

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

上野 祐輝 菅原 俊治
Yuki UENO Toshiharu SUGAWARA

早稲田大学大学院 基幹理工学研究科 情報理工学専攻
Department of Computer Science and Engineering, Waseda University

In this paper, we extend the model of infant agent (IA), which imitate a process of learning a vocabulary by experience, and show that the characteristic that is often observed when infants learn vocabularies in the environment can emerge. With development of robot or human interface technologies, it is expected that people can interact with robots or computers using verbal communication in future. Therefore, the robots have to understand the relationships between words and the corresponding concepts. Although a number of methods for manually defining these relationships into robots, this is costly and difficult due to the fluctuation of expressions. For this issue, the model of IAs that emerge language by itself is proposed. However, the conventional IAs do not take into account the actual environment where received information sometimes contains noise. Thus, we modify the IA model so as to accept noisy information and show that the structure of the language and the learning biases emerge with noisy information.

1. 序論

近年のロボット技術やヒューマンインタフェース技術の発展から、将来機械やロボットが更に人間社会に貢献すると予想できるが、今後ロボットが人間社会に進出するには、人間の指示を理解するための語彙が不可欠である。しかし事前に与えられる知識には限りがあり、世界に関する全ての知識を与えることは非常に困難である。したがって、可能な限りロボット自身が知識を学習・獲得するシステムの実現が求められる [1]。

幼児期の特殊な学習傾向が急速に語彙を獲得することに着目し、幼児の語彙学習をモデル化した幼児エージェント (infant agent, 以下 IA) の研究がある [2]。[2] では対称性バイアスを組み込んだ IA を構築し、幼児の学習時の傾向である学習バイアスが導出でき、言語の構造化ができることを示している。しかし実環境では、与えられる情報に誤りや曖昧性が含まれるため、現実に近い環境での言語の構造化を確認することは重要である。

そこで本研究においては、[2] の IA モデルを拡張し、現実世界に近い、誤った情報が含まれる環境においても、対称性バイアスによって言語が構造化されること、学習バイアスの導出が可能であることを示す。

2. 言語に関する概念と IA に関する定義

2.1 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の思考の制約・傾向性である [3]。本研究では以下の 3 つの学習バイアスの導出を試みる。

- ・事物カテゴリーバイアス
初めて聞いた単語を普通名詞だと判断する傾向性。
- ・形状類似バイアス
形状が似通った対象に単語の適用範囲を広げる傾向性。
- ・相互排他性バイアス
各対象は 1 つのラベルのみを持つと考える傾向性。
対称性バイアスは人の非論理的推論の傾向性「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 [4]。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 [3]。

2.2 言語と学習

対象 o は色属性 c と形属性 f を持つ。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 1 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。

IA は対象集合の中からランダムに選ばれた N 個の対象を見つ、 m 個のラベルを聞く。ラベルのうち少なくとも一つは N 個の対象のいずれかを示すが、その対応関係は明示的に与えられてはいない。IA はこのような経験を繰り返す。

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していく。このときの確信度の形成過程を学習と呼ぶ。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。

2.3 ノイズ混入率

1 度の経験において、提示された対象を o_1, o_2, \dots, o_N と、提示されなかった対象群をまとめて O_{others} と記す。与えられたラベルを l_1, l_2, \dots, l_m と表すと、対象とラベルには以下の関係が言える。左辺が与えられたラベルであり、右辺がそのラベルの示す対象である。

$$\begin{aligned} l_1 &\Rightarrow \{o_1, o_2, \dots, o_N\} \\ l_2 &\Rightarrow \{o_1, o_2, \dots, o_N, O_{others}\} \\ &\vdots \\ l_m &\Rightarrow \{o_1, o_2, \dots, o_N, O_{others}\} \end{aligned}$$

l_1 は必ず、提示された N 個の対象のいずれかを示すが、 l_2 以降のラベルには、誤った情報が含まれる可能性がある。このとき l_2, \dots, l_m が O_{others} を示す確率をノイズ混入率と呼ぶことにする。

