

研究内容

運動パターンの認識と生成を統一する統計的情報処理 –連続的世界の記号化に向けて– (中村グループ)

(1) 実施の内容

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、脳科学、認知科学、心理学など、学際的なアプローチでその実現手法を探り、ミラーニューロンとミメシス理論に注目した。現在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近い部位に位置する器官で、他者の行動の認識と自己の行動生成の双方において活性化されることが知られている [1]。一方、ミメシス理論 [2] では、見まねがコミュニケーションを通じ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、という仮説が提唱されている。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た。

この研究は大きく分類して4つのフェーズに分かれ、それぞれのフェーズで、成果を得た。以下ではそれらのフェーズごとに成果を報告する。

1. 隠れマルコフモデルに基づく行動と原始シンボルの相互発達モデル

多自由度を持つヒューマノイドのようなロボットの行動パターンとシンボル情報を結びつける数理モデルとして、我々は隠れマルコフモデルの確率的な情報処理の性質に着目した。連続的な運動認識・生成と離散的なシンボルの関係を記述するには、複雑な行動を構成する基本的な行動要素(プリミティブ)が必要であり、このプリミティブを短時間における関節角の角度ベクトルおよび角速度ベクトルに対してベクトル量子化を行い、代表的なベクトルとHMMの出力記号を対応付けることによって運動認識を実現した。この対応関係を図1に示す。

原始的なシンボル表現としてのHMMには、運動を再現する能力が求められるが、HMMから最も良く出力される自己行動要素列を求める事は難しい。(出力され得る時系列パターンの取りうる全ての状態の中から最大尤度のものを求める事に相当する) 音声合成の研究分野においては、連続分布型HMMを用いてパターン生成する例も見られるが、音声認識/合成で良く用いられるLeft-to-Rightモデルに依存した方法である。人間の動作のように周期的な要素を含む場合、エルゴディックモデルを適用する場合もあり、一般的なHMMに対する時系列データの生成が求められる。理想的には、パターンが取り得る空間全体に対して探索を行い、もっとも相応しいと思われるパターンを見つけ出せばよい。しかしながら自己行動要素列の長さに対して指数関数的に計算量が増加するため、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。




図 1: 隠れマルコフモデルに基づく行動パターンの表現

HMM から出力される自己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の行動要素と対応させ、行動要素を l 個の遺伝子で表現する。遺伝子に対する適合度として、その遺伝子で表される自己行動要素列が HMM によって出力される尤度 $P(O(t)|A, B, \pi)$ を用いる。また、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。

これにより、行動パターンとそれを抽象化した表現である HMM とを相互結合する数理モデルが構築できた。その概要図を図 2 に示す。

2. 隠れマルコフモデルに基づく時系列データのキーフレーム抽出・認識・再生

ロボットの行動制御や実環境認識などには時系列データの記憶と再現が必要不可欠である。この際、瞬間のデータであるキーフレーム表現を用いて記憶すると、ロボットの行動制御や環境の特徴的な要素の把握などに有効である。特に、ヒューマノイドのように大自由度を持つロボットの運動データや動画像を扱うためには記憶容量のコストを削減するため、少ないパラメータで圧縮された記憶表現と再現手法が求められる。しかし、単なる符号化と復号化では容量コストに対処することはできても、時系列データの認識や生成に必要なコストを考慮したことはない。記憶表現が抽象化された表現ではなく、物理的な状態を保有したまま情報量を圧縮することがロボットにとって有利な表現形態となる。運動の物理的な特徴を保有した圧縮表現であると考えられるのは運動データをある瞬間で切り取った「キーフレーム」と呼ばれる表現である。これは CG において動画像を実現するための基本的な手法で、時間とともに変化する対象の特徴的な瞬間をキーフレームとして捉え、これを時系列方向に重ね合わせることで全体の運動を再現する手法である。近年はロボットの運動制御にも積極的に使われている手法である。また、運動の認識にも親和性が高い表現形態である。

