

幼児エージェントモデル集団における世代学習とその特徴

上野 祐輝^{†1} 菅原 俊治^{†1}

社会における人の幼児期の学習特性を模し、語彙を学習する幼児エージェントの集団での学習モデルを提案する。これまで親から子へ伝える世代学習をモデル化し、語彙の学習の過程をモデル化する研究がなされてきた。しかし、家族や周囲のコミュニティの中で影響を受けながら言語や語彙の獲得は行われる。本研究では、親から子へ伝える世代学習を基礎としながら、子同士に空間的な距離に応じた学習を行わせ、社会的な条件を加味した状況をモデル化し、その中でエージェントの語彙学習の特徴を調べる。実験の結果、単一系の世代学習に比べて言語が構造化されるまでの期間が短いことが分かった。また、直系の親や近隣の親からの影響のみで子同士の影響がないと、言語の構造化に時間がかかることも分かった。

Model of Generational Learning by Infant Agents in a Polyphyletic Group and its Characteristics.

YUKI UENO^{†1} and TOSHIHARU SUGAWARA^{†1}

We propose a model of infant agents with the ability of generational learning in a polyphyletic group and investigate its characteristics using simulation. Infant agents are those that imitate a learning bias in infancy and learn the vocabulary in a virtual social group. Recently, a number of studies that proposed the models of an infant agent that learns the vocabulary or language with interactions between the parent and its infants/children, that is, monophyletic evolution, and evaluate them using computational simulations are conducted. Languages, however, evolve in infants with interacting with other infants in a human's social group. In our proposed model, infant agents learn languages from other infants in the same generation as well as being told by their parents in order to implement polyphyletic evolution by generational learning in the society of infant agents. We then investigate the characteristics of generational learning in a polyphyletic group by comparing those in a monophyletic group. Our experimental results shows that language learning in the polyphyletic group is more efficient.

1. はじめに

言語は人の集団における、人と人との関係によって獲得され、変化する。特に言語学の分野では、言語のクレオール化と呼ばれる現象がある¹⁾。これは、異なる言語を話す人々が植民地などに集められ、それらの言語の混交が起こり、世代を経るにつれて、半ば独自の言語に発達していくことである。センガスらの研究²⁾⁻⁴⁾によると、ニカラグアで初めて聾学校が創設されたのち、それまでバラバラだった聴覚障害者のジェスチャーが、数世代で一定のルールに則った手話に変化した。このとき、手話を洗練された形に発達させていったのは、中等学校などのある程度歳を経た子らではなく、小学校以下の若い世代によるものだった。

手話に限らず、人の若い世代、特に幼児は語彙爆発と呼ばれるほど急激に語彙を学習する⁵⁾。生後 18ヶ月前後からみられるこの特徴について、認知心理学の分野ではさまざまな仮説が立てられ、それを元にさまざまな計算機シミュレーションが行われている⁶⁾⁻¹⁰⁾。例えば 9) では、経験を通じて語彙を学習する幼児エージェント (Infant Agent: 以下 IA) に幼児だけでなく成人にもみられる非論理的推論の傾向性 (対称性バイアス) を導入し、それにより幼児の語彙学習の傾向性 (学習バイアス) について示している。また 10) では 9) のモデルを拡張し、ノイズが多く含まれる環境における幼児の学習バイアスの導出を行っている。しかし、これらはあくまで親と子の単一系の関係のみに着目しており、集団における言語学習の効果を考慮していない。

そこで本論文では 10) の、経験を通じて語彙を学習する幼児エージェントの拡張モデル (以下 exIA モデル) のエージェント集団を構築し、直系の親への依存度、および子同士の空間的な距離に応じて学習を行わせる学習モデルを提案する。また、提案モデルにおける語彙学習の特徴について実験を行った。実験の結果、子同士の学習を導入することで学習効率 (収束性) が上がるが、直系以外の親からの学習を導入しても収束は早まらないことがわかった。

