

語意自動獲得における学習バイアスの効果

*木村優志, 田口亮, 篠原修二, 新田恒雄

豊橋技術科学大学 大学院工学研究科

〒441-8580 豊橋市天伯町雲雀ヶ丘 1-1

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

Abstract: 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。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。

1 はじめに

ことばが指示する対象を論理的に同定することは容易でない。これは「クワインの謎」として知られている問題である。例えば、図 1 の状況で「ガヴァガーイ」という未知のラベルを聞いたとする。「ガヴァガーイ」が示す意味を正しく獲得することは非常に難しい。ラベル「ガヴァガーイ」は「ウサギ」全体を指しているかも知れないが、他の可能性も存在する。例えば、「草むらの中にいるウサギ」かもしれないし、あるいは「白」や「長い耳」のようなウサギの部分の部分を指しているかもしれない。



図 1 クワインの謎

しかし、幼児は言語学習の際に、即時マッピングと呼ばれる驚くほど強力な推論能力を持つ。幼児は新しいことばを一度教わっただけで、そのことばの意味を推定し、おおむね正しい意味を獲得することが知られている。

この即時マッピングの問題への手がかりとして、今井らは幼児が語彙学習で利用している制約（バイアス）に着目している [1]。

本研究では、まずラベルが示す属性（色、形など）の判定を確率分布に従って行う方法を提案する。そして上述の学習バイアスの中から、相互排他性バイアスと形状類似バイアスの二つを定式化し、エージェントに組み込むことで学習効率が改善されることを示す。

2 語意獲得（システム）

2.1 対象属性の判定

エージェントは画像オブジェクトと共に提示されるラベルとの対応関係から、語意を獲得する。ここで、語意とは、ラベル w が示す属性と、オブジェクトから抽出された特徴 $X(X=(x_1, x_2, \dots, x_n))$ 、但し、 x_i は属性 i の特徴の確率分布 $p(x_i/w)$ とを指す。本報告では、ラベルが示す属性を対象属性と呼ぶ。ラベルの対象属性は複数ある場合もある。特徴の確率分布は Online-EM 法 [2] で混合正規分布として学習する。例えば、「まる」は形を対象とするラベルであり、「あか」は色を対象とするラベルである。エージェントにラベルを提示する際、そのラベルが、どの属性を対象としているのかは与えていない。そのため、エージェントはラベルに対応する特徴の確率分布から対象属性を判定しなければならない。例えば、形状を対象属性とするラベル「まる (CIRCLE)」と、明度を対

象属性とするラベル「くらい(DARK)」例を図 2 に示す。ラベル「まる」の形状属性の確率分布は、「まる」で示されるオブジェクトの形状属性に従った分布が学習される。一方、ラベルの非対称属性である色相・明度属性には様々な特徴が入力されるため平坦な分布となる。これから、平坦でない分布を持つ属性のみを対象属性とすればうまくいくように思える。ただし、これは非対称属性の特徴がランダムに出現したと仮定している。もし、出現した非対称属性の特徴が偏っていた場合、図 2 の「くらい」のように、この方法ではうまくいかない。「くらい」の対象属性である明度属性は「まる」の場合と同様の結果となるが、非対称属性で

