

## 論文要旨

本稿では記号創発と身体性の関係について論じる．記号創発は記号接地問題の解決の為のもう一つの道筋である．記号接地問題は自律ロボットの持つ記号知識を設計者が与えるために起こる問題であるが，記号創発はこれに対し，自律ロボット自体に自らの経験を通し記号を発見・組織化させていくアプローチである．我々はこの立場から提案手法である，Dual-Schemata model を用いて様々な身体性を持った自律ロボットに環境との相互作用を通して記号創発を行わせる．これを解析することにより，この手法により記号生成と身体パラメータの間に非線形な関係が現れることを示す．

# 身体と環境の相互作用を通じた記号創発： 表象生成の身体依存性についての構成論\*

谷口 忠大<sup>†</sup>・榎木 哲夫<sup>†</sup>

## Symbol Emergence through Interaction with Environment: Synthetic Approach to the Relationship between Embodiment and Symbol Generation\*

Tadahiro TANIGUCHI<sup>†</sup>, and Tetsuo SAWARAGI<sup>†</sup>

This paper discusses a relationship between symbol emergence and embodiment. Symbol emergence is an alternative approach to overcome symbol grounding problem. We believe human beings' symbols constructed and held internally are originally based on our own embodiment. Therefore, autonomous social robots will also have to construct their own symbols by themselves. In addition to this, we have a nonlinear hypothesis about symbol emergence. To realize symbol emergence inside of autonomous robots, we propose Dual-Schemata model. This model enables an autonomous robot to generate its own symbols, called perceptual schemata, depending on its embodiment. In the end, we show that this symbol emergence has a nonlinear relationship with embodiment.

### 1. はじめに

自律ロボットの設計論においても、人間の認知活動についての研究においても、記号創発 (symbol emergence) は重要な研究テーマとなる。自律ロボットの研究においてはGOFAI(Good Old Fashioned Artificial Intelligence)と呼ばれる時代の研究において、表象操作を知能の基本としてとらえたアプローチがなされてきた。しかし、設計者により自律ロボット内部にデザインされた閉鎖的な記号系は、多くの場合実世界では機能しなかった。そのため、記号系を捨てて、知性の根源を身体性に求めた身体性認知科学的アプローチが提唱されている [10]。しかし、人間の知能について言えば、記号的な能力が他の動物とを分ける根本的特長であるとも言われており [9]、記号系は知能研究の枠組みから外すわけには行かない。このよう葛藤を S.Harnad は記号接地問題 (symbol grounding problem) として問題提起を行った [7]。

こうした文脈から多くの記号接地についての研究がなされているが、その多くは、デザインされた記号をパターン認識などの技術を通してある種のセンサ入力と関係づけるというものである。これは、結局は設計者が記号の意味を与えているのであり、その記号概念は自律ロ

ボット自身のものとは言えない。このようなトップダウンに与えた記号を接地させるという記号接地の考え方式に対し、人間が発達プロセスを通して自ら記号生成していくような構成的プロセスに注目した、自律ロボット自身によるボトムアップな記号創発の考え方式が注目され始めている [12,27]。

本稿では自律ロボットに環境との相互作用を通して内的表象を累増的に生成させていく為に累増的モジュール学習器である Dual-Schemata model を導入する。そして、身体性の異なるロボットが自らの記憶を組織化するプロセスに於いて生成するシエマ (schema) という内的表象が、そのロボットの身体性にどう依存するのかについての実験及び考察を行う。

### 2. 身体性と記号

#### 2.1 身体による世界の分節化

現代記号論の祖の一人である F.Saussure は記号の重要な性質として二段階の恣意性について述べた [14]。それは、連続的で無限の現象が起こる現実世界をどう分節化するかというカテゴリ化についての恣意性と、それをどのようなサインと結びつけるかという恣意性である。後者を扱う機械学習については古くからの人工知能研究において、様々なモデルが与えられてきたが、前者については暗黙的に設計者が与えるのが常であった。なぜならば、前者を扱うには、我々が何を基準にある対象とある対象が「違う」または「同じ」と認識し始めるのかに

\* 原稿受付

<sup>†</sup> 京都大学 大学院 工学研究科 Graduate School of Engineering, Kyoto University; Yoshida-Honmachi, Sakyo ward, Kyoto city, Kyoto 606-, JAPAN

Key Words: symbol emergence, schema, embodiment.

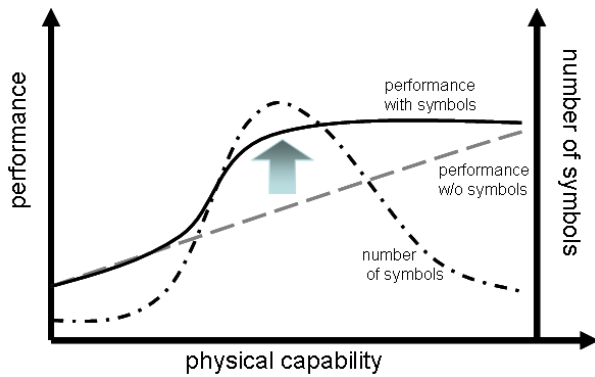


Fig. 1 Conceptual Graph of Nonlinear Hypothesis about Symbol Generation

についての議論が必要であり、計算論的な記号処理だけに閉じた話ではなく、発生的認識論、脳科学、哲学などの領域へと広く開かれた議題だからである。しかしこれは、内的表象がそれ自体、決して物理的に観測しえるものではないという制約の為、科学的に取り扱うのは非常に困難である。

J.J.Gibsonにより開祖された生態学的認識論においては、対象の認識と自らの身体を用いた行為の可能性が非常に深く関係しているといわれている(アフォーダンス)[15]。例えばある巾を持った溝があるとき、ウマのような体の大きなものにとっては飛び越えやすいが、子犬にとっては越え難い障害となるであろう。巨大恐竜にとっては気づきさえしないものであるかもしれないし、鼠のようなさらに小さい動物にとっては飛び越える対象ではすでに無くなっていると考えられる[24]。このような行為主体内部に視点をおいて世界を見る考え方は20世紀前半に生物学者J.Uexkullにより生物記号論として提示されており、そこでは、ある生物から見た主観的な世界はUmwelt(環世界)と呼ばれている。そこでは世界の分節が主体の身体に応じて変わる様が語られている。その分節は先天的なものばかりではなく、後天的な成長や自らの身体の状況に応じても変化する。[16]