本稿の構成は以下の通りである。第 2 節で関連研究について述べ、第 3 節で言語および IA の定義について説明をする。次に提案モデルの概要と複数 IA の学習環境について述べる。第 5 節で実験の結果と考察について述べ、学習中のエージェント同士の相互作用が特に重要であることを示す。

^{†1} 早稲田大学大学院 基幹理工学研究所 情報理工学専攻

Department of Computer Science and Engineering, Waseda University

2. 関連研究

上述のように、認知心理学などの分野の仮説に基づき、さまざまなシミュレーション実験が行われている。例えば6)では、幼児の語彙獲得の過程を周囲の大人の発話と、感覚器官からの情報による教師付き学習とみなし、帰納論理プログラミングで学習を行うモデルを提案している。このモデルでは、学習対象に関する概念や特徴について明示的に与え、対象が含まれる概念など階層的に学習を行っている。8)では、7)のKirbyモデルを拡張したモデルを提案している。Kirbyモデルは、言語が意味表現を意味する内的な言語と音(文字)列として表出された外的言語の二つからなるという仮説に基づき、エージェントからエージェントへの語り聞かせによる文法の学習モデルである。親エージェントから子エージェントへの内的言語と外的言語の二つを渡し、子エージェントは外的言語がどのようなルールで構築されるのかを学習していく。8)では、後述する対称性バイアスによる言語学習が、Kirbyモデルにおける構文獲得においても有効であるということを示している。9)では対称性バイアスから幼児の学習の傾向性を導けることを示し、10)では9)を拡張しより多くのノイズが含まれる場合においても同様の結果を導けることを示し、実環境におけるロボットの言語獲得への応用についても考えている。しかしこれらの研究は単一エージェントもしくは単一システムのエージェントのつながりのみに着目している。

一方マルチエージェントシステムの研究では、言語学習ではないが、エージェント間の相互作用や社会性に着目し、社会的ルール(ノルム)の獲得に関する研究がある。例えば12)ではエージェントを格子状に配置し、エージェント間の距離に基づく相互干渉から集団学習によるノルムの形成について検証している。本研究でも幼児エージェントを格子状に配置し、その相互干渉と学習への影響を調べる。

3. 言語に関する概念とIAに関する定義

3.1 学習バイアスと対称性バイアス

学習バイアスとは、幼児が言語を学習する際に見られる思考の制約・傾向性である¹³⁾。様々なバイアスが存在するが、IAは主に形状が似通った対象に単語の適用範囲を広げる傾向性(形状類似バイアス)により、語彙を学習する。対称性バイアスは、人の非論理的推論の傾向性であり、「AならばB」という前提から「BならばA」という推測を導く¹⁴⁾。これは論理的に間違っているが、人間以外に見られない傾向性である¹³⁾。幼児は学習バイアスを対称性バイアスから導いている、という仮説があり、9)、10)ではこの仮説をもとに語彙を学

習するエージェントに対称性バイアスを導入し、学習バイアスを導いている。

3.2 言語と学習

IAに示す対象 o は色属性 c と形属性 f を持つとする。色属性の集合は $C = \{c_0, c_1, c_2, \dots\}$ 、形属性の集合は $F = \{f_0, f_1, f_2, \dots\}$ と表し、対象集合を $O = \{o | o \in C \times F\}$ と定義する。

全ての対象には一つの単語が付与されるものとし、この単語をラベルと呼ぶ。ラベル集合を $L = \{l_0, l_1, l_2, \dots\}$ と表す。ここでは言語とは、対象とラベルの対応関係のことであり、 $Lang: O \rightarrow L$ と定義する。

また、IAは経験を通して、

・「ラベル l は対象 o である」という確信度

・「対象 o はラベル l である」という確信度

という二つの確信度を形成する。このときの確信度の形成過程を語彙学習と呼ぶ。前者の確信度をラベルに共通する属性を持つことから共通度、後者を、対象に固有のラベルが与えられることから固有度と呼ぶ。

