

顕著性に基づくロボットの能動的語彙獲得

菊池 匡晃^{*1} 荻野 正樹^{*2} 浅田 稔^{*2*3}

Lexical acquisition using the active nature based on saliency

Masaaki Kikuchi^{*1}, Masaki Ogino^{*2} and Minoru Asada^{*2*3}

Observational studies of human infants tell us that they can successfully acquire lexicon and that the relationship between the meaning and the uttered word can be understood from only one teaching session by a caregiver, even though there are many other possible mappings. This paper proposes a lexical acquisition model that makes use of curiosity to associate visual features of observed objects with the labels that are uttered by a caregiver. A robot changes its attention and learning rate based on the curiosity. In experiments with a humanoid robot, the visual features are represented using self-organizing maps that adaptively represent the shape of the observed objects independent of viewpoint.

Key Words: lexicon acquisition, saliency, hebbian learning, self-organizing map, humanoid, curiosity

1. はじめに

近年さまざまなロボットが開発され、実社会において人間と共に活動することが期待されている。人間と共に活動するためには、人間の生活環境や言葉など多くの知識を持っている必要があるが、これらの情報をあらかじめ全てロボットに与えることは事実上不可能である。そのため、ロボットが生活する間に得た世界の情報をもとに、実世界に根ざした世界の理解をすることが重要である。これまでもロボットへの実装を通じた構成論的手法に基づく語彙獲得の研究が行われてきた。ロボットが受動的に観測した視覚的特徴量とラベルの同時生起性に基づく統計処理による語彙獲得 [1-4] が多くとられてきたアプローチである。しかし、このような統計処理では語彙の獲得までに多くの事例を必要とし、人間の幼児に見られる語彙爆発を説明することはできない。1つの事例に対する漠然とした指さしから、発話された言葉の意味を推測することは論理的に非常に困難であるにも関わらず、人間の幼児はほとんどの場合、即時に言葉に意味を付加することができる。この現象は様々な制約でラベル付けする対象を絞ることによって起こると考えられており、Markman [5] は事物全体原理、相互排他原理などによる制約を、Landau et.

al. [6] は形状類似バイアスによる制約を提案している。また語順による制約も考えられ、視覚情報とそれを説明する文章から得られる文法構造などの情報を用いて語彙や語彙のカテゴリーの獲得を目指した研究 [7-10] も行われている。

しかし、これまでの研究では学習者が受動的に観測した情報を基に学習していくアプローチがほとんどであり、学習者の能動的な行動については考慮されてこなかった。人間の幼児が受動的に得られる情報のみで言葉を学習しているとは考えにくく、近年、学習者の能動的な性質を考慮した研究も行われている。小島 [11] らは提示された複数の物体から全体の既知度の増分が最大となる物体をロボットが選択し、人間に情報を要求することで語彙学習の効率を高めている。一般的に、乳児は新奇な事象に対して興味を持ち、既知の事象よりも長く注視することが様々な実験によって示されている。このような能動的な選好性は、新奇な事象についての情報をより多く集めようとしていると考えることができ、語彙の獲得にも役立っていると考えられる。

そこで、本研究ではロボットが自身の感じる顕著性 (saliency) に基づき、能動的に注視する対象を探索、選択し、さらに顕著性をバイアスとして学習していくことで語彙を効率よく獲得していくシステムを提案する。また実環境下での語彙獲得を考えると、見る方向によって物体の形状が異なって見えるため、正しくラベル付けができないという問題が起こる。そこで人間の視覚野をモデル化した特徴抽出器をロボットが学習によって獲得していく、視点によらないロバストな物体認識システムを提案する。この認識システムを用いてヒューマノイドロボットに提案する語彙獲得システムを実装し、実環境下で視点の違いに

原稿受付

^{*1}株式会社 東芝

^{*2}JST ERATO 浅田共創知能システムプロジェクト

^{*3}大阪大学大学院工学研究科知能・機能創成工学専攻

^{*1}TOSHIBA CORPORATION

^{*2}JST ERATO Asada Synergistic Intelligence Project

^{*3}Dept. of Adaptive Machine Systems, Graduate School of Engineering, Osaka University