このような事を踏まえると、今までの人間の持つ言葉(記号)が行う世界の分節化の仕方を自律ロボットに一方的に覚えさせるという、記号接地の考え方はロボット自身のUmweltを無視したものである。人間が持つ記号から始めるのではなく、自律ロボットの身体から始めてロボットにとっての記号が自身の記憶の組織化機構をとおして生成されていく必要があり、我々はこの記号創発のプロセスをモデル化し人間の知能理解や自律的知能の設計論に応用すべく研究を行っている。

## 2.2 言語進化と言語創発

記号・内的表象はそれ自体、決して物理的に観測しえるものではなく、我々は人間の認識プロセスを説明する為、または、我々の言語活動の心理的基盤として仮想しているに過ぎない。しかし、そのようなものの存在を仮

定することで、人間の認知活動・言語活動を説明しやすくなる為に、その存在を多くの人々が信じている。にもかかわらず、それがどうやって内的に獲得されていくのかはその観測の困難性から、未解決な問題である。近年、言語学研究において、長きに渡り禁忌とされてきた言語進化の研究がなされ始めたが、その多くは社会または母親から子供への伝承時における言語の変化など、すでに分節化された知覚対象のラベル付けの共有についてのモデルが多い[26,12]。これはGOFAIで議論された記号処理的なプロセスでの、多主体間での言語共有を志向している。しかし、言語・記号が常に人間の身体を用いた認知活動と切り離せない存在であることに目を向けると、これ以外にも異なる身体性や経験をする主体がどのように異なる世界の分節化を生成するかという議論も必要である[2,3]。そのような点を補完するためにも、身体を用いた記号創発、ひいては言語創発の研究が期待されている。

## 2.3 内的表象の必要性和記号生成の非線形仮説

我々は記号の必要性は二種類あると考えている。一つは状況を離散的に認識するためであり、もう一つはコミュニケーションのためである。ここでは仮に、前者に相当する記号を内的表象と呼び、後者を外的表象と呼ぶことにしよう。本稿では特にこの内的表象の必要性に焦点を当てる。しかし、内的表象は外的表象の存在の基盤として捉えられる為、本来はその二つの相互作用も重要な論点である。

ところで、内的表象の必要性とは何であろうか。進化的・淘汰的観点から見ると、内的表象を持ち離散的な認識をすることが何らかのパフォーマンスの向上に繋がり生体の生存能力を高めたのではないかと考えられる。その仮定の下、本節では身体能力と記号生成の関係について考える。身体能力の非常に高いもの、もしくは熟練を通して高い身体能力を獲得した人は離散的な認識をする必要も無く高いパフォーマンスを発揮できるのならば、そこに離散的認識の存在意義は無い。また、違いを認識してもパフォーマンスが一向に上がらないほどに身体能力の低い者にとっても離散的な認識の必要性は無いと考えられる。例えば、天才的な野球選手はバッティングの極意を尋ねられたときに「来た球の中心を打てばいい。」などという。これはしばしば球種に関わらず同じ打ち方で対処できる身体能力を持っているからだと考えられている。常人は、カーブ、高め、ストレートなどの離散的認識に従って軌道を予測し打ち分けるが、初心者や絶対的に身体能力の低い人間は逆にそれらを識別したところ打つことができない。身体・効果器のサイズに関して例を言えば、半径3メートルのバットを振る巨人にとっては、カーブやフォークでの変位など誤差に過ぎず、わざわざ区別する必要などない。これに対し、割り箸ほどの細いバットを振るバッターがいれば、どんな球種も同じ

く打てないのでやはり区別は無意味であると思われる。このような離散的識別の有用性という観点から、我々は「境界的な中程度の身体能力を持つものが最も記号的認識を行う」という、身体能力と記号生成についての非線形な関係についての仮説を持っている (Fig.1)。このような離散的認識、つまり範疇の形成が一定の素性群、つまり客観的な基準により決定されるのではなく個人間でゆらぐということは Rosch の族類似の考え方から指摘されているが [25]、その基準がどう主観的に生成されるかは難しい問いである。アフォーダンスにおける研究では古くから、人間の対象認識と身体の関係が議論されてきたが、範疇形成と身体のかかわりについて、解析的に妥当な実験系を組むのは非常に困難であり、研究事例も余り見られない。我々はこのような問題に対してこそ構成論的な接近が有効であると考えている、本稿ではこのような疑問に対し、上のような仮説とともに構成的な接近を試みることにより、認知心理学研究への示唆を与えることをも目指す。

#### 2.4 モジュール機構と言語

現在、上に述べたような心理学的、概念的考察とは別に脳科学や知能ロボットの領域から運動と言語の関係についての議論がなされている。川人らは主に人間の運動をつかさどる小脳のモデルとして順逆モデル (forward-inverse model) が並列に複数個ならんだ MOSAIC という機構を提唱しており [8]、鮫島らはこの MOSAIC に強化学習を適用した MMRL を用いて他者の行動を分節化し自らの学習に利用する模倣学習のモデルを提案している [17]。模倣学習は言語の起源として注目されており、他にも稲邑らが、模倣と記号獲得についてのミメシスモデルを提案している [13]。通常言語は大脳皮質がその役割を担っていると考えられがちであるが、近年、小脳の役割が注目されており、身体を通じた運動と言語の関係が研究されている [18]。

このように運動制御のモジュール機構と記号的認識やコミュニケーションを結びつける考え方は一般的である。自律ロボットのためのモジュール型学習機構としては MOSAIC 以外にも、久保田らの MNN [20] や著者らの Dual-Schemata model [1]、高橋らのモジュール型強化学習 [19] などがある。また、明示的にモジュール化はせずにニューラルネットワーク内部にモジュールのゲーティング機能に相当する競合状態を作りだし、モジュール機構をニューラルネットワーク内部のアトラクタとして分散的に表現する手法として谷らの RNNPB がある [21]。尾形らは、RNNPB を用いて実際に自律ロボットと人間との記号的相互作用を実現している [22]。しかし、その多くは前もって設計者がモジュールの数を与えてしまったり、モジュールの分担領域を決めるパラメータを制御するなどしており、自律ロボットが自らの経験のみを参照し累増的にモジュールを増やすものは少ない。次節で