前述したミメシスモデルでは、離散的な行動単位表現で連続的な行動を表現していたが、これは表現としては不十分であり、上記のキーフレーム表現を行動要素と

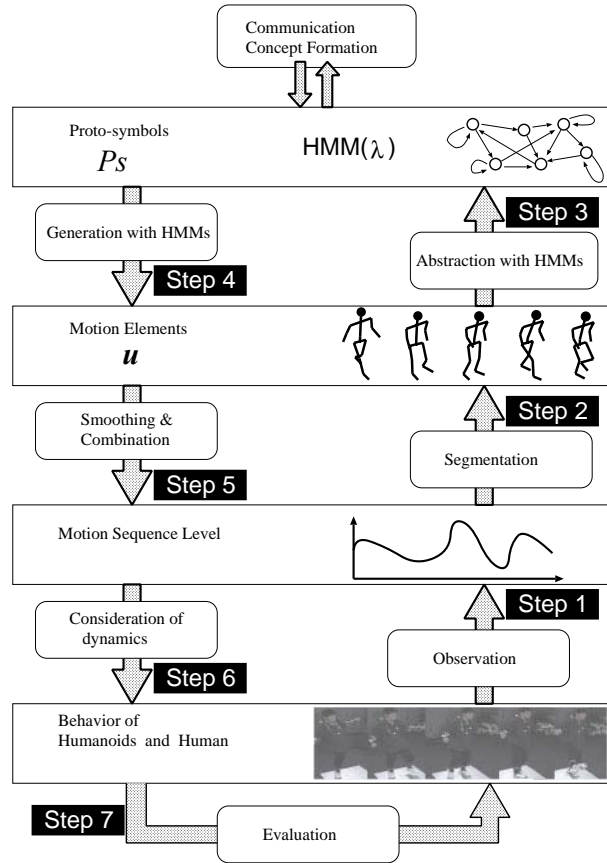


図 2: 隠れマルコフモデルに基づく行動パターンとシンボル情報の相互結合モデル

して採用することによって弱点をカバーすることが可能となる。

使用する HMM は図 3 に示すような混合連続分布型 HMM (Continuous HMM , 以下 CHMM) である。これは状態の有限集合 $S = \{s_1, \dots, s_N\}$, ノード s_i から s_j へ状態が遷移する確率 a_{ij} の集合である状態遷移確率行列 $A = \{a_{ij}\}$, ノード s_i においてベクトル x を出力する確率分布 $b_i(x)$ の集合 B , 初期状態確率分布 $\pi = \{\pi_i\}$. 以上の 4 項組 $\lambda = \{S, A, B, \pi\}$ で表される。図 3 のように , HMM は確率的に状態遷移を繰り返しながら , ベクトルを出力し , 最終的に時系列データを出力することになる。出力確率分布 $b_i(x)$ は M 個のガウス分布

$$b_i(o) = \sum_{j=1}^M c_{ij} \mathcal{N}_{ij}(o; \mu_{ij}, \Sigma_{ij}) \quad (1)$$

の線形結合によって実装される。このガウス分布の平均ベクトルは認識すべき行動のキーフレーム表現として使われるが , 逆に運動パターンの生成にも影響を及ぼす要素である。そこで我々はこのガウス分布の平均を行動要素であると見なし , 行動要素の設計を次式のように定義した。

$$u \stackrel{\text{def}}{=} \{\mu, \Sigma\}. \quad (2)$$




図 3: 連続分布型 HMM に基づく運動の表現

これらのパラメータは，Baum-Welch アルゴリズムと呼ばれる洗練された計算手法によって自動的に求められる．

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で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 $Q = [s_{k[1]}, s_{k[2]}, \dots, s_{k[T]}]$ ， $(k[i] \in \{1, 2, \dots, N\})$ を得る．

step2 *step1* を n_q 回繰り返し， Q_1, \dots, Q_{n_q} の平均を取ることで，平均的な状態遷移列 \hat{Q} を得る．

step3 平均的な状態遷移列 \hat{Q} から，ベクトル列の出力試行を 1 回行い， O を求める．

step4 *step3* を n_o 回繰り返し， O_1, \dots, O_{n_o} を求める．

step5 O_1, \dots, O_{n_o} の時間長を正規化し，平均化することで \hat{O} を求める．

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 HMM のパラメータ λ から運動パターンを生成した様子を図 4 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．