3. 提案モデル

3.1 モデル概要

IA は "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" という経験を繰り返す。それらの経験から、対象 o_h の持つ色属性が c_i 、形属性を f_j とするとき、ラベル l_k を聞いたときに色属性 c_i を見た確率 $V_C(c_i|l_k)$ と色属性 c_i を見たときにラベル l_k を聞いた確率 $V_C(l_k|c_i)$ 、ラベル l_k を聞いたときに形属性 f_j を見た確率 $V_F(f_j|l_k)$ と形属性 f_j を見たときにラベル l_k を聞いた確率 $V_F(l_k|f_j)$ をそれぞれ記憶する。複数のラベルを聞くので、同時に聞いたラベルに関しては以下の補正をかけない。ただし、 V_C 、 V_F の初期値は null である。

次にこれら V の値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 $B_C(c_i|l_k)$ 、固有度を $B_C(l_k|c_i)$ 、形に関する共通度を $B_F(f_j|l_k)$ 、固有度を $B_F(l_k|f_j)$ とおき、確率 V の値が大きければ大きいほど、大きい値を返す。対象 o_h に関する共通度は $B(o_h|l_k) = B((c_i, f_j)|l_k)$ 、固有度は $B(l_k|o_h) = B(l_k|(c_i, f_j))$ で表せる。

3.2 対称性バイアス

「対象 o_h は何か」という問いの答えがラベル l_k ならば、「ラベル l_k はどれか」の答えは対象 o_h であるという傾向を与える。そのため、色と形の共通度、固有度それぞれに関して以下のように規定し補正をかける。

$$B_C(l_k|c_i) = \frac{B_C(c_i|l_k)}{\sum_{l \in L} B_C(c_i|l)} \quad (1)$$

$$B_C(c_i|l_k) = \frac{B_C(l_k|c_i)}{\sum_{c \in C} B_C(l_k|c)} \quad (2)$$

$$B_F(l_k|f_j) = \frac{B_F(f_j|l_k)}{\sum_{l \in L} B_F(f_j|l)} \quad (3)$$

$$B_F(f_j|l_k) = \frac{B_F(l_k|f_j)}{\sum_{f \in F} B_F(l_k|f)} \quad (4)$$

ただし $\forall c_i \in C, \forall f_j \in F, \forall l_k \in L$ である。よって対象 o_h の共通度と固有度には以下の関係が成立する。

$$B((c_i, f_j)|l_k) = \frac{|L|^2}{|O|} B(l_k|(c_i, f_j)) \quad (5)$$

ただし $B(o_h|l_k) = B((c_i, f_j)|l_k) = B_C(c_i|l_k)B_F(f_j|l_k)$ 、 $B(l_k|o_h) = B(l_k|(c_i, f_j)) = B_C(l_k|c_i)B_F(l_k|f_j)$ となることに注意する。

3.3 IA 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 IA の回答を $What(o_h)$ と表す。

$$What(o_h) = \operatorname{argmax}_l B(l|o_h) \quad (6)$$

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し、該当するラベルが複数存在する場合は、その中からランダムに 1 つ選択する。

ラベル l_k について「 l_k はどれか」あるいは「 l_k を取って」と聞かれた場合は、以下の式を用いて回答を行う。

$$WhichI(l_k) = \begin{cases} o_i, & \exists o_i \in O, s.t. What(o_i) = l_k \\ null, & \forall O, What(o) \neq l_k \end{cases} \quad (7)$$

式 (7) は式 (6) を用いて l_k と判断した対象を回答とする。このとき l_k と判断する対象が複数あれば、その中からランダムに 1 つを選択し、該当する対象がなければ null と回答する。

4. 実験

4.1 実験条件

IA に与える言語を教示言語と呼ぶ。本実験で使用する提案モデルを exIA、比較対象として [2] の IA を IA0 とする。exIA 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 exIA は 1500 ステップで成人するとし、それ以上の学習は行わず、次の世代の学習に移る。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、IA0 は一度に与えられるラベル数は 1 であり、ノイズが含まれないことを除けば、全ての条件は exIA と同じである。

4.2 実験 1: 言語の構造化

ランダムに構築した初期言語 $Lang1: O \rightarrow L$ を教示言語とし、exIA に与える。exIA は 1 ステップごとに全ての対象について「これは何か」という問いを受け、そのときの回答と教示言語との一致率を正答率と呼ぶことにする。成人した IA の回答する言語を次の世代の IA の教示言語とし、第 N 世代の教示言語を $LangN$ とおく。これを第 25 世代まで繰り返す。