4. 提案モデルと学習環境

4.1 exIAモデルの概要

exIAは9)のIAを拡張し、情報にノイズを含むことを考慮したモデルである。exIAは1ステップ毎に“ N 個の対象を眺めている状況の中で m 個のラベルを聞く”という経験を行い、これを繰り返す。ただし $m < N$ とする。またどのラベルがどの対象を示すのか、明示的に与えられることはない。これらの経験から、対象 o_h の持つ色属性が c_i 、形属性を f_j とすると、ラベル l_k を聞いたときに色属性 c_i を見た確率 $V(c_i|l_k)$ と色属性 c_i を見たときにラベル l_k を聞いた確率 $V(l_k|c_i)$ 、ラベル l_k を聞いたときに形属性 f_j を見た確率 $V(f_j|l_k)$ と形属性 f_j を見たときにラベル l_k を聞いた確率 $V(l_k|f_j)$ をそれぞれ記憶する。また、このときラベル l_k 以外に聞いたラベルを l_{ka} と表す。exIAではノイズが情報に含まれることを想定しているため、正しくない情報が含まれる可能性のある複数のラベルを聞くとき、同時に聞いたラベルに関しては過度な学習が行われないう補正をかける。ただし、 V_C, V_F の初期値はnullとし、 α は学習率で $0 \leq \alpha \leq 1$ である。

$$V_C(c_i|l_k) \leftarrow V_C(c_i|l_k) + \alpha[r - V_C(c_i|l_k)] \quad (1)$$
$$r = \begin{cases} 1, & l_k \text{を聞き } c_i \text{を見たとき} \\ 0, & l_k \text{を聞き } c_i \text{を見なかったとき} \end{cases}$$

$$V_C(l_k|c_i) \leftarrow V_C(l_k|c_i) + \alpha[r - V_C(l_k|c_i)] \quad (2)$$

$$r = \begin{cases} 1, & c_i \text{ を見て } l_k \text{ を聞いたとき} \\ V_C(l_k|c_i), & c_i \text{ を見て } l_k \text{ を聞かず } l_{ka} \text{ を聞いたとき} \\ 0, & c_i \text{ を見て } l_k \text{ も } l_{ka} \text{ も聞かなかったとき} \end{cases}$$

$$V_F(f_j|l_k) \leftarrow V_F(f_j|l_k) + \alpha[r - V_F(f_j|l_k)] \quad (3)$$

$$r = \begin{cases} 1, & l_k \text{ を聞き } f_j \text{ を見たとき} \\ 0, & l_k \text{ を聞き } f_j \text{ を見なかったとき} \end{cases}$$

$$V_F(l_k|f_j) \leftarrow V_F(l_k|f_j) + \alpha[r - V_F(l_k|f_j)] \quad (4)$$

$$r = \begin{cases} 1, & f_j \text{ を見て } l_k \text{ を聞いたとき} \\ V_F(l_k|f_j), & f_j \text{ を見て } l_k \text{ を聞かず } l_{ka} \text{ を聞いたとき} \\ 0, & f_j \text{ を見て } l_k \text{ も } l_{ka} \text{ も聞かなかったとき} \end{cases}$$

次にこれら式 (1) ~ (4) をボルツマン分布を用いて正規化し、共通度と固有度を求める。色に関する共通度を $B(c_i|l_k)$ 、固有度を $B(l_k|c_i)$ 、形に関する共通度を $B(f_j|l_k)$ 、固有度を $B(l_k|f_j)$ とおき、以下のように定義する。ただしパラメータ τ は正定数。

$$B_C(c_i|l_k) = \frac{\exp(V_C(c_i|l_k)/\tau)}{\sum_{c \in C} \exp(V_C(c|l_k)/\tau)} \quad (5)$$

$$B_C(l_k|c_i) = \frac{\exp(V_C(l_k|c_i)/\tau)}{\sum_{l \in L} \exp(V_C(l|c_i)/\tau)} \quad (6)$$

$$B_F(f_j|l_k) = \frac{\exp(V_F(f_j|l_k)/\tau)}{\sum_{f \in F} \exp(V_F(f|l_k)/\tau)} \quad (7)$$

$$B_F(l_k|f_j) = \frac{\exp(V_F(l_k|f_j)/\tau)}{\sum_{l \in L} \exp(V_F(l|f_j)/\tau)} \quad (8)$$