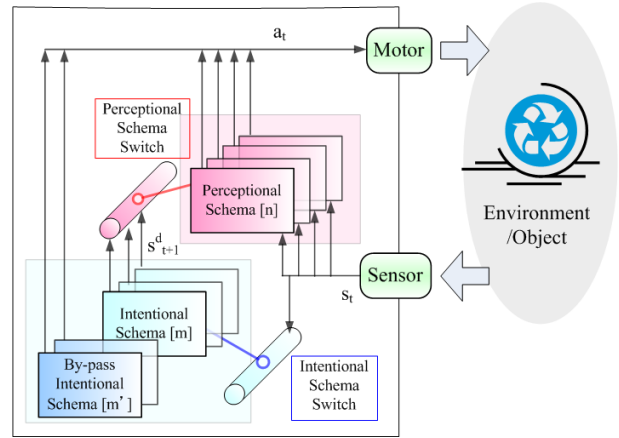


Fig. 2 Dual-Schemata Model

は我々の提案している累増型モジュール学習機構である Dual-Schemata model を導入する。

### 3. Dual-Schemata model

Dual-Schemata model (双シエマモデル) は J.Piaget が人間の発達プロセスを説明する為に提唱したシエマ理論 [11] を元にした、自律ロボットが環境との相互作用を通して環境・対象のモデルに相当するシエマ (概念) を獲得する累増型モジュール学習器である。J.Piaget のシエマはあくまで心理学的なモデルであり、計算論的なモデル化をするには、行為の側面、知覚の側面を敢えて分割したほうが良いと考え、行為の内的表象におけるものを行為シエマ (intentional schema)、対象・環境の内的表象 (内部モデル) にあたるものを知覚シエマ (perceptual schema) として実装した。この二重のモジュール群を持つことが Dual-Schemata model の名前の由来である。他のモジュール学習器との比較において特徴的な点は対象が変化した場合に、あらかじめ設計者によって決められた誤差の閾値は無く、自らが経験した過去の情報との比較で決定される主観的誤差 (subjective error) と呼ばれるパラメータを参照してシエマの分化を行うところにある。故に分化のための誤差の閾値自体は状態空間のスケールに依存せず、さらに自律ロボットの身体性や環境との相互作用の歴史により変化・決定される。我々はこのような特徴が前章において述べたような、自律ロボット固有の Umwelt から内的表象を生成するという言語創発の為のモデルとして適当ではないかと考えている。

文献 [1,4,5] において、我々は Dual-Schemata model を提案したが、本稿ではその定式化を更に進め、Dual-Schemata model 内の知覚シエマと呼ばれるモジュールの内部関数を線形関数に限定することにより、シエマの増加に比例して配置するメモリが累増的に増えていくという問題点を解消したモデルを提案する [2,3]。これを LDS (Light Dual-Schemata model) と呼ぶが、本稿では具体的にはこのモデルを説明し後の実験で用いる。立式の詳細は以前の [1,4,5] Dual-Schemata model と変わる

が、均衡化・分化という基本的ダイナミクスや Fig.2 示したフレームワーク自体は変化しないため、ほぼ同様な動きを期待できる。

### 3.1 自律ロボットの定義

我々はまず、自律ロボットは何かしらかのセンサ系 (sensor) とモータ系 (motor) を持つものと仮定する。それぞれの入出力は毎時有限次元の実数ベクトルで与えられ、それぞれ  $s_t, a_t$  とする。また、自律ロボットは直接的な外部からのセンサ入力のほかに、短期記憶 (short-term memory) などの参照可能な入力を持ち、これを  $v_t$  とし、これにより拡張された入力を  $s_t^\dagger = s_t \oplus v_t$  とする (ここで  $\oplus$  は二つのベクトル空間の直和空間での自然な和を指す)。また、自律ロボットはこれらの値を自らの持つ固有のサンプリングレートで取得、指定するものとし、この一周を  $\tau[s]$  とする。 $s_t$  のような添え字の  $t$  は自律ロボットにとっての離散時間を指し、実際にはこの 1step 間に  $\tau[s]$  の時間が経過しているとする。

### 3.2 知覚シエマ (Perceptual schema)

自律ロボットが自らを取り巻く環境と相互作用する中で、知覚シエマの内部関数はそのダイナミクスを自律的に学習していき、その環境のダイナミクスを表象する存在となる。これは脳神経科学で言うところの内部モデルに相当する。 $n$  番目のインデックスを持つ知覚シエマを  $PS_n$  と呼び、内部関数を持つ。記号論の創始者である C.S.Pierce は「ある主体のある対象についての概念とは主体がその対象に対して行為を行った結果、自らの感覚がどう変化するかということである。」といった [23]。この提言はプラグマティズムの格律 (pragmatism maxim) と呼ばれていが、もし我々が離散時間世界に生活している自律ロボットの立場に立ち、この言葉をロボットが観測できることの実数ベクトルの世界 (自律ロボットの Umwelt) に置き換えるならば、「自律ロボットが働きかける対象の概念とは、三つのベクトル  $s_{t-1}^\dagger, s_t, a_{t-1}$  の関係性である。」ということになる。ただし、これは  $s_t$  が行為  $a_{t-1}$  の結果を表す限りにおいての話であり、行為とその結果をどの時間尺度で見るとかは別の重要な問題である。ここでこの三つ組のベクトルの関係は以下の三つの関数関係によって記述することが出来る。

$$s_{t+1} = F_n(s_t^\dagger, a_t) \quad (1)$$

$$a_t = I_n(s_t^\dagger, s_{t+1}) \quad (2)$$

$$s_t^\dagger = B_n(a_t, s_{t+1}) \quad (3)$$

$F_n$  はしばしば順モデル (forward model) とよばれ、 $I_n$  は逆モデル (inverse model) と呼ばれる場合が多い。自律ロボットにとっての環境のダイナミクスについての概念は、これらの関数によって表象される (三項の関係を正しく予測するかぎりにおいて)。ここで全ての知覚シエマはこれら三つの関数をその内部に持ち、継続的にこれ

を更新し続ける。過去の Dual-Schemata model においてはその内部関数としてあらゆる形の近似器を持つことを許したが (ニューラルネットワークや RBF, GP による関数など)、LDS では内部関数として用いるものは線形関数に限定する。これは、知覚シエマ内部に順モデルと逆モデルをコヒーレントに獲得する為である。よって、 $F_n$  と  $I_n$  は以下のような線形式であらわされると仮定する。LDS において  $B_n$  は特に利用しない。

$$s_{t+1} = F_n(s_t^\dagger, a_t) = F_n^{s^\dagger} s_t^\dagger + F_n^a a_t + F_n^{const} \quad (4)$$

$$a_t = I_n(s_t^\dagger, s_{t+1}) = I_n^{s^\dagger} s_t^\dagger + I_n^s s_{t+1} + I_n^{const} \quad (5)$$

これらの式の中で  $F_n^{s^\dagger}$ ,  $F_n^a$ ,  $I_n^{s^\dagger}$ , と  $I_n^s$  は実数行列であり、 $F_n^{const}$  と  $I_n^{const}$  は実数ベクトルである。

