\frac{T^{(k)}}{T_c}t\right) \quad (17)$$

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 Fig. 6 の Step3 のようにブロック分けする. 各運動パターン $\theta_c^{(k)}(t)$ ($k = 0, 1, \dots, n$) から三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 (Fig. 6: Step 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 (Fig. 6: Step 5).

Fig. 7 Six motions performed by human: (a) walk, (b) stretch, (c) kick, (d) squat, (e) throw, (f) stoop

4. 原始シンボル空間を用いた行動の認識・生成の実験

前章までに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] ごとに二十次元の関節角度データを獲得することができる。Fig. 7 のような walk, kick, squat, stoop, stretch, throw の6種類の行動を対象とし、それらを配置した六次元の原始シンボル空間を事前に用意した。

形成された原始シンボル空間内における状態点の配置の状況を Fig. 9 に示す。図からも分かるとおり、四つの次元は各原始シンボルを判別するために使用されているが、五次元目以降は活用されていない。すなわちこの実験の場合、原始シンボルの幾何学的な性質を表現するには四次元空間で十分であることが分かった。

4.1 行動認識実験

まず、原始シンボル空間の形成に用いた既知の行動のうち、二つの行動が混合しているような未知の行動を認識させる実験を行った。認識対象として用いたのは、kick と throw を同時に行う行動と、walk と stretch を同時に行う行動の2種類である。

この認識結果を Fig. 9 において最も使われている第一次元と第二次元によって構成される平面にプロットしたグラフを Fig. 10 に示す。図が示している通り、kick と throw を同時に行っている動作は、kick, throw それぞれの原始シンボルの間に位置し、同じように walk と stretch を同時に行う行動はそれぞれの原始シンボルの間に位置した。この結果からも分かるとおり、未知の行動であっても既知の行動に対応する原始シンボルとの幾何学的位置関係を参照することによって、どのような行動が含まれているのかということが認識可能であることが分かった。

次に、Fig. 11 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 Fig. 12 に示す。各軸はそれぞれ原始シンボル空間の主要な三次元を示しており、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。

ただし、この手法では (a) 連続的に徐々に動作が変化しているのか、(b) 非連続的に動作が変化しているのか、ということ

Fig. 8 Six motions imitated by humanoid

Fig. 9 Result of proto-symbol space construction

を認識することが問題となる。 T_{span} が既知の動作パターンの時間長に比べてほぼ同じ値である場合には (a), (b) の違いを明確に区別することができない。この区別を行う必要がある場合には、 T_{span} を既知の動作パターンの時間長に比べて十分に小さい値に設定する必要がある。

4.2 行動生成実験

動作パターンを原始シンボル空間上の原始シンボルに変換した後、その原始シンボルから動作パターンを再現することで動作模倣を行う事が可能となる。そこで人間の動作パターンをヒューマノイドロボットに模倣させる実験を行った。用いるヒューマ

Fig. 10 A recognition result of novel motions

Fig. 11 A novel motion: from walking to kicking

ノイドロボットのモデルはモーションキャプチャシステムで用いた人間の自由度配置と同じ 20 の自由度を持つロボットを仮定する。Fig. 7 に示した 6 種類の動作に対してクロスバリデーションによる認識・生成を行った結果を Fig. 8 に示す。ここで、ヒューマノイドは足を地面に付けているのではなく、腰リンクの位置姿勢を空中で固定してある。そのため実際の姿勢と少し異なるように見えるが、ほぼ正しく人間の動作を模倣できていることが分かる。

Fig. 12 A result of motion recognition in the proto-symbol space

Fig. 13 Generated motion by continuous proto-symbol manipulation

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 $\mathbf{x}_{walk}$ と kick の状態点 $\mathbf{x}_{kick}$ を結ぶ線分を 10 等分し、その各セグメントの節点によって得られる状態点列

$$\mathbf{X}[i] = \{\mathbf{x}_i\}$$

ただし

$$\mathbf{x}_i = 0.1i\mathbf{x}_{kick} + (1 - 0.1i)\mathbf{x}_{walk} \\ (i = 0, 1, \dots, 10)$$

から行動を生成した結果を Fig. 13 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。

5. 関 連 研 究

Tani, Ogata らは、リカレントニューラルネットワークの一

種である RNNPB [11] を用いて、ロボットの感覚運動情報をモデル化し、認識と生成の統合 [12]、および時系列データの低次元化手法 [13] を提案している。しかし、低次元化されたパラメータを用いて行動要素を組み合わせ、任意の行動を生成する具体的な計算手法については言及されていない。

HMM による行動認識の研究は数多く存在する [14]~[16] 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ない。また、Pentland らは、HMM を合成することで新しい動作の認識を実現する手法 [17] を提案しているが、右手の動作に関する HMM と左手の動作に関する HMM を合成して上半身の動作を表現するような合成であり、我々が提案しているような、二つの動作の中間的な動作を認識・生成することは実現できていない。