対象 o_h に関する共通度 $B(o_h|l_k) = B((c_i, f_j)|l_k)$ 、固有度 $B(l_k|o_h) = B(l_k|(c_i, f_j))$ は、色と形の共通度、固有度をそれぞれ掛け合わせるによって表すことができる。

$$B((c_i, f_j)|l_k) = B_C(c_i|l_k)B_F(f_j|l_k) \quad (9)$$

$$B(l_k|(c_i, f_j)) = B_C(l_k|c_i)B_F(l_k|f_j) \quad (10)$$

exIA は対象 o_h を示されて「これは何か」と問われたときに、上記の B の値を参照して返答を行う。

4.2 対称性バイアスの導入

対称性バイアスを考慮し、共通度と固有度が比例関係になるよう、 B_C 、 B_F の値を以下のように修正する。ただし $\forall c_i \in C, \forall f_j \in F, \forall l_k \in L$ 。

$$B_C(l_k|c_i) = \frac{B_C(c_i|l_k)}{\sum_{l \in L} B_C(c_i|l)} \quad (11)$$

$$B_C(c_i|l_k) = \frac{B_C(l_k|c_i)}{\sum_{c \in C} B_C(l_k|c)} \quad (12)$$

$$B_F(l_k|f_j) = \frac{B_F(f_j|l_k)}{\sum_{l \in L} B_F(f_j|l)} \quad (13)$$

$$B_F(f_j|l_k) = \frac{B_F(l_k|f_j)}{\sum_{f \in F} B_F(l_k|f)} \quad (14)$$

これにより対象 o_h (色属性 c_i 、形属性 f_j) の共通度と固有度には以下の関係が成立する。ただし $B(o_h|l_k) = B((c_i, f_j)|l_k) = B_C(c_i|l_k)B_F(f_j|l_k)$ 、 $B(l_k|o_h) = B(l_k|(c_i, f_j)) = B_C(l_k|c_i)B_F(l_k|f_j)$ である。

$$B((c_i, f_j)|l_k) = \frac{|L|^2}{|O|} B(l_k|(c_i, f_j)) \quad (15)$$

この修正を 1 回の経験につき 10 回行うことにより、固有度および共通度の誤差は 10^{-4} 以下に収束する。

4.3 exIA の回答方法

対象 o_h に関して、「 o_h は何か」という問いに対する exIA の回答を $What(o_h)$ と表す。

$$What(o_h) = \underset{l}{\operatorname{argmax}} B(l|o_h) \quad (16)$$

これは対象 o_h に関してもっとも固有度の高いラベルを選択することを表す。ただしもっとも固有度の高いラベルが複数存在する場合は、その中からランダムに一つ選択し、該当するラベルが存在しない場合は null (exIA がその対象 o_h を知らない) を示す。本モデルにおける正答とは、この $What(o_h)$ の答えが子 exIA と直系の親 exIA で等しいときのことを言う。

4.4 相互作用を考慮した学習環境

集団での語彙学習の相互作用を調べるために、複数の exIA 間に距離を導入し、空間的な距離に応じて exIA 間の関係性を定める。exIA を 3 次元 (x, y, z) 座標空間の座標が自然数の格子点に配置する。平面 $z = n_z$ (ただし n_z は自然数) 上に存在する各 exIA は第




図 1 学習モデル概略図

$n_z + 1$ 世代の exIA の集合を意味する．提案モデルにおいて平面 $z = n_z$ 上に存在するいずれかの exIA が学習を受けているとき，平面 $z = n_z$ 上に存在する exIA を子 exIA，平面 $z = n_z - 1$ 上に存在する exIA を親 exIA と呼ぶ．座標 (n_x, n_y, n_z) (ただし n_x, n_y, n_z は任意の自然数) に子 exIA が存在するとき，座標 $(n_x, n_y, n_z - 1)$ に存在する exIA を前者の exIA に対する直系の親 exIA と呼ぶ．