図 4: HMM に基づく運動パターンの生成結果

3. 離散・連続ハイブリッド隠れマルコフモデルによる身体性を考慮した模倣学習

隠れマルコフモデルに基づく行動パターンとシンボル表現の結合モデルでは，HMM が出力する記号を，あらかじめ与えておいた離散的な表現の行動要素（関節角度の時系列パターン）と対応付けていた．そのため，観察した行動パターンが行動要素の時系列パターンから大きく異なる場合，適切な表現が不可能となり，行動を正しく認識したり生成したりできなくなるという問題があった．そこで，従来使用していた離散型 HMM（Discrete HMM，以下 DHMM）に代えて前述した混合連続分布型 HMM（CHMM）を用いて設計することにより，行動要素の適切な設計を狙う．CHMM は図 3 に示すように，連続値のベクトルを出力する HMM で，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，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．しかしながら，CHMM は行動生成の際の計算量が膨大となり，生成には向かない．そこで行動要素の獲得には CHMM を用い，一方で行動の認識や生成には DHMM を用いるようにした．この 2 種類の HMM の有効な部分を互いに用いる事によってミメシスループを構築する．

行動の認識及び生成を繰り返しながら行動要素と原始シンボルを獲得させる．これによって，ミメシスは行動の認識及び生成を同時に可能とするモデルを獲得する．学習の手順を以下に示す．

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を追加
4. 行動要素のパラメータを再学習し，1 に戻る

生成した行動はあらかじめ与えた評価基準によって適切なものかどうかを判定され，適切だった場合，行動要素を獲得するための学習用データベースにその行動データが追加される．今回はこの基準として，生成した行動を自ら再認識した場合の認

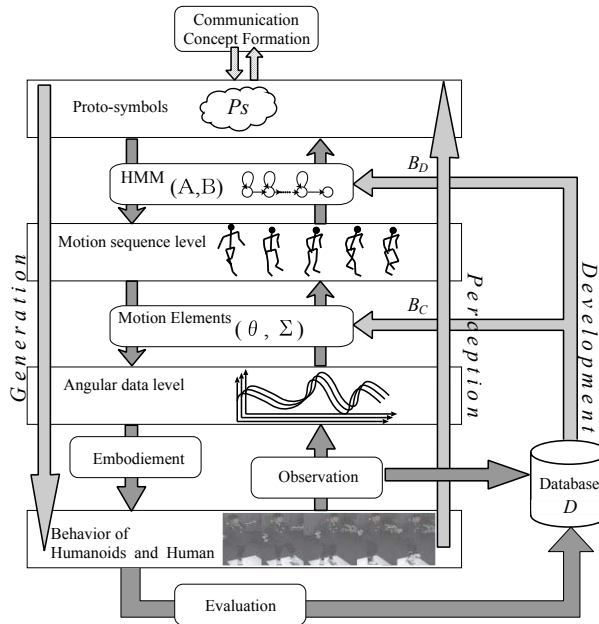


図 5: 離散・連続ハイブリッド隠れマルコフモデルに基づくミメシスモデル

識率及び，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．このほかにも，たとえば歩行行動では転倒せずに歩いた歩数，あるいはやスクワットにおける重心の軌跡などを用いることができる．生成した行動が不適切だった場合はそのデータを捨て，再び行動を生成するステップに戻る．その結果ヒューマ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．

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自由度に低次元化したものを用いた．20回の観察の後，80回の行動生成を経て生成された行動要素の状態を図6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角速度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が，手本となる行動に対応するAの領域だけでなく，Bで示した領域にも行動要素が分布している．これは，稼働範囲の狭い身体特性に沿うように生成した行動によって得られたものである．すなわち，他者行動を認識するために使用する行動要素(Aの領域)と，自己行動を生成するために使用する行動要素(Bの領域)の双方を獲得することが確認された．

4. 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

今までのミメシスモデルでは，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




図 6: 生成された行動要素

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 7 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．そこで従来のモデルを発展させ，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構築した．




図 7: 従来のミメシスモデル (左) と提案するモデル (右)

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．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 λ_1, λ_2 として次の式で表現する [4] ．

$$D(\lambda_1, \lambda_2) = \frac{1}{n} \sum_i \frac{1}{T_i} [\log p(\mathbf{y}_1^{T_i} | \lambda_1) - \log p(\mathbf{y}_1^{T_i} | \lambda_2)] \quad (3)$$

$$D_s(\lambda_1, \lambda_2) = \frac{1}{2} (D(\lambda_1, \lambda_2) + D(\lambda_2, \lambda_1)) \quad (4)$$

ここで， $\mathbf{y}_1^{T_i}$ は λ_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．

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手法である．具体的には，射影された対象 i の空間での位置ベクトルを x^i と表し，対象間の射影された空間上での距離を d_{ij} とした時， f_{ij} と d_{ij} の誤差 S を x に関して最小化する問題に帰着する．本研究では f_{ij} として $D_s(\lambda_i, \lambda_j)$ を採用した．