### 3.3 行為シエマ (Intentional Schema)

もう一方のモジュール群は行為シエマ (intentional schema) と呼ばれる。知覚シエマが環境や行為対象の表象として働くのに対して、行為シエマは自らの振る舞い、行為の表象として働く。その具体例については後の実験において示す。 $m$  番目のインデックスを持つ行為シエマは  $IS_m$  と呼ばれ、内部関数として  $G_m$  を持つ。

$$s_{t+1}^d = G_m(s_t^\dagger) \quad (6)$$

この式に於いて  $s_{t+1}^d$  は次の時刻に要求する目標状態 (desired value) としての  $s_{t+1}$  をあらわす。これからもわかるように行為シエマの働きはエージェントの感覚入力を如何に変更していくかという指令値を現在の状態を参照しながら、時々刻々知覚シエマに出力し続けることにある。この様な行為シエマに加え、無知覚行為シエマ (by-pass intentional schema) を定義する。通常の行為シエマは指令値  $s_{t+1}^d$  を知覚シエマに出力し、現在の環境に対応する環境モデルを持つ知覚シエマがそれを実現するための行為出力  $a_t$  を決定して行為系へと出力する。これに対し、無知覚行為シエマは現在の環境のダイナミクスを参照しない完全にフィードフォワードな行為に対応する。つまり、無知覚行為シエマは環境のモデルである知覚シエマを参照することなく直接行為系に  $a_t$  を出力する。無知覚行為シエマは内部関数として  $G_m^\times$  を持つ。

$$a_t = G_m^\times(s_t^\dagger) \quad (7)$$

知覚シエマと異なりこれらの関数は Dual-Schemata model 同様 LDS においても任意の関数を取ることを許される。行為シエマの学習は主に強化学習を用いて行うことが出来、この時、Dual-Schemata model は階層的モジュール型強化学習器と見なすことが可能になる [6]。しかし、本稿では議論を分散させない為に、この学習については論じず行為シエマ自体は設計者が直接与えるものとする。

### 3.4 シェマ状態 (Schema state)

Fig.2 に示したように Dual-Schemata model は知覚シェマ選択器 (perceptual schema switch) と行為シェマ選択器 (intentional schema switch) を持つ．モジュール型学習器では必ずスイッチング (排他的選択) もしくはゲーティング (重ね合わせの為の重み計算) の機構が必要となるが, Dual-Schemata model では排他的な選択を行う．あらゆる時刻において, それぞれの選択器は一つのシェマを選択する．それぞれの選択器がどのようにシェマを選択するかについては後ほど述べる．時刻  $t$  において知覚シェマ選択器が  $PS_n$  を, 行為シェマ選択器が  $IS_m$  を選択したとき, シェマ状態  $ST(t)$  は以下のように定義される．

$$ST(t) = (PS_n(t), IS_m(t)) \quad (8)$$

これらの表記を用いて行動関数  $H$  は知覚シェマ  $PS_n$  に含まれる逆モデル  $I_n$  と行為シェマ  $IS_m$  に含まれる内部関数  $G_m$  を用いて以下のように表現される．

$$a_t = H_{ST(t)}(s_t^\dagger) = I_n(s_t^\dagger, G_m(s_t^\dagger)) \quad (9)$$

ただし,  $IS_m(t)$  が無知覚行為シェマの場合には行動関数は

$$a_t = H_{ST(t)}(s_t^\dagger) = G_m^\times(s_t^\dagger) \quad (10)$$

として, 知覚シェマを用いずに決定される．また, 多くの場合モータ出力には制約があるので,  $a_t$  の成分の  $\pm 1$  を超えた場合には  $\pm 1$  になるように制限する．

### 3.5 均衡化 (Equilibration)

本節では知覚シェマの持つダイナミクスの一つである均衡化のプロセスについて説明する．自律ロボットが時刻  $t$  に於いて三組のベクトル  $s_{t-1}^\dagger, a_{t-1}, s_t$  を獲得したとき, 知覚シェマ  $PS_n(t)$  はその経験を既存のシェマに同化 (assimilation) しようとする．同化と調節 (accommodation) とは J.Piaget のシェマ理論に於いて重要なキーワードである [11]．ここで  $PS_n$  がその経験を同化するか否かは主観的誤差 (subjective error)  $R_n(t)$  に依存する．主観的誤差とは自らが内部に持つ多様性  $\hat{E}$  と, あらたな経験と内部関数の誤差  $E$  の相対的な関係に於いて生じる値である．これを測る為に, 各, 知覚シェマは経験サンプルと内部関数の誤差を測る関数  $E_n(t)$  と, 知覚シェマの持つ多様性を監視する関数  $\hat{E}_n(t)$  を持たねばならない．ここで知覚シェマが内部にもつ多様性  $\hat{E}_n$  とは過去に自らが同化した経験の持つ多様性に他ならない．これは過去の経験が自らの内部モデルの間に生じた誤差の履歴から生じるものであり, 対象・環境が変化しない場合にはこれを用いて次の経験に対し内部モデルがとる誤差の期待値を予測することができると考えられる．つまり, シェマ内部の多様性を示す  $\hat{E}_n$  とは誤差  $E_n(t)$  を予測するための, 誤差予測モデルとして定義できる．以

前の Dual-Schemata model では誤差計測に逆モデルを用いていたのに対して, LDS では順モデルを用いて誤差を計測する．

$$E_n(t) = |s_t - F_n(s_{t-1}, a_{t-1})|_{each} \quad (11)$$

ここで,  $|\dots|_{each}$  ベクトルの各成分ごとに絶対値を取ることを意味する．たとえば  $|v|_{each} = |(v_i)|_{each} = (|v_i|)$  となる．ここで  $E_n$  がスカラーではなく, ベクトルであることに注意が必要である．