図 1, 図 2, 図 3 は、ノイズ混入率が 0 % のとき、50 % のとき、100 % のときの正答率の推移を示したものである。それぞれの図では第 1 世代、第 3 世代、正答率が 100 % に収束した世代での正答率の推移を示して、世代を経るにつれて正答率が上がっていくことがわかる。

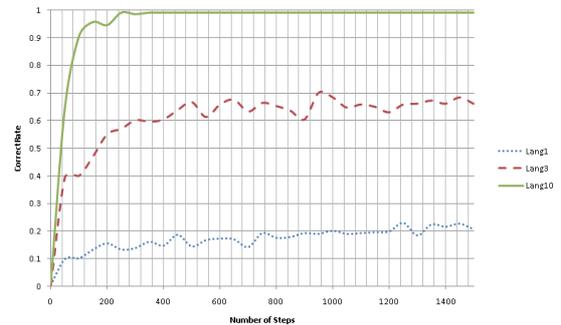


図 1: ノイズ混入率が 0 % のときの exIA の正答率の推移

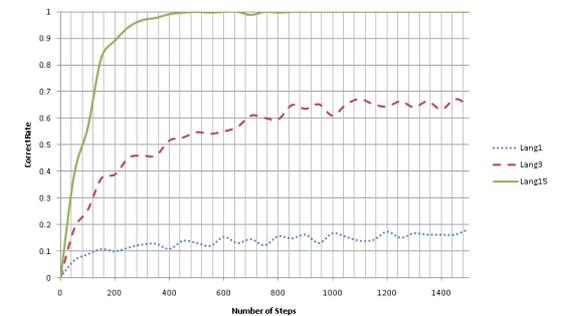


図 2: ノイズ混入率が 50 % のときの exIA の正答率の推移

図 4, 図 5 はノイズ混入率が 100 % のときの第 1 世代と第 18 世代における exIA の回答を示す。なお、 F と C はそれぞれ

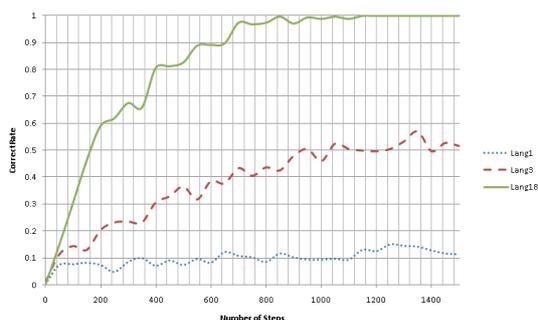


図 3: ノイズ混入率が 100 % の時の exIA の正答率の推移

れ対象 O の形・色属性を, L は対象 O に関して exIA が返答したラベルを示す. これにより, 最初は乱雑だった言語が, 世代を経るに従い形に関して構造化することがわかる. また, 構造化はノイズ混入率によらずに起こり, 構造化が完了するのは exIA の正答率が 100 % となる世代である.

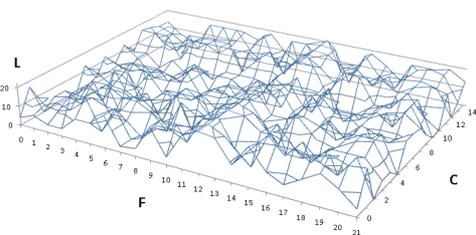


図 4: ノイズ混入率 100 %, Lang1 における exIA の回答

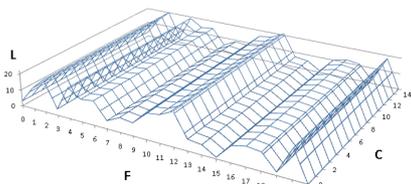


図 5: ノイズ混入率 100 %, Lang18 における exIA の回答

4.3 実験 2: 学習バイアス

実験 2 では学習バイアスの一種である, 事物カテゴリーバイアス, 形状類似バイアス, 相互排他性バイアスが導出できることを確認する. 世代交代は行わず, 教示言語は実験 1 で構造化された言語を用い, ノイズ混入率を 50 % とする. なお, 他のノイズ混入率についても調べたが, 大きな差異は観測されなかった.

図 6 は事物カテゴリーバイアスについての実験結果である. ここでは IA が経験できる対象を, 特定の色属性・形属性が共通する対象のみに限定し, その後未知のものを含む全ての対象についての正答率の推移を調べた. このとき IA が経験した対象は全体の約 10 % である. これにより, IA0 と比べて exIA は正答率が低く, 収束していないことがわかる.

