

Online-EM による語意学習機構と学習バイアスの適用

田口亮 木村優志 篠原修二 桂田浩一 新田恒雄

豊橋技術科学大学 大学院工学研究科

〒441-8580 愛知県豊橋市天伯町雲雀ヶ丘 1-1

E-mail: {taguchi, kimura, shinohara, katurada, nitta}@vox.tutkie.tut.ac.jp

あらまし 本報告は、幼児の言語獲得過程において観察される学習バイアスに基づく、効率的な語意獲得アルゴリズムについて述べる。語意獲得では、教示された音声画像のどの属性を指しているのかをエージェントが自ら同定しなければならない。これまでの語意獲得システムは、同定を属性間の確率計算から行うため、正確な同定を得るまでに多くの事例を必要とした。一方、人間の幼児の場合、幾つかの学習バイアスを組み合わせることで、効率的に対象の属性を同定する能力を持っている。エージェントも同様に確率計算からだけでなく、幼児が持つバイアスを利用することで、学習を効率化することが期待できる。本報告では、Online-EM アルゴリズムに基づく画像オブジェクトの語意学習法に、基準分布との比較に基づく対象属性同定法を導入することを提案する。また、学習バイアスを実装した語意獲得実験を通してその有効性を示す。

キーワード 語意学習, Online-EM アルゴリズム, 学習バイアス, Infant Agent

A Learning Mechanism of Word Meanings Based on the Online-EM algorithm and Application of Learning Biases

Ryo Taguchi, Masashi Kimura, Shuji Shinohara, Kouichi Katurada, Tsuneo Nitta.

Graduate School of Engineering, Toyohashi University of Technology

1-1 Hibariga-oka, Tempaku-cho, Toyohashi-city, 441-8580 JAPAN

E-mail: {taguchi, kimura, shinohara, katurada, nitta}@vox.tutkie.tut.ac.jp

Abstract . This paper describes efficient concept acquisition for an infant agent (IA) based on learning bias, or constraint, that is observed in human infant learning. Previous concept acquisition systems calculate probabilities to identify the correct attributes that each object has, however, such approaches need much examples to achieve high accuracy. In this paper, we propose to incorporate learning biases into the learning stage of a concept acquisition system based on an online-EM algorithm. The experimental results show that the proposed method can achieve efficient learning.

Keyword Learning of Word Meaning, Online-EM Algorithm, Learning Biases, Infant Agent

1. はじめに

IT 技術の進展と普及に伴うサービスの多様化とシステムの複雑化から、自然対話によるインタフェース技術への社会的要請が芽生えつつある。現在の人間-機械システムでは、一般に対話に利用する背景知識を、辞書や対話シナリオの形で与える必要がある。しかし、こうしたアプローチでは実世界の事物・事象に関する膨大な知識を開発者が記述しなければならないため、対話に使用する知識をシステム自らが学習・獲得していく機構の実現が望まれる。近年、上記の課題に対して、「人間-エージェント-実世界の事物・事象」との三項

関係を基に、単語の意味（語意）をエージェント自身の感覚・運動系の信号と対応付けて獲得させる、新しい語意獲得研究が行われ始めている [1][2][3][4]。

本報告では、画像オブジェクトをエージェントに提示し、そのオブジェクトに関連したラベルを教示し、語意を獲得させる課題を扱う。教示するラベルは、例えばオブジェクトの名前やオブジェクトが持つ属性を説明したラベル（「あか」や「まる」など）である。ただし、そのラベルがオブジェクトのどの属性を説明しているかは与えない。従って、エージェントはそのラベルが対象とする