座標 (n_x, n_y, n_z) に存在する exIA は，学習開始から s ステップまでは直系の親 exIA からのみ学習を受ける．この期間 s ステップを初期学習期間と呼ぶ．その後，依存度 t の確率で直系の親から学習を受け， $(1 - t)$ の確率で同じ子世代の exIA から学習を受ける．同じ子世代の exIA から学習を受ける場合は，それぞれの空間的な距離の二乗の逆数によるルーレット選択を行い，学習を受ける exIA を決定した．

さらに，子 exIA 同士の学習との比較のために，子 exIA からは学習を受けずに，親世代の exIA からのみ学習を受ける場合について定義する． (n_x, n_y, n_z) に存在する exIA は $(n'_x, n'_y, n_z - 1)$ の exIA から学習を受ける．初めから学習が終了している親 exIA から学習を受けるので，初期学習期間は 0，依存度は存在せず，空間的な距離の二乗の逆数に基づくルーレット選択により，学習を受ける exIA を決定する．

図 1 では学習プロセスの概略を示す．各点が exIA を示し，実線の矢印が前者を，破線の矢印が後者を示す．なお平面 $z = 0$ 上の exIA は第 1 世代の exIA の集合であり，ランダムに生成された共通する言語をそれぞれ与えられる．

5. 実験

5.1 実験環境

親 exIA が子 exIA に与える言語を教示言語と呼ぶ．本実験では 1 世代につき 4 つの exIA を配置する．これは $z = n$ (ただし n は自然数)，すなわち第 $n + 1$ 世代において $(0, 0, n), (0, 1, n), (1, 0, n), (1, 1, n)$ に exIA が存在する．提案モデルは 1 ステップにおいて 1 回の学習を行い，一回の経験において見る対象の数は 5，一度に与えられるラベル数は 2 とする．また提案モデルは 1 世代につき 1500 ステップで学習を終了し，次の世代の学習に移る．これを 25 世代まで行う．子 exIA は学習が終わると，すべての対象についてラベルを返答し，教示言語との比較を行う．このときの子 exIA による返答と教示言語との一致率を正答率と呼ぶ．すべての対象について返答が終わると，それをもとに新たな教示言語を生成し，子 exIA を親 exIA にする．色の属性数は 16，形の属性数は 22，対象の数は 352 でありラベルの種類は 22 とする．なお，以下の結果はランダムシードを変えて 10 回試行した結果を平均したものである．

5.2 正答率と言語の構造化の関係

図 2 と図 3 は単一系における言語変化の例について示している．各図の軸 F は形の属性番号，C は色の属性番号，L はラベルの識別番号であり，F と C の交点の L の値が形 F と色 C を持つ対象のラベル L を示す．図 2 は第 1 世代に与えられる教示言語であり，ラベルは形や色に関係なく割り振られている．子 exIA は語彙学習の過程で，形状類似バイアスにより対象の持つ形属性に対応してラベルを割り当てるため，言語学習が進み世代を経ると，図 3 のようにラベルは形に関して全単射となるように収束する．この過程を言語の構造化と呼ぶ．ただしラベルと形の組み合わせは実験によって異なる．

一方で，子 exIA の正答率と言語の構造化には相関があり，構造化が進むと正答率があがり，構造化が完了すると正答率が 100 % に収束する．図 4 では単一系の各世代における正答率の変化を示す．この相関関係より，言語の構造化が完了するまでの期間の比較には exIA の各世代の正答率を用いる．言語の構造化，正答率との相関関係については複数系の各 exIA も同じである．ある世代においてそのうちの何れかの exIA が初めて 100 % の正答率に達したとき，その世代を収束世代と呼ぶ．

