

# Infant Agent に与える効率的な概念獲得のための制約に関する検討

小玉 智志<sup>†</sup> 田口 亮<sup>†</sup> 桂田 浩一<sup>†</sup> 山田 博文<sup>‡</sup> 新田 恒雄<sup>‡</sup>

豊橋技術科学大学 大学院工学研究科<sup>†</sup> 豊橋技術科学大学 マルチメディアセンター<sup>‡</sup>

## 1. はじめに

近年、ロボットが画像や音声などから概念を獲得するための研究が行われている[1]. 我々は、人間の教示から概念をオンラインで学習する Infant Agent (以下 IA) の開発をしてきた[2] が、概念の獲得には多くの教示回数を必要としていた.

そこで学習効率を改善するために、人間の幼児が概念を獲得する際の制約を IA に与えることを提案し、評価実験で結果を示す.

## 2. Infant Agent による概念獲得

### 2.1 Infant Agent

IA は人間の幼児の概念獲得機構をモデルに、知識を持たない状態から人間との対話を通して概念を学習するエージェントである. 学習の際には教示者となる人間がオブジェクトを提示して、それに対する概念を音声で教示する. IA はオブジェクト画像の特徴を視覚情報として、音声の特徴を聴覚情報として受け取り、両者の対応関係を概念として獲得する.

### 2.2 視聴覚情報

#### 2.2.1 視覚情報

視覚情報には、形状、色相、明度の3つの属性を用いる. 具体的に、オブジェクト画像を2値化し、細線化処理を施した画像から25次元高次局所自己相関特徴[3]を求め、形状特徴に使用した. また、オブジェクト画像のRGB情報をHSV変換し、そのH成分を色特徴、V成分を明度特徴として使用した.

#### 2.2.2 聴覚情報

本稿では、認識誤りなどによる実験の煩雑化を避けるため、キーボード入力によるラベルを聴覚情報として使用する.

### 2.3 概念の獲得

IA はラベルと対で提示されるオブジェクト特徴の頻度から、属性ごとの確率分布を作り、図1のように概念辞書に格納する. 確率分布の学習方法には、Online-EM[4]法を用いた. 一方例えば“まる”という概念は、形状属性以外は対象としていない. そこで、分布を学習すると共に、属性を特定する手段として確信度を算出する.

ラベル付け学習が開始される以前に、全てのオブジェクト特徴の頻度から分布を学習する(以降、基準分布). 基準分布は、各属性共にすべてのオブジェクトの特徴を用いるため、学習が進むにつれて一樣な分布に近づく.

不要な属性、例えば形状を表現する概念(まる等)の色相属性には様々な特徴が入力され、特定の色に偏った分布は生成されない. このため、基準分布と概念“まる”との色相属性間距離は、ラベルの対象となっている属性(形状)のそれと比較して小さく期待される.

確信度の算出には、概念と基準分布の持つ混合分布との比較を属性ごとに行い、基準分布との距離を正規化したもの( $D_i$ :  $0 \sim 1$   $i$ :属性)を、各属性の確信度とする( $J_i = D_i$ ).

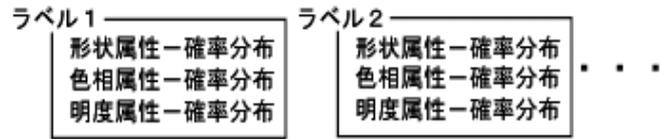


図1 概念辞書

## 3. 幼児学習における制約の理論

### 3.1 人間の持つ制約

未知の事物に対してラベル付け学習を行う場合、そのラベルが形、色、大きさ、素材など多数の属性のうち、どれを対象としているかを正確に学習するためには多くの事例が必要である. しかし、幼児は少ない学習回数で正確に概念を獲得することが出来る. マークマンや今井らは、人間の幼児がいくつかのバイアスを用いて学習することで、これを実現していると説明している[5]. 本稿ではそのうち、事物分類性バイアス、相互排他性バイアス、形状類似性バイアスを IA に与えることで、概念獲得効率の改善を目指す.

### 3.2 制約の実現

#### 3.2.1 事物分類性バイアス

事物分類性バイアスは「未知の事物に対して付けられたラベルを、その事物を含むカテゴリに対するラベルと判断する」と定義されている. そのため、カテゴリを事前に作成しておく必要がある. そこで、教示を行う前にオブジェクトを IA に提示し、予め Online-EM 法により各属性をカテゴリ化しておき、学習に利用する.