原始シンボル空間における行動認識・生成

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．

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 λ_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．

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．

未知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．

$$\hat{a}_{ij} = \alpha a_{ij}^{(1)} + (1 - \alpha) a_{ij}^{(2)} \quad (5)$$

$$\hat{b}_i(\mathbf{o}) = \sum_{m=1}^M \alpha c_{im}^{(1)} \mathcal{N}(\boldsymbol{\mu}_{im}^{(1)}, \boldsymbol{\sigma}_{im}^{(1)}) + (1 - \alpha) c_{im}^{(2)} \mathcal{N}(\boldsymbol{\mu}_{im}^{(2)}, \boldsymbol{\sigma}_{im}^{(2)}) \quad (6)$$

ただし， $b_i(\mathbf{o})$ は $b_i(\mathbf{o}) = \sum_{m=1}^M c_{im} \mathcal{N}(\boldsymbol{\mu}_{im}, \boldsymbol{\sigma}_{im})$ で表せる混合ガウス分布である．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 $\hat{\lambda}$ を得ることができる．

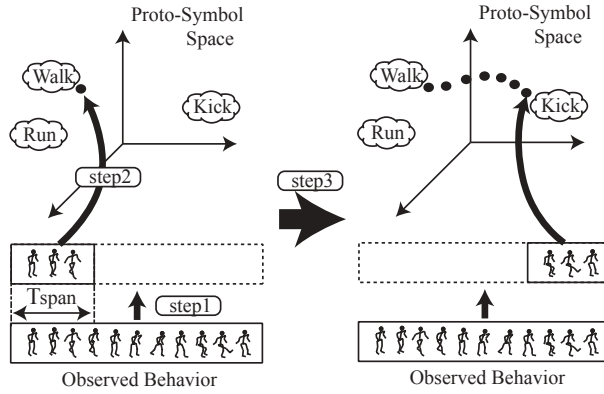


図 8: 原始シンボル空間を用いた運動パターンの認識

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 8 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． $k = 1, 2, \cdots, n$ と少しずつずらしながら随時射影を行うことによって，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

$$X[t] = [x[1] x[2] \cdots x[n]] \quad (7)$$

を得ることができる (Step3)．

一方，状態点の遷移データ $X[t]$ から運動パターンを生成するには，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

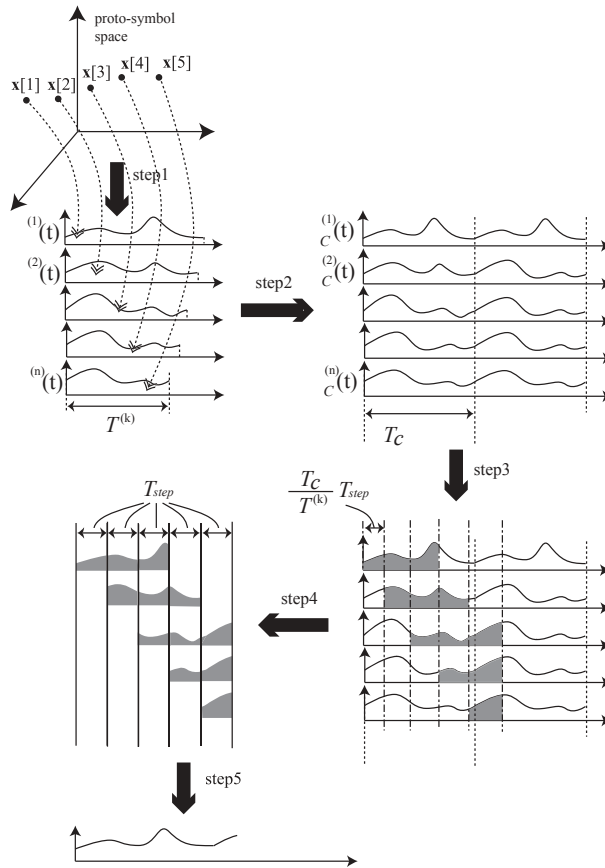


図 9: 原始シンボル空間を用いた運動パターンの生成

た．この生成プロセスの概要を図 9 に示す．原始シンボル空間上の時系列パターンの 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．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正規化し，時間幅ごとに運動パターンを Step 3 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 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)．

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 10 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．

図 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




図 10: 実験に使用した 6 種類の人間の行動:(a) 歩く, (b) ストレッチ, (c) キック, (d) スクワット, (e) 投げる, (f) 前屈

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 12 に示す．図 12 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 [6] 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．