属性を自ら導出しなければならない。類似の問題を扱った先行研究では、対象属性の導出を確率計算にのみ頼るが、語意の獲得に多くの事例を必要とした。実世界では、発話対象となりうる属性と、それらの組み合わせが無限に存在するため、全ての確率を計算することは現実的でない。効率的な語意学習を実現するには、確率計算に制約を取り入れるなど、効率的な対象属性同定法が必要と考える。我々は、発達心理学の分野で議論されている「学習バイアス」[5]をエージェント（以下、Infant Agent, IA）に実装する手法を提案し、語意獲得の効率化を試みている [6]。本報告では、前報と同様に(1) 単一属性を対象とするラベルのみ対象とする実験と、一歩進めて、(2) 複数属性を対象とした語意獲得実験を行う。語意学習アルゴリズムには Online-EM アルゴリズムを用い、ラベルに対するオブジェクト特徴を混合分布として学習する。学習した混合分布から計算される確信度（対象属性か否かの尺度）に、前述した学習バイアスを掛けることで、効率的に対象属性を同定する。語意獲得実験から、単一属性を対象としたラベルだけでなく、複数属性を対象としたラベルが教示される場合においてもバイアスが有効に作用すること示す。

2. Infant Agent による語意獲得

IA は人間の幼児が持つと推定される語意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語意を学習するエージェントである。以下、IA の語意獲得機構とバイアスの実装方法について述べる。

本報告では語意をラベルの対象となる属性と、その属性値（以下、特徴と呼ぶ）の範囲として定義する。例えば、「赤い」というラベルは、「色相属性を対象としたある特徴の範囲」と定義できる。本実験では、オブジェクト画像を見せながらラベルを教示することで、人間は IA に丸や赤、明るいなどの、IA のセンサ情報に直接対応した語意を獲得させる。ただしこの時、ラベルがどの属性を対象としているのかについては与えられない（複数の属性が対象となる場合もある）。そのため、IA はラベルとオブジェクト特徴の頻度から、(1)ラベルの対象属性セットと、(2)特徴の範囲、を学習しなければならない。(2)の特徴の範囲は、ラベルと特徴の共起確率を求めることで、学習することができる。本報告では、特徴の範囲を混合正規確率分布（以下、特徴分布と呼ぶ）とみなし、Online-EM 法[7]を用いて学習する。この方法は、

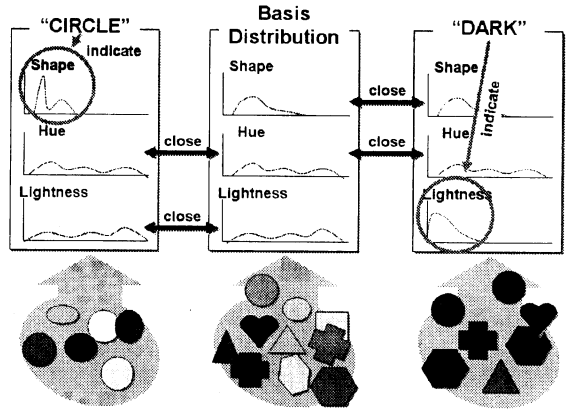


図1: On-line EM による語意の学習

学習の各段階で分布の生成・消滅・分裂を行い、逐次的に確率分布を推定することができる。一方、上記(1)の対象属性セットの同定には、各属性の特徴分布を利用する必要がある。ラベルがある属性を対象としている場合、その属性に関しては、一定の特徴で区別されたオブジェクト画像が入力されるため、学習した特徴分布にはその特徴に合わせた偏りが生まれる。一方で、ラベルの対象とならない属性に関しては、ラベルとは独立に事例が与えられるため、その特徴分布はラベルには依存しない分布となる。例えば、「まる」というラベルの場合、まるい形を持っている全てのオブジェクトに対して教示されるため、様々な色と明るさの特徴が与えられる。従って、学習された分布が前述のラベルに依存しない特徴分布に従っていれば不要な属性と判断することができる（図1参照）。本報告では、この各属性におけるラベルには依存しない特徴分布を基準分布 ($P_i(x_i)$) と呼ぶ。ここで x_i は入力された属性 i の特徴を指す。本実験では、教示以前に予め様々なオブジェクトを提示し、基準分布を学習させる。基準分布は、各属性共に多くのオブジェクト特徴を加算するため、学習が進むにつれて IA が置かれた環境内における特徴分布に近づく。