#### 3.2.2 相互排他性バイアス

相互排他性バイアスは「相異なるラベルが同じ対象事物に関連付けられることは無い」と定義されている. IA の判断と異なる教示ラベルが与えられたとき、そのラベルは自身の判断した概念とは異なる属性を指しているものとした. そのバイアスには以下の式を用いた.

$$E_i = 1.0 - J_i \cdot \{ 2.0 / (1.0 + e^{-N_i}) - 1.0 \} \quad \dots(1)$$

$E_i$ : 相互排他性バイアス  $i$ : 属性

$J_i$ : IA が判断した概念の属性尤度

$N$ : IA が判断した概念の学習回数

ここで、右辺{ }内の項は、学習があまり行われていない概念によって過度なバイアスが掛かるのを抑制するためのものである.

#### 3.2.3 形状類似性バイアス

形状類似性バイアスは「形の似通った事物同士が同じラベルを持つ可能性が高い」と定義されている. これは、未知のラベルを学習する際、形を優先的に利用する傾向があることを意味している. そこで、

$$S_i = 1.0 \quad (i = \text{形}) \quad S_i = 0.5 \quad (i \neq \text{形}) \quad \dots(2)$$

を与えることで形状を優先させた. 但し、バイアス  $S_i$  は、相互排他性バイアスによって、未知のラベルがある属性を指しているものとされた場合、その働きの妨げとならないよう、無効とする.

Constraint and the efficient in concept acquisition of an Infant-Agent

<sup>†</sup>Satoshi Kodama, Ryo Taguchi, Kouichi Katsurada, Hirobumi Yamada and Tsuneo Nitta, Toyohashi Univ. of Tech

### 3. 2. 4 バイアスを考慮した確信度の算出

上記3. 2. 2節, 3. 2. 3節のバイアスを用いることで, 各属性の確信度を

$$J_i = D_i \cdot B_i \quad \dots(3)$$

但し,  $B_i = E_i \cdot S_i$

とした。

上記バイアスは, 教示手順次第では概念の獲得効率を低下させる(知識の無い状態で“赤”と教示を受けた場合, 形状類似性バイアスが働く等)。そこで以下の更新式を用いて教示ラベルに対応した属性とそうでない属性を分離し, 誤りを早期に修正する。

$$B_i \leftarrow B_i + \{ 1.0 / (1.0 + e^{-(\Delta D_i - 0.5)}) - 0.5 \} \quad \dots(4)$$

i: 属性  $\Delta D_i$ :  $D_i$ の差分

上式は, 観測値  $D_i$  の変化がバイアス  $B_i$  をコントロールできる形式を与えている。

### 3. 3 IA による概念の判断

IA が概念の判断を行う際には, 提示されたオブジェクトから取得した特徴  $\mathbf{x}=\{x_i\}$  を概念の持つ混合分布が生起する確率  $P_i(x_i)$  と  $J_i$  を用いる。IA が保持している全ての概念ごとに, 各属性が持つ混合分布に対して次式の  $P^k(\mathbf{x})$  を算出し, 最大かつ閾値よりも大きい概念(のラベル)を提示し, 閾値以下ならば“?”を提示する。

$$P^k(\mathbf{x}) = \prod_i \{ (1.0 - P_i^k(x_i)) / (1.0 + e^{-\alpha(J_i - 0.5)}) \} + P_i^k(x_i) \quad \dots(5)$$

$\alpha$ : 定数(=10.0) i: 属性

## 4. 実験

### 4. 1 評価方法

本実験では, ラベルの対象となる属性と非対象な属性とに分離するまでの学習回数と, 提示されたオブジェクトに対しての正解率を見る。概念を正しく判断したかどうかについては, 「正しいラベルを提示した」「判断できない(教示された経験が無い)場合に“?”を提示した」の2通りを正解とし, 「間違っただけのラベルを提示した」「判断できる(教示された経験のある)にも関わらず“?”を提示した」の2通りを不正解とした。

### 4. 2 実験条件

実験では, オブジェクトとして 108(形状) × 100(色相) × 100(明度) = 1,080,000 個用意し, 教示を行う際には IA に提示するオブジェクトをランダムで決定した。教示文字列は, 21 個(各属性 7 通り × 3) の概念のいずれかを与えた。全ての概念は単一の属性を対象としており, 包含関係も無いようにした。教示手順は以下の 2 通りで行った。