5.3 実験内容

本実験では以下の 2 つの実験を行った．




図 2 単一系における第 1 世代に与える教示言語




図 3 単一系における第 14 世代の学習終了時の言語

実験 1：単一系との比較

単一系の世代学習は $(0, 0, n)$ にのみ exIA が存在する状況と考えられ、子 exIA は直系の親 exIA からのみ学習を受けるが、複数系では直系の親 exIA と同世代の子 exIA 同士で相互に学習する。このとき単一系と、1 世代に 4 つの exIA が存在する複数系での収束性と、収束するまでの世代数を比較する。初期学習期間 s を 500 ステップ、依存度 t を 50% とする。

実験 2：子同士の学習を行わず、親集団からのみ学習を受ける場合との比較

上記の子 exIA 同士の学習を行う場合と、直系の親以外も含む親集団からのみ学習を受ける場合を比較する。実験 1 と同様に初期学習期間 s を 500 ステップ、依存度 t を 50% とする。

5.4 実験結果と考察

5.4.1 実験 1

実験 1 の結果を表 1 に示す。表の「500-50%」は複数系の学習で初期学習期間が 500 ス




図 4 単一系における世代ごとの言語の構造変化

	単一系	500-50%
平均収束世代数	14.0	8.625
未収束回数	0	2

テップ、親への依存度が 50% の場合を表す。収束世代数は単一系で平均 14.0 世代、複数系で 8.6 世代であった。これは子同士の学習を導入することで、学習機会の回数は同じでも、早い段階で言語の構造化が完了することを示している。これは子同士の学習で、互いに言語の構造が影響しあうためである。例えば学習の途中で対象 O_a に対して子 exIA C_a がラベル L_a を割り振り、子 exIA C_b がラベル L_b を割り振ったとする。 C_b が C_a から学習を受けると、その影響により、 C_b は O_a を L_a と判断する確率が増す。この相互の繰り返しにより、学習中の exIA 同士の共通の認識が構築されていく。なお表 1 が示すように、複数系の場合、少数 (2 回) であるが、25 世代を越えても構造化しないことがあった。これは exIA の特性によるものである。9) によれば exIA はより要素数の多い要素に関して収束する。そのため、本実験においては色属性より形属性が多いので、通常は形に関して収束する。しかし exIA に提示する対象やラベルがたまたま偏ると、exIA にとっての見かけ上の要素数が現実と異なる可能性がある。単一系であれば学習を行う exIA は一つなので、しばらくすれば偏りは解消される。しかし複数系では学習を行う exIA は学習の完了している直系の親 exIA だけでなく、学習中の子 exIA も存在するため、不完全な言語構造による学習が繰り返され、その偏りが是正されないことがある。したがって形に関する要素数を色に関する要素数より十分大きくすれば収束性は向上すると考えられる。

表 2 親世代集団からのみ学習を受ける場合との比較

	親世代のみ	500-50 %
平均収束世代数	13.2	8.625
未収束回数	5	2

5.4.2 実験 2

表 2 に実験 2 の実験結果を示す。直系の親と子世代同士の学習を行った場合と、子世代同士の学習を行わず親世代から学習を受ける場合を比べると、前者のほうが早く言語の構造化が行われ、未収束回数も少なかった。未収束回数の差については、後者では同世代の学習がないからと考えられる。親世代からのみ学習を受ける場合、親は既に学習を終えているが、それぞれが異なる言語構造を持つことがあり、対象に関するラベルに別々のものが割り振られる可能性があり、子が惑わされることになる。さらに、子同士の学習がないので言語の摺り合わせもない。

表 1 と表 2 より、単一系と、親世代から学習を受ける複数系を比較すると、未収束回数は異なるもののその収束世代数に大きな差はない。一方複数系について、直系の親と子世代同士の学習を行う場合と、親世代から学習を受ける場合を比較すると、一つの子 exIA の学習にかかわる exIA の数は同じだが収束世代数には大きな差がある。このことから言語の学習において、集団での学習だけで効率良く言語が構造化されるのではなく、学習が完了する前の子同士の学習が重要なことを示唆している。