また, 誤差予測にシェマ状態毎に分散的にメモリを配置し, 過去の誤差の平均値を用いていたのに対し, LDS では各知覚シェマに誤差予測の為の線形モデルを持たせる．

$$\hat{E}_n(t) = \hat{E}_n^s \dot{s}_t + \hat{E}_n^{const} \quad (12)$$

$$\dot{s}_t = \frac{1}{\tau} * |s_{t+1} - s_t|_{each} \quad (13)$$

ここで  $\hat{E}_n^s$  と  $\hat{E}_n^{const}$  はそれぞれ各成分非負の行列と実数ベクトルである．また  $\tau[s]$  は離散時間ステップ巾をあらわす．順モデルが環境のモデルを近似しきれていない度合いを示す．主に,  $\hat{E}_n^s$  はモデル化誤差,  $\hat{E}_n^{const}$  は環境に含まれる定常的なノイズ等に相当する．近似は慣性項付きの勾配法によってまず線形項のみのモデルとして近似し, 残差を定数項で近似しそれらを足し合わせることににより更新する．この誤差予測モデル  $\hat{E}_n$  は  $\dot{s}_t$  と  $E_n(t)$  の関係を時々刻々と近似し続ける．これらの関数を用いることにより, 主観的誤差  $R_n(t)$  は以下のように算出される．これは新たな経験に対する誤差と過去の経験についての誤差の比で計算される無次元量である．

$$R_n(t) = \|\text{diag}(\hat{E}_n(t))^{-1} * E_n(t)\|_\infty \quad (14)$$

$\text{diag}(*)$  は  $*$  を対角成分とした対角行列である．もし  $R_n(t) \leq k$  ならば知覚シェマ選択器により選択されていた知覚シェマ  $PS_n$  は時刻  $t$  で経験を自らに同化する．同化されない経験は廃棄される．ここで  $k$  は同化の為の閾値であり, 同化係数 (assimilation threshold) と呼ぶ．上記の同化を繰り返す中で  $PS_n$  の内部で定義された順モデルは自らが同化した新たな経験に合うように更新し続ける．これが調節のプロセスである．これらの繰り返して行われる二組の操作は全体として均衡化 (equilibration) のプロセスと呼ばれる．この更新には慣性項付きの勾配法を用いる．慣性項が記憶の役割を果たす．逆モデル  $I_n$  は  $F_n$  が線形であるために  $F_n^a$  の逆行列, もしくは擬似逆行列を求めることによって算出することが出来る．

### 3.6 分化 (Differentiation)

知覚シェマ選択器は知覚シェマ活性度  $V_n(t)$  と呼ばれるパラメータに従って, どのシェマを選択するか, または新たにシェマを生成するかを決定する．知覚シェマ活性度  $V_n(t)$  は自律ロボットが現在対面している環境のダ

イナクスに対して各知覚シマが自らとそれとがどれだけコヒーレントかを示す変数である。  $V_n(t)$  は主観的誤差に従って毎時以下の式によって更新される。

$$V_n(t+1) = p * V_n(t) + (1-p) * \exp(-\frac{1}{2} R_n(t)^2) \quad (15)$$

$p$  は定数でどれだけ過去の活性度に固執するか (persistence) を表す。通常  $V_n = 0$  は「現在の環境は  $PS_n$  に対応していない」ことを示す。また、 $V_n = 1$  は「現在の環境が  $PS_n$  に対応している」ことを示す。知覚シマ選択器はこの知覚シマ活性度を参照しながら以下の法則に従い知覚シマを選択する。

- (1) もし全ての知覚シマの活性度が予め定めた閾値  $V_{turn}$  を上回らなければ、知覚シマ選択器は新たな知覚シマを作り出す。新たな知覚シマは現在の総数が  $N$  個の場合  $PS_{N+1}$  と名づけられる。
- (2) 知覚シマ選択器は知覚シマ活性度が  $V_{turn}$  以上のものの中から、最も古いものを優先して選択する。

このようなルールに従う事により知覚シマ選択器は知覚シマを選択・作成していくことが出来る。新たなシマは元のシマの内部関数と十分に大きな  $\hat{E}$  (多様性) を与えられる。 $V_{turn}$  は  $V$  についての閾値であるが、「誤差  $E$  がどれほどであれば、他のシマを選択するか」という誤差についての閾値は  $\hat{E}$  との相対的關係、すなわち、過去の経験の履歴や自律ロボットの持つ身体性に依存して相対的に決定される。故にこの選択のアルゴリズムは「誤差最小のモジュールを選択する」というものでは決してない。また、通常は  $V_{turn} = \exp(-\frac{1}{2} k^2)$  に設定する。

#### 4. 実験

本章では LDS をボール追跡を学習する過程でシマの分化を行うロボットのシミュレータに適用した実験を示す。過去の論文 [1,4,5] で、我々は Dual-Schemata model を実ロボットに適用した。このロボットは pan, tilt の二自由度と二基の CMOS カメラを持っており、壁面に投影された青球を追跡するというタスクを与えられた。この実験のなかでロボットは 4 種類のボールの動き (静止, 横運動, 縦運動, 円運動) を追うことが出来るようになった上に、これらの 4 つの動きに対応する形で自らの知覚シマを 4 個に分化させた。

しかし、過去の研究の中では、シマの分化は人間のもつ 4 つの運動状態概念に対応するように生成されたのを観察したのみであり、自律ロボット固有の身体性から生じる Umwelt との関わりについては議論しなかった。Dual-Schemata model で仮定しているような、自己閉鎖的な系が概念分化を行う時、それが何を区別して学習するかはその外部との相互作用の仕方に深く依存する。しかし、その相互作用は常に自らの身体の支配下にある。




Fig. 3 Physical Environment




Fig. 4 Sensory Input

つまり、身体のサイズ・性能の違いが概念の分化に影響を与えるはずである。2章で述べたように、我々現実の生体においても身体の違いが概念形成の違いを生み出すと考えられており、実験の結果が人間や動物の概念生成のプロセスと符合しているかが注目される。

本論文に於いては [1,5,4] と類似した環境を計算機シミュレーション環境下に設計し、同様のタスクを異なる身体性を持ったロボットに与えることにより、身体性とシマ分化の関係を見る。

##### 4.1 実験環境

シミュレーションについて説明する。Fig. 3に於いて小さいほうの球は壁面に射影されたロボットのカメラの焦点を示す。ここでその位置座標を  $(q^{pan}, q^{tilt})$  とする。次に薄いほうの四角形はカメラの視野を示す。その一辺は  $2 \times VA[\text{cm}]$  とする。  $VA$  は視角 (visual angle) を意味する。また、実際の pan-tilt カメラは二つの自由度について有限の可動域を持つ。ゆえにそれに従い、ロボットはその焦点の動きも制限される。Fig. 3において暗いほう (後方) の四角形は焦点の可動域を示す。その縦横はともに  $200[\text{cm}]$  に設定し、その中心の座標を  $(0,0)$  とした。大きいほうの球は追跡対象の球を意味し、その座標は  $(B_x, B_y)$  とする。Fig. 4はロボットが得ることの出来るセンサー入力  $s_t$  を簡単に示している。ロボットは自らの視野内における主観的なボールの位置座標以外の情報は知ることが出来ない。もしロボットが動けば例えばボール自身が静止していてもその座標が動くということは注意しなければならない。また、もし球が視野外に出た場合には、出る寸前のボール位置の方向にカメラの