IA はラベル w が教示されると、Online-EM 法によって属性ごとの特徴分布 $P^w_i(x_i)$ を学習し、その結果から確信度 $Conf^w_i$ を計算する。確信度 $Conf^w_i$ は属性 i がラベル w の対象になっているか否かを判断する指標であり、学習された分布と基準分布の相関 ($Corr^w_i: 0 \sim 1$) から求める。そして、 $Conf^w_i$ が閾値 Th_i よりも小さい場合、属性 i はラベル w に不要であると判断する。

IA は特徴 $\mathbf{X}(\mathbf{X}=\{x_1, x_2, \dots, x_n\})$ が入力された場合、

学習した結果を用いて複数のラベルを出力する。具体的には、特徴 \mathbf{X} が入力された場合のラベル w の出力確率 $P^w(\mathbf{X})$ を次式により算出する。

$$P^w(\mathbf{X}) = \prod_{i \in \arg[\text{Conf}_i^w > Th_i]} P_i^w(x_i) \quad (1)$$

そして対象属性セットの等しいもの同士で $P^w(\mathbf{X})$ を比較し、最大の $P^w(\mathbf{x})$ を持つラベルを対象属性セットの数だけ出力する。

3. バイアスの定式化と学習機構への組み込み

3.1. 語意獲得のバイアス

ラベル付け学習において、対象属性を確率的に判断する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ラベルの意味を同定することが出来る。マークマンや今井らは、幼児が幾つかのバイアスを用いて学習することにより、これを実現すると説明している[5]。本報告ではそのうち、相互排他性バイアス、形状類似バイアスの二つを定式化して IA の学習機構に組み込み、語意獲得の効率を改善することを目指す。

3.2. 定式化と学習機構への組み込み

本報告では相互排他性バイアス、形状類似バイアスの二つを、未知のラベル w が与えられた時、コンテキストに応じて確信度 Conf_i^w を抑制するバイアス $B_i^w(t)$ と捉え、次式で定式化する。

$$\text{Conf}_i^w = (1 - \text{Corr}_i^w) \times B_i^w(t) \quad (2)$$

ただし、 $0 \leq B_i^w(t) \leq 1$ 、 t はラベル w の学習回数、 Corr_i^w は前節で説明した属性 i の特徴分布と基準分布との相関である。バイアス $B_i^w(t)$ は初めて w が教示された場合 ($t=1$)、以下の式で初期化する。

$$B_i^w(1) = E_i^w \times S_i \quad (3)$$

ここで、 E_i^w は相互排他性バイアス、 S_i は形状類似バイアスである。例えば、 $B_i^w(t)$ が低いと Conf_i^w は抑制され、この結果、属性 i は非対象属性とみなされ易くなる。以下 E_i^w および S_i の算出方法を述べる。

(1) 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

れる。類似のバイアスとしてコントラスト原理があるが、コントラスト原理は「同義語はない」という弱い制約であるのに対して、相互排他性バイアスはラベルの階層化（例えば「犬」と「動物」など）を抑制する。そのため、「犬」や「猫」など同一階層のラベル学習を効率化する。そこで、IA が既に目前の画像オブジェクトについて幾つかのラベル W' を知っており、これらとは異なる教示ラベル w が与えられたとき、新しいラベルは既知のラベルとは異なる属性（階層関係にならない）を指すとする傾向を、次式で表現した。

$$E_i^w = \begin{cases} 1.0 & (j_i \leq Th_i) \\ 0.5 & (j_i > Th_i) \end{cases} \quad (4)$$

$$\text{但し } j_i = \max_{w' \in W'} \left\{ \text{Conf}_i^{w'} \left(\frac{1}{1.0 + \exp(-\alpha(t^{w'} - \beta))} \right) \right\}$$