Maeda ら [18] は HMM を用いて人間の作業動作をモデル化し、その HMM 間の擬距離を Kullback-Leibler 情報量で計量し、多次元尺度法を用いて動作の分類を行っている。また Kobayashi らも高次元局所自己相関係数を用いた動画の分類を行うための空間構成の記述法を提案している [19]。しかし、いずれも抽象化された空間から動作を生成する手法については述べられていない。本手法は動作の抽象化のみならず、抽象化された空間内でシンボル操作を行うことで未知動作の認識・生成を行える点が利点となっている。

動作を低次元化し、パラメトリックにモデリングする手法として、主成分分析に基づくアプローチもいくつか提案されている [20]。しかし、主成分分析は時間成分を直接扱うことができないため、時間軸に沿って正規化されたデータや位相を合わせるなど、時系列データに対する前処理が必要である。システムのパフォーマンスがその前処理の性質に依存するという点があり、時間成分をいかに表現するかが課題として残されている [21]。

人間の身体動作に関する力学的な拘束条件や事前知識を用いることで低次元化された抽象化空間を構成したり [22]、動作修正インタフェースを実現した例 [23] もあるが、本手法では身体動作に依存せず、一般的な時系列データに対して適応可能な低次元化を実現している。そのため、音声情報や視覚情報などマルチモーダルな感覚運動情報への応用が容易である利点 [24] を備えている。

ヒューマンフィギュアの動作生成において、動作要素を内挿によって合成する手法もいくつか提案されている [25] [26] が、それらの研究事例は運動生成のみを対象としており、認識と生成の双方向の計算を行うモデルには至っていない。本研究で提案した原始シンボル空間は単なる動作のブレンディング（生成）のための手法ではなく、新奇動作を基本動作の組み合わせとして認識し、かつ、基本動作の組み合わせで新奇動作を生成するという、双方向の計算を行う事ができる点が従来研究にはない特徴となっている。

6. お わ り に

本研究では幾何学的シンボル操作によって動作パターンを認識・生成するための原始シンボル空間の構成法を提案した。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、定常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、逐次的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。

本論文で提案した手法にはいくつかの課題点が残されており、現在その解決手法について継続的に研究を進めている。主な課題点は以下の通りである。

逐次的な原始シンボル空間の修正

本稿で示した実験では、既存の原始シンボルの総数が変化しないことを前提とした条件が用いられていた。逐次的に原始シンボルが既知として空間内部に追加されるような場合、現状では多次元尺度法を用いて初期状態から空間を構成し直す必要がある。構成された原始シンボル空間を逐次的に発展させるような枠組みの開発が今後求められる。

軸の持つ意味

多次元尺度法のアルゴリズムが示しているように、原始シンボル間の擬距離のみが空間構成に反映される要素であり、構成された空間は回転の座標変換に対して解釈の変更が起きない。すなわち各軸には物理的な意味は存在していない。しかしながら、各軸に意味や解釈を対応づけることが可能であれば、複数の原始シンボルを用いて合成するだけでなく、単体の原始シンボルに対する幾何学的シンボル操作が可能となり、応用可能性は幅広くなる。

内挿の限界点

本稿で示した原始シンボルの合成は、状態点を内分する操作に対応する内挿によって計算されていた。これは、合成される原始シンボルの状態点の一角、既知の原始シンボルの状態点を頂点とする閉凸面体内部に限定されることを意味する。より一般的で多様な動作パターンの認識・生成のためには外挿のような合成法が必要となってくる。