よらず正しい語彙が獲得されることを示す。

2. 顕著性を利用した語彙獲得

ロボットが環境中に存在する対象物の特徴に関する語彙を、養育者とのコミュニケーションを通して獲得していくタスクを取り扱う。ロボットは対象物の視覚特徴量として色、形状の属性についての特徴量が得られる。ただし属性と特徴量との関係はロボットにとって未知であり、属性のカテゴリの識別はできない。また養育者が教示する全てのラベルは単一の属性をさし、包含関係はないものとする。

2.1 システムの構成

提案システムの概要を Fig. 1 に示す。学習は以下のように行われる。

- (1) 視野内の対象物のなかから顕著性の高い特徴をもつ対象物を選択し注視する。顕著性の高い特徴をもつ対象物がない場合には周囲を探索する。
- (2) 対象を指差し、養育者に教示を求める。その際に知っているラベルを発話して知識を養育者に伝える。観測している特徴量にマッピングされているラベルを発話するため、発話は正しいとは限らない。
- (3) 養育者から教示されたラベルと対象物の特徴量の対応関係を Hebb 学習によって固定化する。この際に顕著性によるバイアスをかけ、顕著性の高い特徴量ほどラベルと結びつきやすくする。
- (4) 顕著性を感じなくなるまで注視し、次の対象物を探索する。

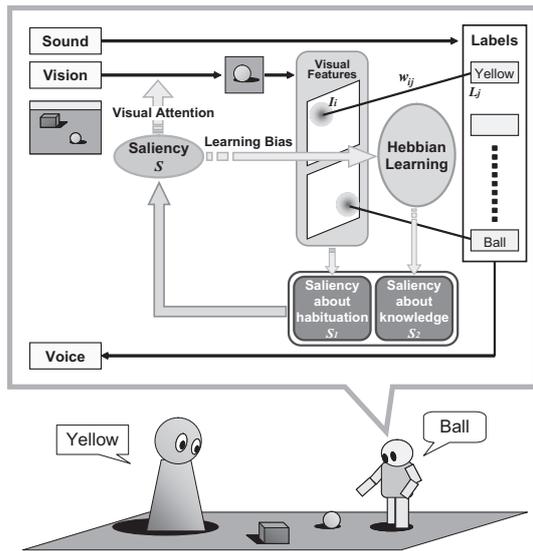


Fig. 1 An overview of the proposed system for lexical acquisition based on curiosity

2.2 顕著性のモデル化

ロボットは視野内にある対象物の中から最も顕著性の高い特徴量をもつ対象物を注視対象とし、顕著性の高い対象物が視野内にない場合には、見つかるまで周囲を探索する。各特徴量に対してロボットの感じる顕著性は馴化による項 S_1 と知識による項 S_2 2つの項の積であらわされる。

2.2.1 馴化による項 S_1

S_1 は頻繁に観測される特徴量に対しては慣れ (馴化: habituation) で顕著性は低くなり、逆に、初めて観測される特徴量または長期間観測されていなかった特徴量に対しては高くなる (自発的回復: spontaneous recovery) ことをあらわす。 S_1 によって目新しい特徴に注目して語彙を学習し、効率的に未学習の特徴量を探索できることが期待される。特徴 i に対する馴化による項 S_1^i は時刻 t では以下のように更新される。

$$S_1^i(t) = S_1^i(t-1) + \Delta S_1^i(t-1) \quad (1)$$

$$\Delta S_1^i(t) = \frac{\alpha(1 - S_1^i(t)) - \beta S_1^i(t) I^i(t)}{\tau} \quad (2)$$