図 7, 図 8 は形状類似バイアスについての実験結果である.

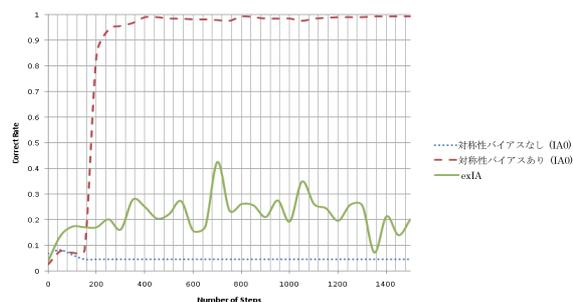


図 6: 未学習の対象に対する正答率

学習後に IA の経験したことのない色と形を持つ対象 o_{novel} を提示し, 同時に初めて聞く l_{novel} を与える. この教示後に o_{novel} と共通の色をもつ対象群 O_C , 共通の形を持つ対象群 O_F について「これは何か」という質問をする. IA が l_{novel} と判断した対象の割合を, O_C に関しては図 7 に, O_F に関しては図 8 に示す.

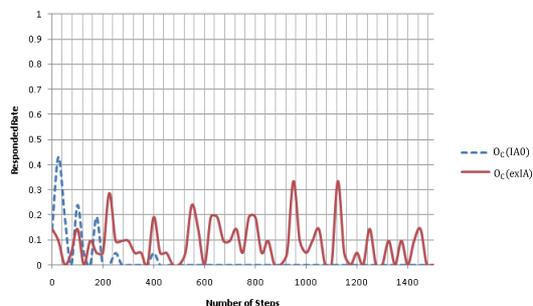


図 7: 対象群 O_C に関して IA0, exIA が各対象群について l_{novel} と判断した割合

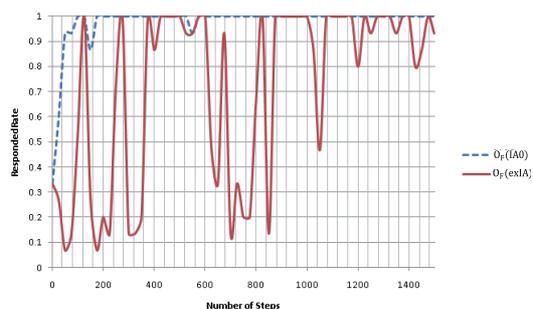
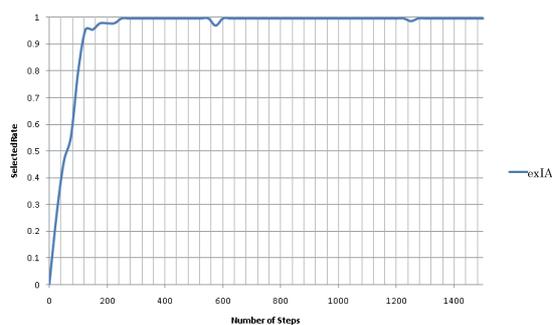
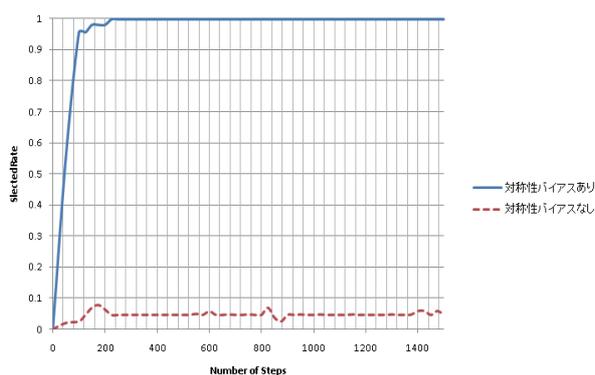


図 8: 対象群 O_F に関して IA0, exIA が各対象群について l_{novel} と判断した割合

図 9, 図 10 は相互排他性バイアスについての実験結果である. IA の学習済みの対象と未経験な対象 o_{novel} の二つを提示し, 同様に未経験なラベル l_{novel} を示し「 l_{novel} はどちらか」と質問をする. これを全ての対象について行い, o_{novel} を exIA が選択した割合を図 9, IA0 が選択した割合を図 10 に示す.