参 考 文 献

- [1] T. Inamura, Y. Nakamura, I. Toshima and H. Tanie: "Embodied symbol emergence based on mimesis theory," *International Journal of Robotics Research*, vol.23, no.4, pp.363-378, 2004.
- [2] 稲田哲也, 中村仁彦, 戸嶋巖樹, 江崎英明: "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", *日本ロボット学会誌*, vol.22, no.2, pp.256-263, 2004.
- [3] M. Donald: *Origins of the Modern Mind*. Harvard University Press, 1991.
- [4] M. Donald: 'Approaches to the Evolution of language: social and cognitive bases,' J. Hurford, M. Kennedy and C. Knight (Eds.), *Mimesis and the Executive Suite: missing links in language evolution (chapter 4)*. pp.44-67, Cambridge University Press, 1998.
- [5] T.W. Deacon: *The symbolic species*. W.W. Norton & Company, Inc., 1997.
- [6] S. Young, et al.: *The HTK Book*. Microsoft Corporation, 2000.
- [7] B.H. Juang and L.R. Rabiner: "A probabilistic distance measure for hidden markov models," *AT&T Technical Journal*, vol. 64, no.2, pp.391-408, 1985.
- [8] 高根芳雄: 多次元尺度法. 東京大学出版会, 1980.
- [9] 岡太彬訓, 今泉忠: パソコン多次元尺度構成法. 共立出版, 1994.
- [10] 奥村晴彦: パソコンによるデータ解析入門. 技術評論社, 1986.
- [11] J. Tani and M. Ito: "Self-organization of behavioral primitives as multiple attractor," *IEEE Trans. on Systems Man and Cybernetics*, vol.33, no.4, pp.481-488, 2003.
- [12] R. Yokoya, T. Ogata, J. Tani, K. Komatani and H.G. Okuno: "Experience-based imitation using RNNPB," *Advanced Robotics*, vol.21, no.12, pp.1351-1367, 2007.
- [13] T. Ogata, S. Sugano and J. Tani: "Acquisition of Motion Primitives of Robot in Human-Navigation Task-Towards Human-Robot Interaction based on "Quasi-Symbols", " *人工知能学会論文誌*, vol.20, pp.188-196, 2005.
- [14] T. Wada and T. Matsuyama: "Appearance based behavior recognition by event driven selective attention," *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp.759-764, 1998.
- [15] J. Yamato, J. Ohya and K. Ishii: "Recognizing human action in time-sequential images using hidden markov model," *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp.379-385, 1992.
- [16] P.K. Pook and D.H. Ballard: "Recognizing teleoperated manipulations," *IEEE International Conference on Robotics and Automation*, pp.578-585, 1993.
- [17] M. Brand, N. Oliver and A. Pentland: "Coupled hidden markov models for complex action recognition," *Proceedings of the 1997 Conference on Computer Vision and Pattern Recognition (CVPR '97)*, pp.994-999, 1997.
- [18] Y. Maeda and T. Ushioda: "Hidden Markov Modeling of Human Pivoting," *Journal of Robotics and Mechatronics*, vol.19, no.4, pp.444-447, 2007.
- [19] T. Kobayashi and N. Otsu: "Action and Simultaneous Multiple-Person Identification Using Cubic Higher-order Local Auto-Correlation," *Proc. of International Conference on Pattern Recognition*, pp.741-744, 2004.
- [20] Y. Motai: "Synthesized articulated behavior using space-temporal on-line principal component analysis," *Advanced Robotics*, vol.21, no.13, pp.1503-1520, 2007.
- [21] K. Tatani and Y. Nakamura: "Dimensionality Reduction and Reproduction with Hierarchical NLPCA Neural Networks-Extracting Common Space of Multiple Humanoid Motion Patterns-", *Proc. of IEEE International Conference on Robotics and Automation*, pp.1927-1932, 2003.
- [22] A. Safonova, J.K. Hodgins and S.N. Pollard: "Synthesizing Physically Realistic Human Motion in Low-Dimensional, Behavior-Specific Spaces," *ACM Transactions on Graphics (SIGGRAPH 2004)*, vol.23, no.3, pp.514-521, 2004.
- [23] Z. Popovic' and A. Witkin: "Physically based motion transformation," *Proc. of SIGGRAPH*, pp.11-20, 1999.
- [24] T. Inamura, N. Kojo and M. Inaba: "Situation recognition and behavior induction based on geometric symbol representation of multimodal sensorimotor patterns," *IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.5147-5152, 2006.
- [25] D. Wiley and J. Hahn: "Interpolation Synthesis of Articulated Figure Motion," *IEEE Computer Graphic and Applications*, vol.17, no.6, pp.39-45, 1997.
- [26] C. Rose, M.F. Cohen and B. Bodenheimer: "Verbs and adverbs: multidimensional motion interpolation," *IEEE Computer Graphics and Applications*, vol.18, no.5, pp.32-40, 1998.

稲邑哲也 (Tetsunari Inamura)

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。2006 年国立情報学研究所助教授。同年総

合研究大学院大学複合科学研究科情報学専攻助教授。2007 年同准教授。ヒューマンロボットインタラクション、確率的情報処理を利用したロボットの知能化等の研究に従事。2003 年および 2006 年人工知能学会全国大会優秀論文賞、2003 年船井情報科学奨励賞、2008 年日本ロボット学会研究奨励賞受賞。人工知能学会、日本機械学会、電子情報通信学会、日本音響学会、IEEE などの会員。(日本ロボット学会正会員)

中村仁彦 (Yoshihiko Nakamura)

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 1991 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)

谷江博昭 (Hiroaki Tanie)

2003 年東京大学工学部卒業。2005 年同大学大学院情報理工学系研究科知能機械情報学専攻修士課程修了。脳の情報処理機構、モーションキャプチャシステムの開発等の研究に従事。

(日本ロボット学会学生会員)