ただし初期値は $S_1(0) = 1$ である。各記号の意味は以下のとおりである。

α : 自発的回復 (spontaneous recovery) の早さを決める定数

β : 馴化 (habituation) の早さを決める定数

τ : 時定数

I^i : 特徴 i が観測されるときは 1, そうでないときは 0 となる値

S_1 の変化の様子を Fig. 2 に示す。 S_1 は観測している場合 ($I^i = 1$) には下がり、そうでない場合には上昇している。

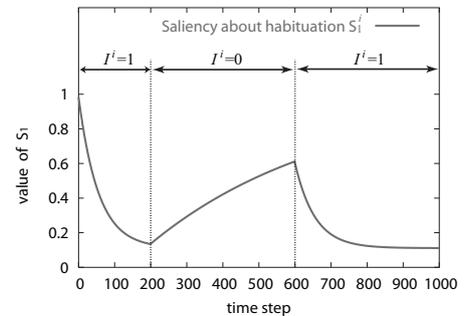


Fig. 2 An example of the time course of the saliency S_1

2.2.2 知識による項 S_2

S_2 はラベルを知っている特徴量に顕著さを感じなくなることをあらわす。すでにラベルにマッピングされている特徴量に対して S_2 は低くなり、ラベルにマッピングされていない特徴量に対して高くなる。すでにラベルと結合されているニューロンに対して、新たなラベルが結合されるのを抑制するようなバイアスをかけると、語彙獲得が加速すると期待される。特徴量とラベルの対応関係の学習には Hebb 学習を用いるため、ロボットにとって知識は特徴抽出 SOM のニューロンとラベルの結合強度 w にあたる。ラベル l から i 番目のニューロンへの結合強度を $w_{l \rightarrow i}$ とあらわす (Fig. 3) と、 i 番目のニューロンと最も強く結びついているラベル L は

$$L = \arg \max_l (w_{l \rightarrow i}) \quad (3)$$

となる (Fig. 4)。このラベル L との結合度 $w_{L \rightarrow i}$ が高いほど i 番目のニューロンに対応するラベルの知識を持っているといえ

る．そこで知識による項 S_2^i をシグモイド関数を用いて

$$S_2^i = 1 - \text{sigmoid}(w_{L \rightarrow i}) \quad (4)$$

$$\text{sigmoid}(w) = \frac{1}{1 + e^{-\gamma(w-\theta)}} \quad (5)$$

と定義する．ここで γ は立ち上がりの傾きを決めるパラメータ， θ は閾値を決めるパラメータである．Fig. 5 に S_2 の変化の様子を示す． $w_{L \rightarrow i}$ が大きくなると S_2 が小さくなるのがわかる．

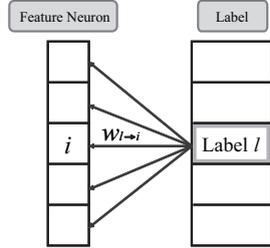


Fig. 3 The knowledge of a robot is described by the connection weights.

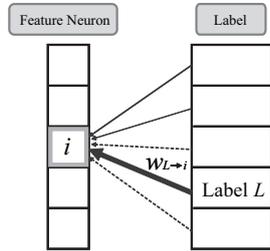


Fig. 4 The knowledge of the i -th feature neuron is described by $w_{L \rightarrow i}$ that is the highest value among $w_{l \rightarrow i}$.

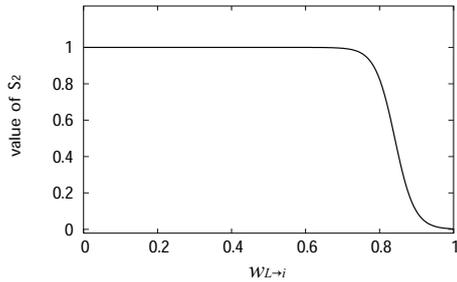


Fig. 5 The second saliency S_2 in terms of $w_{L \rightarrow i}$

2.2.3 最終的な顕著性 S

i 番目の特徴量のニューロンに対する顕著性 S^i を以下のように定義する．

$$S^i(t) = (S_1^i(t) + c_1) (S_2^i(t) + c_2) \quad (6)$$

ただし c_1, c_2 は定数である．

2.3 顕著性に基づく能動的選択

ロボットは顕著性に基づいて能動的に注視対象を選択する．見えている複数の対象物の中から最も目を引く（顕著性の高い）対象物を選択して注視するものとする．視野内に存在する対象物についてそれぞれ観測された特徴量 I と顕著性 S の各成分ごとの積の最大値 M を求める． n 番目の対象物に対応する M は