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 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．

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，原始シンボル空間状の状態点 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 $X[t] = [x[1] \ x[2] \ \cdots \ x[n]]$ 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



図 11: 新規行動 : 「歩いた後に蹴る」

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 14 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事が可能となる．

(2) 得られた研究成果の状況及び今後期待される効果

本研究では，他者の行動を認識プロセスと自己の行動の生成プロセス，原始シンボルを創発するプロセス，の三つのプロセスを統合する数理モデルとして隠れマルコフモデル (HMM) を採用し，連続分布型 HMM に基づくミメシスモデルを考案した．また，原始シンボル間の関係性を記述するための原始シンボル空間の形成手法を提案し，幾何学的な原始シンボル操作に基づく複雑な運動の認識・生成を実現した．またさらに，階層構造を重ねることでより高次元な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




図 12: 原始シンボル空間の構成結果とそれを用いた運動の認識結果:三角形と四角形が原始シンボルを表し，黒い小さな点列は運動パターンの認識結果を示す．

認識・生成が可能となることを示した．

Deacon が示しているシンボルの発達モデルによれば，抽象化されたシンボル表現の世界と運動パターンを相互結合させるには，幾何学的な関係性のみでなく，抽象化された記号の世界での操作に基づいて運動パターンを認識・生成するプロセスが必要となり，逆に運動パターンの差を記号の差として表現することも必要となる．本研究で示したミメシスモデルは，この運動パターンと記号の相互関係を実現するために有効なツールとして位置づけられる．また，抽象化された記号表現へのアプローチとしては，ミメシスモデルの階層構造を位置づけている．

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．

このような運動パターンと記号の相互結合モデル，相互発達モデルの実現により，次のような効果が期待できる．(1) 見まねによる運動学習：教示者と学習者の身体構造が異なる場合でも，抽象化された記号表現を経由して運動パターンを伝えることによって，運動を学習することが可能となる．(2) 言葉の指示に基づく運動獲得：ヒューマノイドロボットの運動を設計する問題やロボットに自ら運動を獲得させる問題は，自由度が大きい場合困難を伴う．教示者が言葉による指示を加えることによって，運動パターンの獲得，設計を促進させることが可能となる．(3) 高次脳機能の構成論的理解：本研究は運動と記号の関係を記述する工学的なアプローチである




図 13: 幾何学的原始シンボル操作に基づく運動パターンの生成結果:「歩いた後に蹴る」

が, ミラーニューロンの生理学的な解明など, 学際的な問題との関連が大きい. 工学的な見地から脳科学, 神経科学, 心理学などへの波及効果も期待される.

参考文献

- [1] 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.
- [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] B.H. Juang and L.R. Rabiner. A probabilistic distance measure for hidden markov models. In *AT&T Technical Journal*, Vol. 64, No.2, pp. 391–408, 1985.
- [5] 高根芳雄. 多次元尺度法. 東京大学出版会, 1980.
- [6] P.K. Pook and D.H. Ballard. Recognizing teleoperated manipulations. In *IEEE International Conference on Robotics and Automation*, pp. 578–585, 1993.

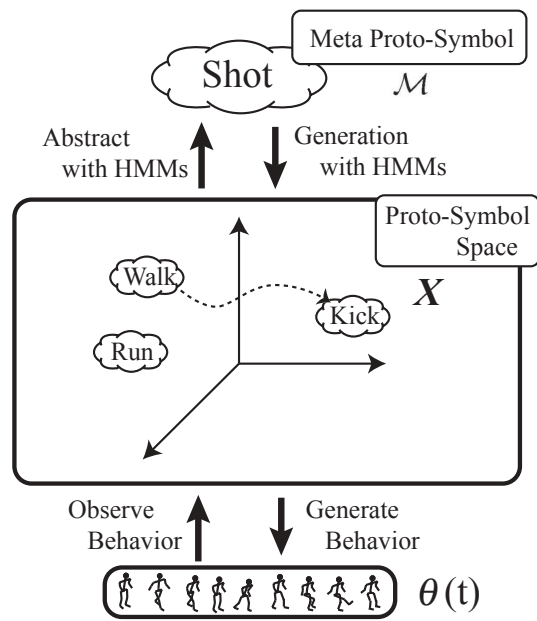


図 14: 階層型ミメシモデル




図 15: Deacon によるシンボルの発達モデル