中心から  $\sqrt{2}$  の距離にあるものとして与える．また，観測ノイズとして標準偏差  $5.0 \times 10^{-3}$  のガウスノイズを乗せる．次に，モータ出力を  $a_t = (u_t^{pan}, u_t^{titt})$  と定義する．また，短期記憶による入力として  $v_t = (s_{t-1}, a_{t-1})$  を与える．ロボットの焦点 ( $q_t^{pan}, q_t^{titt}$ ) は以下の式に従って移動する．

$$\frac{d}{dt} q_t^{pan} = gain * u_t^{pan}, \frac{d}{dt} q_t^{titt} = gain * u_t^{titt} \quad (16)$$

ここで  $gain$  はモータ出力のゲインを表す定数である．本実験では  $5[m/s]$  とする．行為シエマは環境との相互作用を通じて強化学習等の手法を用いて獲得させる手法を既に提案しているが [6]，本稿の本題ではないので設計者が Table 1. に従い与えることにする．ここで  $\delta(t)$  は乱数ベクトルである．その各要素は標準偏差 1 のガウスノイズである．Table. 1 の中で本実験において特に重要なのは *chase mode* である．また，*random mode* や *browse mode* は当実験に於いて，知覚シエマが学習を進める上での *exploration* の役割を担う．知覚シエマの均衡化が完了したとき，このシエマはボールを追跡する行為を発現する．なお，この実験に於いて同化係数  $k$  は 2.3,  $V$  の更新に用いる  $p$  は 0.8 に固定する．

Table 1 Intentional Schemata

Index	Name	Inner function
$IS_0$	Random mode	$a_t = G_0^x \equiv 0.5\delta_t$
$IS_1$	Chase mode	$S_{t+1}^* = G_1(S_t) \equiv (0,0)$
$IS_2$	Browse mode	$S_{t+1}^* = G_2(S_t) \equiv 0.5\delta_t$

## 4.2 実験内容

本実験ではロボットに様々な身体的パラメータを設定することにより，ロボットの持つ身体性と記号創発の関係性を考察する．シミュレーション環境では我々は様々な身体パラメータを持ったロボットを用意することが出来る．カメラの視野について二通りの身体パラメータを与えた例を Fig.3 に与える．まず，Table.2 に示すように対象球の運動状態を定義する．なお，本実験では  $\omega = 10[rad/s]$  に固定する．これらは我々の目には異な

Table 2 Movement of target ball

Mode	Name	Dynamics
$M_0$	Pause	$(B_x, B_y) = (0,0)$
$M_1$	Horizontal	$(B_x, B_y) = (60\cos(\omega t), 0)$
$M_2$	Vertical	$(B_x, B_y) = (0, 60\sin(\omega t))$
$M_3$	Circularly	$(B_x, B_y) = (60\cos(0.5t), 60\sin(\omega t))$

るダイナミクスを持つとして捉えられる 4 つの動きである．しかし対象に関わる自律ロボットにとってのダイナミクスとは，あくまで主体の観測可能なセンサ情報とそれに働きかけられるモータ情報とのかかわりあいの中

で見出されるものである．身体性が我々と異なるロボットが我々と同様な分節化を行うとは限らない．実験は  $1000[s]$  を一つの単位とし， $250[s]$  毎に球の運動モードを  $M_1$  から  $M_4$  へと周期的に変更した．また，行為シエマについては  $50[s]$  を一つの単位とし， $20[s]$  の間  $IS_0$ ，次の  $20[s]$  の間  $IS_1$ ，そして最後の  $10[s]$  の間  $IS_2$  という動作を繰り返させた．この試行を  $10000[s]$  行い，最後の  $2000[s]$  については均衡化のダイナミクスを止めて獲得されたシエマの性能について調べた．この時，様々な身体パラメータを持つロボットに対し，同じ環境の変化と行為シエマによる決定をさせているにもかかわらず，その結果として異なったシエマ分化が行われた場合には，それは身体パラメータに原因していると考えられる．

## 5. 結果と考察

この実験に於いて，変更することの出来るロボットの身体パラメータは多く存在するが，議論を分散させない為にカメラの視角  $VA$  とロボットの行動周期  $\tau$  に限定して議論を行う．これらはそれぞれ空間と時間について自律ロボットが持つ身体的リソースを決定する重要なパラメータである．紙面の都合上，追跡学習の収束過程についての議論は省略するが，均衡化自体は教師ありのモデル学習であるので，強化学習などに比べると非常に速い学習スピードを持ち，静止球の追跡については初めて *chase mode* をとってから数秒で追跡が可能になった．

### 5.1 シエマ分化のプロセス

毎  $1000[s]$  の間に，対象球の運動状態毎に，その運動状態のときに自律ロボットがとった知覚シエマ状態のインデックス  $n$  についての時間平均値の一例を Fig.5 に示す．もし，ある運動状態が常に  $n$  番目の知覚シエマに受け持たれるようになった場合，この値は  $n$  になる．よってこのグラフは各運動状態が別々のシエマに受け持たれていく様子を表している．このグラフは  $VA = 100[cm]$  で  $\tau = 0.1[s]$  の時のものであるが，このグラフから，この時 4 つの運動状態が自律ロボット内でシエマの分化を通じて分散的に記憶されていくのが分かる．また，Fig.6 に知覚シエマの内部関数である  $F$  の係数行列  $F^{\dagger}$  の 1 行 1 列目の成分を  $1000[s]$  までプロットしたものを示す．安定的な推移はしないが内部関数の係数パラメータの視点からも分化の様子が分かる．

### 5.2 身体性と記号生成

我々は Dual-Schemata model の分化の仕組みに基づいた表象生成の身体依存性を調べる為に，前章で述べたシミュレーションを  $\tau = \{1/32, 1/16, 1/8, 1/4, 1/2\}$  及び  $VA = \{40, 60, 80, 100, 200, 400\}$  の  $5 \times 6$  の 30 組の組み合わせについて行った．そのときそれぞれどれだけの知覚シエマが分化されたかについて考察する．しかし，知覚シエマの個数と一言で言っても，その中には生成さ