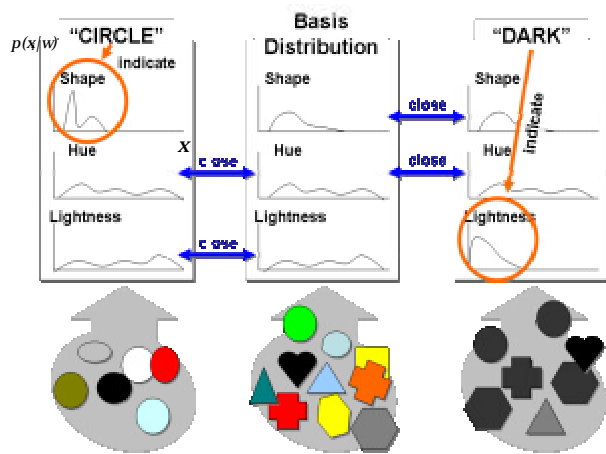


図2 Online-EM による語彙の学習

ある形状属性の確率分布は平坦な分布にならない。環境から出現する形状特徴がもともと偏っていたためである。「くらい」の形状属性を正しく非対称属性として判定するために、基準分布(Basis Distribution) $p(x_i)$ を導入する。基準分布 $p(x_i)$ は環境に存在する全てのオブジェクトから学習した、ラベルに依存しない確率分布である。 $p(x_i/w)$ が基準分布と似ている場合、その属性を対象でない属性として判定することで、特徴が偏っている環境でも、対象属性を正しく判断できる。

属性 i がラベル w の対象属性かどうかは確信度 $Conf_i^w$ を用いて決定する。 $Conf_i^w$ は基準分布 $p(x_i)$ と確率分布 $p(x_i/w)$ との相関 $Corr_i^w$ から計算する以下のように求める。

$$Conf_i^w = 1 - Corr_i^w \quad (1)$$

$Conf_i^w$ の値は $p(x_i/w)$ が基準分布と近い場合に 0 に近づき、基準分布と異なっているほど 1 に近づく。 $Conf_i^w$ が、閾値 Th_i より大きい場合、その属性をラベル w の対象属性として判定する。

あるオブジェクトが提示された際のラベル w の生起確率 $P(w|X)$ は次式により計算する。

$$P(w|X) = P(w) \prod_{i \in \arg\{Conf_i^w > Th_i\}} \frac{p(x_i|w)}{p(x_i)} \quad (2)$$

対象属性が同じラベルのうち、最大の $P(w|X)$ を持つラベル w を、オブジェクトのラベルとして判定する

2.2 語彙学習におけるバイアスとその実装

対象属性を確率分布のみから判断できるようになるためには、多くの事例が必要である。以下では、語彙学習バイアスのうち、形状類似バイアスと相互排他性バイアスを実装し、属性判定の効率化に役立てることを考える。

我々は、これらをコンテキストに応じて確信度を抑制するバイアス $B_i^w(t)$ と捉え、(3)式のように定式化する。ここで、 t はラベル w の学習回数を表し、 $B_Conf_i^w$ はバイアスを考慮した際の確信度を表している。バイアスを考慮する際には、(2)式で $Conf_i^w$ の代わりに $B_Conf_i^w$ を使用する。

$$B_Conf_i^w(t) = Conf_i^w \cdot B_i^w(t) \quad (3)$$

$$B(0) = E_i^w \cdot S_i$$

但し、 $0 < B_i^w(t) < 1$ 、 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、 $B_i^w(t)$ が低いとき $Conf_i^w$ は抑制され、属性 i は非対称属性とみなされやすくなる。

相互排他性バイアスは、「相異なるラベルが同じ事物に関連付けられることは無い」と定義されるものである。IA が既にオブジェクトについて幾つかのラベル w を知っており、新奇のラベル 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を示すとする傾向を、(4)式のように定義する。ここで、

c_i は、提示されたオブジェクトについて、既知のラベルの確信度を表している。

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

$$\text{但し } j_i = \max_{w' \in W'} \left\{ Conf_i^{w'} \left(\frac{1}{1.0 + \exp(-\mathbf{a}(t^{w'} - \mathbf{b}))} \right) \right\} \quad (4)$$

$Conf_i^{w'}$: 既知のラベル w' の属性確信度
 $t^{w'}$: w' の学習回数

未知のラベルのカテゴリを決定する際に、形状属性の類似性を最も重要視していることが知られており、これを形状類似バイアスと呼ぶ。我々はこのバイアスを未知のラベルの形状属性以外の確信度を抑制するものと捕らえ(5)式のように定式化する。