- ① ランダムで教示内容を決定し, 教示する。
- ② 形状に関する概念から教示し, その後残りの概念について教示する。

なお, 教示を行うごとにオブジェクトをランダムに複数提示し, 概念を正しく判断できるかを確認している。

### 4. 3 実験結果

図2にバイアス(制約)を用いない場合, 図3に制約を用いた場合の概念獲得効率を示す。それぞれ横軸は各概念の学習回数であり, 縦軸は各属性の確信度  $J_i$  である。ここで対象属性とは, 形状に関する“まる”であれば形状属性のことであり, 非対象属性は色相, 明度属性のことである。教示手順①においては制約が悪影響を及ぼし(形状類似性: 知識の無い状態で色相に関する概念を教示しても, 形状に関する概念と判断

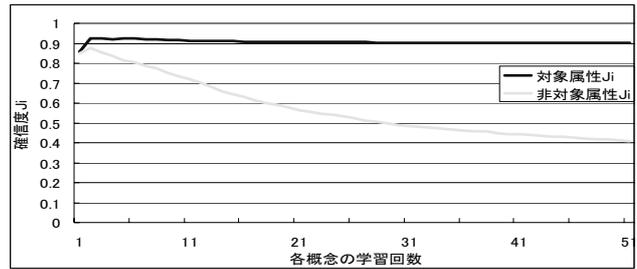


図2 制約無しでの概念獲得効率

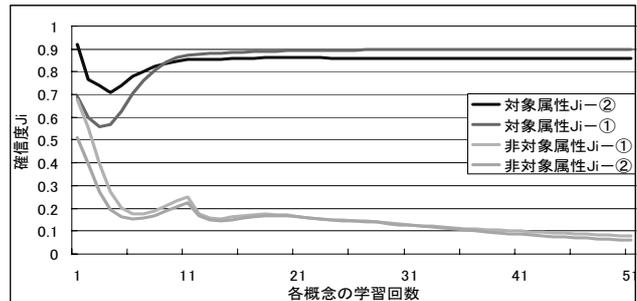


図3 制約有りでの概念獲得効率

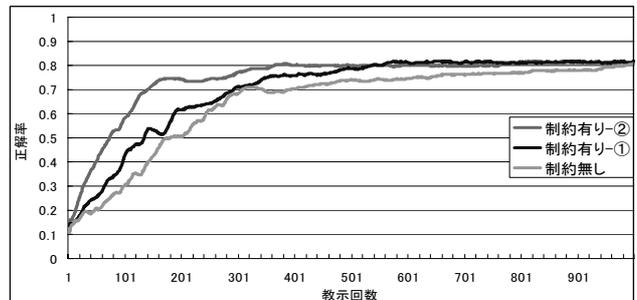


図4 概念正解率

してしまう。相互排他性: 汎化誤りから“赤い丸”を“青(学習済)”と判断したときに“赤(未学習)”と教示されると“赤”は色相以外を対象とした概念と判断してしまう, など), 対象属性の確信度が学習初期に低下しているが(4)式から, 学習を繰り返すことで確実な分離が行われている。教示手順②では, 初期に形状に関する概念を教示するために形状類似性が有効に働き, その後に教示した概念についても相互排他性により形状以外の属性と対応することが容易となったため, 概念獲得の効率化が顕著に見られる結果となった。

図4に概念正解率を示す。横軸は教示回数で, 縦軸が正解率となっている。教示手順①, ②ともに, 対象となる属性と非対象な属性の分離が早く正しく行われたことから, 制約を用いない場合と比較して少ない学習回数で正しく概念を判断できるようになったと考えられる。

## 5. まとめ

本稿では IA の概念獲得に制約を利用する方法を提案し, 評価実験によりその有効性を示した。

今後は包含関係にある概念や, 複数の属性を対象とした概念など, 概念間の関係も考慮し, 相互作用的に学習が進む方式についても検討を行いたい。

## 参考文献

- [1] 赤穂ほか 信学会論文誌, Vol.J80-A pp.1546-1553, 1997.
- [2] 小玉ほか 人工知能学会全国大会, 2004, 3F3-03.
- [3] 栗田ほか 信学技報, PRMU96-213 pp.159-164, 1997.
- [4] 石井ほか 信学技報, NLP97-142, pp43-50, 1998
- [5] 今井むつみ “ことばの学習パラドックス”, 共立出版, 1997