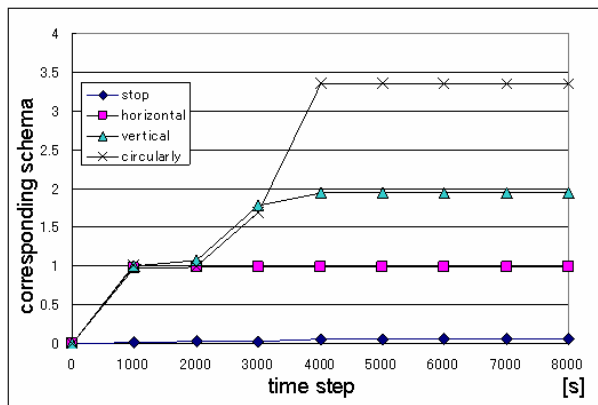


Fig. 5 differentiation process of perceptual schemata




Fig. 6 differentiation process of perceptual schemata's inner function parameter

れたものの  $\hat{E}$  が偶発的に小さくなりすぎて選択されなくなるものなど、作られたものの使われないうで放置されるものも度々現れる．このようなものは数えずに、分化したシエマの中で利用されるものだけを数えることにする．これを測る為に、生成されたシエマの個数に対応するパラメータを情報エントロピを用いて計算する．均衡化終了後のシエマ利用期間となる 8000[s] ~ 10000[s] の間で知覚シエマ選択器により  $PS_n$  が選択された確率を  $P(PS_n)$  とする．これを用いて、知覚シエマの選択についての情報エントロピ  $S$  と擬似シエマ数 (pseudo-number of schemata)  $M$  を以下のように定義する．ただし、この時シエマ選択のルールは 3.6 節で導入したルールをそのまま用いる．

$$S(PS) = \sum_{PS_n} -P(PS_n) \log(P(PS_n)) \quad (17)$$

$$M(PS) = \exp(S(PS)) \quad (18)$$

こうすると  $M$  は各シエマが満遍なく使われた場合のシエマの数に一致する．これを分化したシエマの数のパラメータとして利用する．このとき、各身体パラメータについての  $M$  は Fig. 7 のようになる．ここでは、視野が小さいときにも大きいときにも分化したシエマは少なく、中程度で最も多い．また、時間解像度についても小さいときと大きいときにはシエマは多くは生成されず、中程度に於いて最も多く生成される．これは、ちょうど 2.2 節において我々が仮説として挙げた身体性と記号生成についての非線形な関係を表している．つまり、記号生成につ

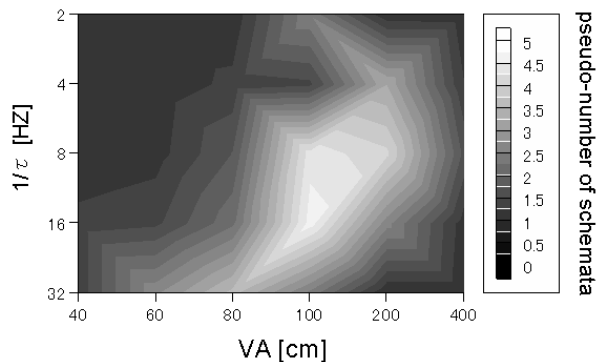


Fig. 7 relationship between spatiotemporal resources and pseudo-number of perceptual schemata

いて我々の仮説を認めるとするならば、Dual-Schemata model はその構成論的なモデルとなっているといえる．しかし、Fig. 1 にあげた中での記号生成時のパフォーマンス向上についてはこのグラフは何も言っていない．次節では、シエマ分化とパフォーマンスについて考察する．

### 5.3 内的表象によるパフォーマンスの向上

モジュール化されない内部モデルは新たな環境に対面したときに、古い記憶が上書きされてしまう為に、もとも環境に戻った時に一から再適応しなおさなければならないという非効率性がある．つまり、モジュール化つまり内的表象の利点とは、異なると判断したダイナミクスを別々のモジュールに割り当てることにより、記憶の保持を行う点にある．そこで、静止球についてこのような割り当てを知覚シエマ選択器が上手く行えているかと、そのときの静止球追跡のエラーを比べることによって内的表象生成とパフォーマンスの関係について考察する．上のような割り当てが上手く出来ているかどうかを測る為に、相互エントロピを導入する．相互エントロピは通信路が情報をどれだけ欠損せずに送っているかを調べる指標である．今、集合  $X, Y$  に対する確率分布  $p(x), q(y)$  と同時確率分布  $r(x, y)$  があった時、相互エントロピ  $I$  は

$$I(X, Y) = \sum_{x, y} r(x, y) \log \frac{r(x, y)}{p(x) \times q(y)} \quad (19)$$

で定義される． $M$  と同様に  $N = \exp(I)$  がその通信路の擬似的なチャンネル数に相当する．今  $X = \{M_0, M_{other}\}, Y = \{PS_0, PS_1, \dots\}$  として、パフォーマンスの指標となるカメラ焦点と対象球の距離の時間平均の逆数  $error^{-1}$  と共に Fig. 8 に示す．ちょうど静止球を他の球と識別する領域において、分化を行わない場合に比べてパフォーマンスが向上していることが分かる．このグラフ関係はちょうど Fig. 1 と重なり合う．Fig. 8 において、十分視野の広い領域においてパフォーマンスが落ちているのは、カメラの視野によるメリットよりもカメラ入力にのるノイズの大きさの方が大きな影響を与えた為と考えられる．これらのことより、Dual-Schemata model は我々の考え

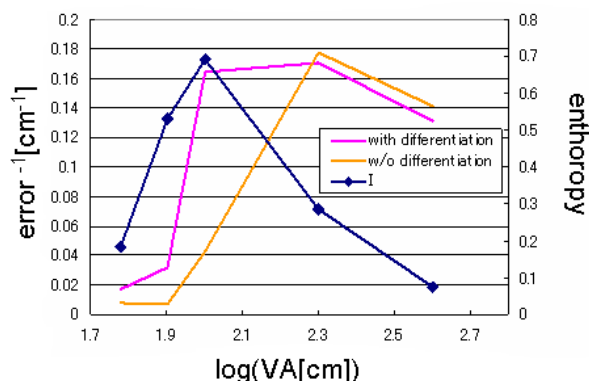


Fig. 8 Performance and Modularity

る身体パラメータと記号生成についての非線形仮説を満たす構成論となっていることが分かる。

## 6. まとめ

本稿では、身体性と自律ロボット内部での記号創発の関係について考察した。我々の提唱モデルである Dual-Schemata model の修正版である LDS を導入し、様々な身体パラメータを持つ顔ロボットにシミュレーション空間内で実装し四種類の物理的なダイナミクスを持った運動球と相互作用をするなかで知覚シマの組織化を行わせた。その結果、身体パラメータが高すぎる場合も低すぎる場合も余りシマの分化は行わず、中程度の時に最も多く分化するという非線形な結果を得た。単純に考えると、多くの情報を得ることが出来る身体を持っていれば多くの記号を獲得すると考えられがちであるが、必ずしも多くの記号を持つことが主体にとってメリットになるわけではない。主体は自らの身体に合った形で世界を分節化して初めてその恩恵を受けることが出来るのである。しかし、このようなことを構成論的な方法以外で追及することは、現時点では困難である。内的表象は計測されるものでは無く内観を通してしか認識されないものだからである。しかし、本稿 1 章でも述べたように、人間の行う記号の解釈活動をどう考えるかは知能ロボット研究にとっても重要な課題であり、多角的な研究が望まれる。