$\text{Conf}_i^{w'}$: 既知のラベル $w' \in W'$ の属性確信度
 $t^{w'}$: w' の学習回数

w' の学習回数が少ない場合、そのラベルはまだよく知らないとみなされ、確信度 $\text{Conf}_i^{w'}$ が抑制される。これによって、学習途中のラベルによって間違った相互排他性バイアスが掛かることを抑制している。

(2) 形状類似バイアス

形状類似バイアスは「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」と定義される。これは、未知のラベルを学習する際に、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、

$$S_i = \begin{cases} 1.0 & (i = \text{形状属性}) \\ 0.5 & (i \neq \text{形状属性}) \end{cases} \quad (5)$$

を与えることで形状以外の属性を抑制させる。ただし、すでに相互排他性バイアスにより、形状属性が抑制されている場合には、その働きを妨げないように無効とする。

(3) バイアスの減衰

教示手順次第では語意の獲得効率を低下させることがある（知識の無い状態で“あか”と教示を受けた場合、形状類似バイアスが働くなど）。そこで次の更新式を導入し、学習回数に応じてバイアスの効果を減衰させる。

$$B_i(t) = B_i(t-1) + \gamma[1 - B_i(t-1)] \quad (6)$$

ただし、 γ は減衰率 ($0 < \gamma < 1$) である。

4. 語意獲得実験

4.1. 実験用データ

4.1.1. 視覚情報

本実験で使用した画像オブジェクトは、3DCGのモデルをレンダリングし、394*306ピクセル、フルカラーのBMP形式として保存したものを使用した。オブジェクトは形状108パターン、色相100パターン、明度100パターンの計1,080,000通り作成した。図2に実験に使用したオブジェクトを示す。IAは与えられた画像オブジェクトから形状、色相、明度の3属性の特徴を抽出する。形状の特徴は、まず画像を2値化し細線化処理を施す。そして、その画像から24次元×3層(計72次元)の高次局所自己相関特徴[8]を求める。また、画像を占める割合の最も高い色のRGB値をHSV座標系に変換し、変換後のH成分とV成分をそれぞれ色相、明度特徴として利用する。HSV表色系へと変換することで、RGB表色系よりも人間の語彙体系との親和性の高い特徴量となる。

4.1.2. 聴覚情報

本報告では、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。教示ラベルは、単一の属性を対象にした21個と、複数の属性(形状と色相)を対象にした7個の計28個を用意した。具体的なラベル名は形状ラベルを「形状1」～「形状7」、色相ラベルを「色相1」～「色相7」、明度ラベルを「明度1」～「明度7」、複数属性ラベルを「複属1」～「複属7」とした。各形状と、ラベルの対応を図2に示す。色相と明度に関しては、それぞれの特徴空間を7等分し、ラベルを付与した。複数属性ラベルについては、形状特徴と色相特徴の組み合わせを7種類用意し、それぞれにラベルを付与した。例えば、「形状1」と「色相1」の特徴を持つオブジェクトに対しては、「複属1」と教示する。