図 9: exIA が l_{novel} を選択した割合図 10: IA0 が l_{novel} を選択した割合

5. 考察

5.1 言語の構造化に関する考察

図 1~図 5 より, ノイズが含まれていても世代をえるにつれて, 言語が構造化されていき, IA の正答率が 100 % になることがわかる. しかしその期間が, ノイズ混入率によって異なる. ノイズ混入率が 0 % のとき (図 1) では, exIA の正答率が 100 % となった世代は第 10 世代, 50 % のとき (図 2) は第 15 世代, 100 % のとき (図 3) は第 18 世代である. また, ノイズ混入率が上がるほど, 正答率が 100 % となるまでに必要な学習ステップ数が増えている.

このことから, ノイズという誤った情報によって言語の学習状態が平均化されたと考えられる. IA の回答は提示された対象とその際に与えられたラベルの条件付確率によって出力されるため, IA0 や, exIA のノイズ混入率が 0 % の場合は, 提示された対象に関してのみ確率が高まる. しかし誤った情報が含まれると, 提示された対象以外に対する確率が高まり, 相対的に条件付確率が抑制される.

5.2 学習バイアスに関する考察

exIA において相互排他性バイアス以外の学習バイアスは確認できなかった. 事物カテゴリーバイアスに関しては, 図 6 によると, exIA の正答率は IA0 の半分以下の正答率であり, 形状類似バイアスは図 7, 図 8 によると, exIA が l_{novel} と判断した割合が収束することはなかった.

このことに関しては, 上記の言語の構造化に関する考察の項で述べたように, 間違った情報によって IA の学習状態が平均化されたことが考えられる. 実験 2 の事物カテゴリーバイアスの実験においては, 色属性 c_0 , 形属性 f_0 のいずれかを含む対

象のみを学習するので, それ以外の組み合わせは直接的には学習できない. 学習されなかった組み合わせは, 色属性, 形属性それぞれに関する固有度の積から対象の固有度を求めるが, 間違った情報によって固有度のいずれか, あるいは両方が抑制されれば, 正しい答えを導くことは難しい. 相互排他性バイアスのみが確認できたのは, 誤情報による学習の平均化の影響が小さいからである. 形状類似バイアスの実験では未経験の対象を提示したあとに, その対象の要素の一部を持つ O_C と O_F の対象群に対して判断を行っているが, この提示後の学習に誤情報が含まれることにより, 提示した対象と, その色・形属性の固有度が抑制される. 一方で相互排他性バイアスの実験で, 未経験の対象と学習済みの対象を提示した上で質問を行っている. 学習済みの対象に関する固有度は, 誤情報による抑制を受けているため, 未経験の対象に関する固有度が優先されやすい.

また, 図 8 を見ると, exIA は IA0 と比べると収束はしていないものの, なんらかの傾向があるように見える. これに関しては今後の調査が必要である.

6. 結論と課題

複数のかつ間違った情報を与えた場合でも, 対称性バイアスによる言語の構造化が行われることが確認できた. 一方で相互排他性バイアス以外の学習バイアスは十分に確認できなかった.

提案モデルの課題としては, 構造化されるまでに多くの世代を経る必要があることが上げられる. センガスらの研究 [5][6] によると, ニカラグアの豊学校では, それまでバラバラだった手話がわずかに数世代で一定のルールにのっとったものに変化していったのに対し, 提案モデルにおいては, 構造化が完了するまでにかかる世代数は, ノイズ混入率が 0 % の場合においても 10 世代もの時間がかかる. 実際の言語の学習において提案モデルを応用する場合, この学習の遅さを解決することが課題となる. そのため今後は, 誤情報の影響を小さくしたモデルの構築を行いたい.

参考文献

- [1] Donald. A. Norman, "エモーショナル・デザイン" 新曜社, pp. 215-284, 2004
- [2] 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, TOM 16, pp.125-146, 2007
- [3] 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, 18 巻 1 号, pp. 31-40, 2003
- [4] 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
- [5] Senghas, A. , Coppola, M. , "Children creating language: How Nicaraguan sign language acquired a spatial grammar." Psychological Science, 12, pp. 323-328, 2001
- [6] Senghas, A. , "Intergenerational influence and ontogenetic development in the emergence of spatial grammar in Nicaraguan sign language." Cognitive development, 18, pp. 511-531, 2003