## 謝 辞

貴重なご意見を頂いた多くの討論者、特に京都大学工学研究科デザインシステム論研究室と京都自律適応系研究会のメンバーに感謝します。また、本研究は 21 世紀 COE プロジェクト「動的機能機械システムの数理モデルと設計論」の一部として遂行いたしました。

## 参 考 文 献

- [1] 谷口, 榎木: 双シマモデル; 人工知能学会論文誌, Vol.19, No.6, pp.493-501 (2004)
- [2] T. Taniguchi, T. Sawaragi: Design and Performance of

- Symbols Self-Organized within an Autonomous Agent Interacting with Varied Environments; *IEEE International Workshop on RO-MAN*, (2004)
- [3] T. Taniguchi, T. Sawaragi: Self-Organization of Inner Symbols for Chase: Symbol Organization and Embodiment; *IEEE International Conference on SMC 2004 CD-ROM*, (2004)
- [4] T. Taniguchi, T. Sawaragi: Assimilation and Accommodation for Self-organizational Learning of Autonomous Robots: Proposal of Dual-Schemata Model; *IEEE International symposium on CIRA 2003*, pp. 277-282, (2003)
- [5] T. Taniguchi, T. Sawaragi: An Approach of Self-Organizational Learning System of Autonomous Robots by Grounding Symbols through Interaction with Their Environment; *SICE Annual conference 2003*, pp.2259-2264, (2003)
- [6] 谷口, 榎木: 顔ロボットの移動物追跡のための運動記憶の動的構成による環境適応, *SICE システム・情報部門学術講演会 2004 講演論文集*, pp.185-190, (2004)
- [7] S. Harnad: The symbol grounding problem; *Physica D*, Vol.42, pp.335-346, (1990)
- [8] D. M. Wolpert and M. Kawato: Multiple paired forward and inverse models for motor control; *Neural Networks*, Vol. 11, pp.1317-1329, (1998)
- [9] Terrence W. Deacon: *The Symbolic Specoes: The co-evolution of language and the brain*, W W Norton & Co Inc (1997) (金子隆芳 訳: 「ヒトはいかにして人となったか」, 新曜社, (1999))
- [10] R. Pfeifer, C. Scheier: *Understanding Intelligence*, The MIT Press, (2001) (石黒, 細田, 小林 訳: 知の創成, 共立出版 (2001))
- [11] John H. Flavell: *The Developmental Psychology of Jean Piaget*: Van Nostrand Reinhold, 1963, (岸本 訳: ピアジェ心理学入門, 明治図書, (1969))
- [12] 橋本: 言語進化とはどのような問題か? ~ 構成論的な立場から; 第 18 回日本人工知能学会全国大会予稿集, in CD-ROM, (2004)
- [13] 稲邑, 中村, 戸嶋, 江崎: 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)
- [14] 丸山: *ソシュールを読む*, 岩波書店, (1983)
- [15] J.J. Gibson: *The Ecological Approach to Visual Perception*, Houghton Mifflin Company, (1979) (古崎, 辻, 村瀬 訳: ギブソン 生態学的視覚論, サイエンス社, (1985))
- [16] J.V. Uexkull, G. Kriszat: *Streifzüge Durch die Umwelten von Tieren und Menschen Bedeutungslehre*, Verlag GmbH, (1970) (日高, 野田 訳: 「生物から見た世界」, 思索社, (1973))
- [17] 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; *電信情報通信学会論文誌 D-II*, Vol. J85-D-II, No.1, pp.90-100, (2002)
- [18] 今水, 銅谷, 二見, 小椋, 田邊, 斉藤, 山鳥, 大津: *運動と言語, 認知科学の新展開 (3)*, 岩波書店, (2001)
- [19] 枝澤, 高橋, 浅田: 複数学習器を用いたマルチエージェント

ト環境における行動獲得; 第22回日本ロボット学会学術講演会, in CD-ROM (2004)

- [20] N. Kubota, D. Hisajima, et al.: Fuzzy and Neural Computing for Communication of a Partner Robot; Journal of Multi-Valued & Soft Computing, Vol. 9, pp.221-239, (2003)
- [21] J.Tani, M.Ito,Y.Sugita: Seif-Organization of Distributedly Represented Multiple Behavior Schemata in a Mirror System:Reviews of Robot , s Using RN-NPB; Neural Networks, Vol.17, pp.1273-1289 (2004)
- [22] 尾形, 菅野, 谷: 動作プリミティブを介した人間とロボットの協調; 第22回日本ロボット学会学術講演会, in CD-ROM (2004)
- [23] 笠松, 江川: プラグマティズムと記号学, 勁草書房,(2002)
- [24] 川人, 佐々木, 他: 運動, 岩波講座認知科学(4),(1994)
- [25] John R. Anderson: Cognitive Psychology and its Implications, W.H.Freeman and Company, (1980) (富田, 増井, 他訳:認知心理学概論, 誠信書房,(1982))
- [26] Luc Steels: Evolving grounded communication for robots, Trends in Cognitive Science, 7(7), pp. 308-312.(2003)
- [27] Evolution of Communication and Language Using Signals, Symbols, and Words IEEE Transactions on evolutionary computation, Vol. 5, No. 2,(2001)

## 著者略歴

谷口 忠大 (学生会員)



1978年6月24日生。2003年3月京都大学大学院工学研究科精密工学専攻修士課程修了。同年4月同専攻博士課程に進学し現在に至る。2003年度から21世紀COEプロジェクト「動的機械システムの数理モデルと設計論」若手研究助成対象者。2005年度から日本学術振興会特別研究員。ボトムアップな記号組織化, 意味生成に注目し, 自律適応システム設計論の研究に従事。日本人工知能学会, 日本認知科学会, 計測自動制御学会, 日本神経回路学会, などの会員。

榎木 哲夫 (正会員)



19XX年X月XX日生。1986年京都大学大学院工学研究科博士課程指導認定退学。同専攻助手。1994年同専攻助教授, 2002年同専攻教授。その間, 1991~1992年米国スタンフォード大学客員研究員。京都大学工学博士。現在, 人間機械共存環境下での協調システムの設計・解析と知的支援等に関する研究に従事。工学博士。計測自動制御学会学術奨励賞, 論文賞, 著述賞, 等受賞。計測自動制御学会, IEEE などの会員。