4.2. 単一の属性を対象とした語意の獲得実験

4.2.1. 実験条件

教示ラベルは、21個(各属性7通り×3)とした。全てのラベルは単一の属性を対象とし、包含関係も無いようにしている。教示手順は以

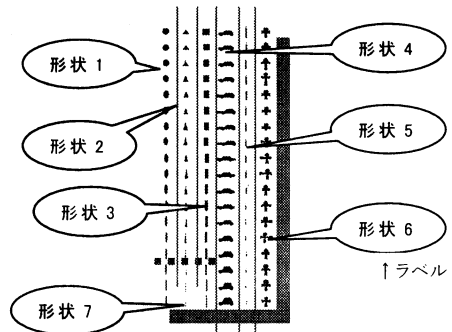


図2: 実験用画像オブジェクト

表1: 語意獲得実験に用いたパラメータ

Th _{形状}	0.2
Th _{色相}	0.4
Th _{明度}	0.4
α	0.5
β	20
γ	0.1

下の3通りで行った。

- ① 教示するラベルをランダムに決定する。
- ② 形状-色相-明度の順にラベルを教示する。
- ③ 色相-明度-形状の順にラベルを教示する。

なお、1回教示する度に200種類の画像オブジェクトをランダムに提示し、ラベルを正しく判断できるか否かを確認した。ただし、正しく判断できた場合でもラベルの対象属性が間違っている場合には不正解とした。学習に用いたパラメータを表1に示す。

4.2.2. 実験結果

まず提案手法によって語意が正しく獲得されることを確認するため、バイアスを適用せず前述した教示手順①(ランダム)で2000回の教示を行った結果を図3と4に示す。図3に学習終了時における、各ラベルが持つ色相属性の特徴分布を示す。横軸が色相の特徴値 x_i ($0 \leq x_i < 2\pi$)、縦軸が確率値 $P^{w_i}(x_i)$ である。図から色相ラベル「色相1」～「色相7」に関しては、それぞれの特徴空間を区分するように分布が学習され、形状ラベルの一つである「形状1」は基準分布と似た特徴分布が学習されたことがわかる。また、図4に学習終了時における、各ラベルの正解率を示す。「形状1」と「形状2」の正解率が若干低いが、他のラベルについて90%以上の高い正解率が得られた。この結果は提案手法によって正しく語意が獲得できることを示している。




図 3: Online-EM で学習された色相属性の特徴分布 (i =色相)




図 4: ラベルごとの正解率

次に、バイアスの有効性を検証する。図 5-7 は上記①～③の条件で、バイアス（制約）を適用した場合と、適用しない場合について、ラベルの平均正解率を比較したものである。横軸は教示回数、縦軸は平均正解率を示す（図 6,7 については教示しているラベルの平均正解率）。図 5 より、学習バイアスがない場合と比較し、バイアスを組み込むことの効果が大きいことが見て取れる。形状-色相-明度という順で教示した場合、初めの形状については形状類似バイアスが働き、色相、明度については相互排他性バイアスが働くため、正解率の立ち上がりが良くなっている（図 6）。色相-明度-形状という順で教示した場合には、形状以外のラベルについては間違っただけのバイアスを掛けることになるため、悪い影響が出るのが懸念された。しかし、学習回数に合わせてバイアスを減衰させることで正しい属性の判断ができるようになり、悪影響は見られず形状ラベルの獲得速度だけが向上した（図 7）。ただし、形状を優先して教示することで、最も効率良い語意学習を達成することができる。

4.3. 複数の属性を対象とした語意の獲得実験

4.3.1. 実験条件

複数属性を対象としたラベル 7 個を含む 28 個のラベルを教示する。教示手順は前述の①に従い、教示するラベルをランダムに決定する。他の実験条件は先の実験と同様である。




図 5: 正解率（ランダムに教示）




図 6: 正解率（形状-色相-明度の順で教示）




図 7: 正解率（色相-明度-形状の順で教示）

4.3.2. 実験結果

まずバイアスを適用しない場合の結果を図 8 に示す。図の濃い実線が複数属性を対象とした 7 個のラベルの正解率を平均したもので、薄い破線が単一属性を対象とした 21 個のラベルの正解率を平均したものである。図から約 1000 回の教示によって単一属性ラベル、複数属性ラベル共に 80%以上の正解率になることがわかる。この結果から、提案手法は単一属性ラベルと複数属性ラベルが混在する場合においても、正確にそれぞれの語意を学習できることが示された。なお、単一属性ラベルに比べ、複数属性ラベルの学習が早いのは、色相および明度属性を不要と判定する方が、形状属性を不要と判定するよりも簡単だからである。