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

本研究では、これらのバイアスを、前節の対象属性の判定時に利用する。未知のオブジェクトに未知のラベルが提示された場合、形状類似バイアスにより、そのラベルが形状を対象としているものだと仮定する。また、いくつかラベルが既知であるオブジェクトに対して新奇なラベルが提示された場合、新奇なラベルは既知のラベルとは違う対象属性をさしていると推定する。学習するにつれて、エージェントはラベルの確率分布から対象属性の判定ができるようになる。そのため、上記バイアスの効果をラベルの学習回数に応じて減らしている。

$$B_i^{w'}(t) = B_i^{w'}(t-1) + \left[1 - B_i^{w'}(t-1) \right] \quad (6)$$

但し、 α は減衰率 ($0 < \alpha < 1$)

3 実験

実験では、画像オブジェクトを IA に提示し、オブジェクトに関連するラベルを教示して語意を獲得させる。オブジェクトの属性は、形状、色相、明度の3つを用いる。ラベルを教示する際には、ラベルがオブジェクトのどの属性を示すかは与えない。形状特徴は、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24次元×3層(計72次元)の高次局所自己相関特徴[3]を求め、形状特徴として使用した。また、オブジェクト画像のRGB情報をHSV変換し、そのH成分を色相特徴、V成分を明度特徴として使用した。学習バイアスの効果を確認するために、(1)単一属性を示すラベルの学習実験と(2)複数属性(形状、色相)を示すラベルの学習実験を行った。

実験では、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個のオブジェクトを使用した。教示ラベルは単一の属性を対象としたものを各属性について7種類ずつ、計21種類を用い、300ターンごとに教示・評価ラベルの




図3 正解率 (形状-色相-明度の順で教示)




図4 正解率 (色相-明度-形状の順で教示)



図5 バイアスの有無の比較 (複数属性ラベル)

対象属性を変えている。実験(2)では、実験(1)と同様のオブジェクトに対し、形状と色相を対象とするラベル7種類を加えた計28種類のラベルを用いている。この実験では、ラベルはランダムに提示する。

実験(1)の単一属性の実験からは、バイアスを組み込むことにより、学習が加速することがわかる。教示ラベルを形状-色相-明度の順に変えた実験の結果を図3に示す。色相-明度-形状という順に変えた実験の結果を図4に示す。実験途中で、正解率が0に落ちるのは、300ターンごとに評価する属性も変わっているためである。図3では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速くなる。図4の教示手順では、形状以外のラベルに対して間違ったバイアスを掛けることとなるため悪影響が出ることが懸念された。しかし、図4のからは正しい属性の判定ができており、形状ラベルの獲得速度が向上することが分かる。これは、(6)式に従って、ラベルの学習回数に応じてバイアスの効果を減衰させたことで、正しい属性の判定ができるようになったからだと考えられる。

実験(2)の形状と色相の二つの属性を示すラベルを学習する実験の結果を図5に示す。この実験ではバイアスにより学習が加速することがわかる。学習初期には形状類似性バイアスが強く作用するため、非形状属性(色相と明度)が不要な属性と判定される。しかし、各特徴分布の学習がある程度進むと、色相属性の特徴分布の確信度が高くなるため、対象属性と判定されるようになる。一方、ラベルの対象とならない明度属性は、学習が進むにつれて基準分布に近づき、対象属性ではない判定される。この効果により、学習バイアスを組み込んだIAは、これを適用しないIAと比較して学習効率が高くなる。実験(1)および実験(2)の実験結果は、形状を含む単一・複数属性ラベルに対する、相互排他性バイアスと形状類似性バイアスの有効性を示唆している。

4 まとめ

本稿では、学習したラベルとオブジェクト特徴分布から、ラベルに対応するオブジェクトの属性を判定する方法を示し、これに幼児の語彙獲得バイアスを実装することで効率的に対象属性の選択ができることを示した。

参考文献

- [1] 今井: ことばの学習パラドックス, 共立出版, 1997
- [2] 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
- [3] 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.