6. おわりに

本研究では、経験を通じて語彙を学習する幼児エージェントについて、子同士の相互学習を行わせるモデルを提案した。ノイズを考慮した幼児エージェントモデル¹⁰⁾の問題は、センガスらの研究²⁾⁻⁴⁾と比べて、言語の構造化が完了するまでに必要な期間が長いことであった。そのため、10)を拡張し、集団における語彙学習の相互作用を提案し実験を行った。その結果、単一系よりも言語の構造化が完了するのに要する世代数が小さいことから、言語の構造化において子同士の相互学習が重要であることを示した。また、エージェントの数により収束が早まったというわけではないことを示した。本研究の結果は、たとえば 10)にも述べられているように、ロボットの言語学習への適用が挙げられる。特に 15)のように幼児の集団における学習を活用したロボットの言語学習も研究されており、これらの研究に重要な示唆を与えると考える。

今後の課題としては、初期学習期間や依存度を変化させた場合の詳細な調査、語彙学習以

外の構文学習などへの応用などを行いたい。

参考文献

- 1) 針生 悦子：言語心理学，朝倉書店，pp.4-54 (2006)。
- 2) Senghas, A., Coppola, M.: Children creatin language: How Nicaraguan sign language acquired a spatial grammar, *Psychological Science*, 12, pp.323-328 (2001)
- 3) Senghas, A.: Intergenerational influence and ontogenetic development in the emergence of spatial grammar in Nicaraguan sign language, *Cognitive development*, 18, pp.511-531 (2003)。
- 4) Senghas, A., Kita, S., Ozyurek, A.: Children creating core properties of language: Evidence from an emerging sign language in Nicaaragua, *Science*, Vol.305, pp.1779-1782 (2004)。
- 5) 今井 むつみ，針生 悦子：レキシコンの構築 -子供はどのように語と概念を学んでいくのか，岩波書店，pp.1-10, 25-73 (2007)。
- 6) 小林 郁夫，古川 康一，今井 むつみ，尾崎 知伸：帰納論理プログラミングによる幼児の名詞語彙獲得のモデル化，*信学技報*，NLC99-23，pp.29-36，電子情報通信学会 (1999)。
- 7) Kirby, S.: Learning, bottlenecks and the evolution of recursive syntax, *Linguistic Evolution through Language Acquisition: Formal and Computational Models*, Cambridge University Press (2002)。
- 8) 的場 隆一，中村 誠，東条 敏：構文獲得における対称性バイアスの有効性，*認知科学*，vol.15，No.3，pp.1-13 (2008)。
- 9) 篠原 修二，田口 亮，橋本 敬，桂田 浩一，新田 恒雄：幼児エージェントにおけるバイアスの形成と言語の構造化，*情報処理学会論文誌：数理モデル化と応用*，Vol.48，No.SIG 2 (TOM 16)，pp.125-146 (2007)。
- 10) 上野 祐輝，菅原 俊治：幼児期の学習モデルを利用した語彙の獲得と世代学習の効果と特徴，*人工知能学会全国大会論文集*，Vol.25，1G1-4 (2011)。
- 11) 田口 亮，木村優志，篠原修二，桂田浩一，新田恒夫：Online-EM による学習機構と学習バイアスの適用，*信学技報*，Vol.NCL2005-60 (/SP2005-93)，pp.31-36 (2005)。
- 12) Partha, Mukherjee., Sandip, Sen., Stephane, Airiau.: Norm Emergence Under Constrained Interactions in Diverse Societies, In Proc. of Int. Joint Conf. on Autonomous Agents and Multiagent Systems (AAMAS 2008), pp.779-786 (2008)。
- 13) 今井 むつみ，針生 悦子：レキシコンの獲得における制約の役割とその性質，*人工知能学会誌*，第 18 巻 1 号，pp.31-40 (2003)。
- 14) 服部 雅史：条件推論における方向性，*立命館人間科学研究*，pp.1-13 (2002)。
- 15) Joe Saunders, Caroline Lyon, Frank Forster, Chrystopher L. Nehaniv and Kerstin Dautenhahn: A Constructivist Approach to Robot Language Learning via Simulated Babbling and Holophrase Extraction Proc. of the IEEE Symposium on Artificial Life (ALife '09), pp. 13-20 (2009)。