図 9,10 ではバイアスを適用した場合としない場合の結果を比較している。図 9 は単一属性ラベルの正解率を平均したもので、濃い実線がバイア

スを適用した結果、薄い破線がバイアスを適用しなかった結果である。教示ラベル数の増加に伴って、学習速度が全体的に低下しているが、複数属性ラベルを含む教示があった場合も、単一属性ラベルにおけるバイアスの有効性は変わらないことが示されている。これは、先の実験と同様に形状ラベルの獲得速度が向上したことによる。また、図 10 は複数属性ラベル 7 個の平均正解率を示している。図から、複数属性ラベルにおいてもバイアスが有効に作用していることがわかる。実験に適用した二つのバイアスのうち相互排他性バイアスは、ある程度学習が進んだラベルを使用してバイアスを算出している。そのため、ランダムで教示した場合にはその効果が小さくなる。従って、今回の実験に影響を与えているのは形状類似バイアスである。本実験で用いた複数属性ラベルは形状と色相を対象としているのに対して、形状類似バイアスは新規のラベルの非形状属性（色相と明度）の確信度を抑制する。従って、この複数属性ラベルでは、対象属性となるべき色相に間違っバイアスが掛けられる事になる。しかし、バイアスが学習と共に減衰し、各分布の学習がある程度進むと、基準分布との相関が小さいままの色相属性は、バイアスが掛けられても高い確信度を維持する。一方、基準分布との相関が徐々に大きくなる明度属性は、バイアスが減少しても確信度が高くなり不要な属性として判定されやすくなる。そのため、バイアスを適用しない場合と比べ、正解率の立ち上がりが良くなる。この結果は、形状を含む複数属性ラベルに対する形状類似バイアスの有効性を示唆している。

5. まとめ

本報告は、Online-EM による語意獲得手法を提案すると共に、幼児の学習バイアスを考慮した効率的な語意獲得アルゴリズムについて検討した。今回は 2 つの学習バイアスを定式化するとともに、複数属性を対象とする語意の獲得実験を行った。実験の結果、単一属性ラベルだけでなく、複数属性ラベルにおいても形状類似バイアスが学習の効率化に有効であることが示された。相互排他性バイアスが複数属性ラベルの学習に与える影響の詳細については、今後、教示手順を変更した実験を通して明らかにしていきたい。




図 8: 複数属性を対象とした語意の獲得実験 (バイアスなし)




図 9: バイアスの有無の比較 (単一属性ラベル)




図 10: バイアスの有無の比較 (複数属性ラベル)

文 献

- [1] 中川, 升方, “視聴覚情報の統合化に基づく概念と文法の獲得システム,” 人工知能学会, Vol.10, No.4, pp.619-627, 1995.
- [2] 赤穂, 速水, 長谷川, 吉村, 麻生, “EM 法を用いた複数情報源からの概念獲得,” 信学会論文誌, Vol.J80-A pp.1546-1553, 1997.
- [3] 金, 岩橋, “知覚情報の統合に基づく言語音声単位の獲得アルゴリズム,” 信学技報, TL200-21, pp.9-16, 2000.
- [4] 小玉, 田口, 桂田, 岡部, 新田, “オンライン学習による Infant Agent のための効率的な概念獲得,” 人工知能学会全国大会, 2004, 3F3-03.
- [5] 今井, “ことばの学習パラドックス,” 共立出版, 1997.
- [6] 新田, 小玉, 田口, 木村, 桂田, “生得的学習バイアスを適用した Infant Agent による概念獲得,” 情報処理学会研究報告, SLP2005-57, pp69-74, 2005.
- [7] 石井, 佐藤, “オンライン EM アルゴリズムによる動的な関数近似,” 信学技報, NLP97-142, pp43-50, 1998.
- [8] 栗田, 小林, 三島, “PARCOR 画像の高次局所自己相関特徴を用いた背景変化および平行移動に強いジェスチャー認識,” 信学技報, PRMU96-213 pp.159-164, 1997.