$$M_n = \max_i (I_n^i S^i) \quad (7)$$

として求められる．最終的に注視する対象物 N は

$$N = \arg \max_n M_n \quad (8)$$

となる．ただし， M_N が閾値よりも小さいときには目を引く対象物がないとして，見えている対象物は注視せず，周囲を探索して別の対象物を探索する．

2.4 顕著性バイアスを適用したラベルのマッピング

特徴量抽出 SOM のニューロンの活性度をあらゆる特徴量 I へのラベルのマッピングには Hebb 学習を用いる．ある特徴量 I が入力されたとき，ラベル l に対応するニューロンの活性度を a_l とすると，

$$a_l = \sum_i I^i w_{l \rightarrow i} \quad (9)$$

が閾値を超えたときにラベル l が発話される．あるラベル l が教示されると，そのとき活性化している特徴量ニューロンとラベル l をあらゆるニューロンの結合を強める．結合荷重を更新する際には顕著性によってバイアスをかけ，顕著性の高い特徴量ほどラベルと強く結び付けられる．結合荷重 w_l の更新式は

$$\Delta w_{l \rightarrow i} = \epsilon a_l (I^i - \text{threshold}) S^i \quad (10)$$

となる．ただし $w_{l \rightarrow i} \geq 0$ とする． i 番目の特徴量ニューロンの活性度が閾値を超えているときには結合を強め，超えていない場合には結合を弱める．ラベル l が教示されたときは $a_l = 1$ ，教示されなかったときは $a_l = 0$ ，自分で発話したときは $0 < a_l < 1$ の範囲の定数とした．また，発話したラベル l が間違いであると訂正された場合には，そのラベルの結合を

$$\Delta w_{l \rightarrow i} = -\epsilon' I^i \quad (11)$$

と更新し，観測されている特徴量との結合を弱める．また， w_l はノルムを 1 に保つように学習ステップごとに正規化される．学習率 ϵ は，顕著性の知識による項 S_2 を用いて

$$\epsilon = c S_2^n \quad (12)$$

$$n = \arg \max_i (w_{l \rightarrow i}) \quad (13)$$

と定義する． c は定数である．すでにラベル l が特徴量 n と結びついているときには S_2^n は小さな値となり，他の顕著性の高い特徴量に結合されることを防ぐことが期待される．訂正時には顕著性に関係なく結合を修正するために，学習率 ϵ' は定数とする．

3. シミュレーション

3.1 実験設定

ロボットは環境中に存在する対象物の特徴をあらわすラベルを学習していく。シミュレーションでは色、形状だけでなく大きさ、重さ、硬さの合計 5 種類の属性についての特徴量をロボットは観測することができるとした。対象物は色 40 通り、形 80 通り、大きさ、重さ、硬さはそれぞれ 8 通りのバリエーションを持ち、ロボットは各特徴量に対応する合計 144 のラベルを学習する。養育者は以下のようにラベルを教示する。

- ロボットの発話が正しいまたは発話なしの場合、養育者は発話されていないラベルのうち 1 つを教示する。
- 発話が誤りの場合、発話されたラベルが誤りであると教え、同じ属性の正しいラベルを教示する。
- 全ての属性について発話が正しい場合には何も教示しない。

提案手法の有効性を検証するために Hebb 学習の際の顕著性によるバイアス (Bias) と注視対象の能動的選択および探索 (Search) の有無によるパフォーマンスを比較する。また環境の設定として全ての対象物が一様に分布している環境 (一様分布環境 Fig. 6(a)) と観測可能な対象物が段階的に増えていく環境 (段階的学習環境 Fig. 6(b)) の 2 通りを考える。一様分布環境では、ロボットは全ての対象物を始めから観測することができる。段階的学習環境における初期状態では各属性について 3 通りのバリエーションをもった対象物が環境中存在しており、顕著性 S の値が閾値以下の特徴しか周辺にないとロボットが判断したタイミングで、新たな特徴量を含んだオブジェクトを提示する。 n 回目の追加段階時には n 個のオーダーで新しい特徴を追加する。

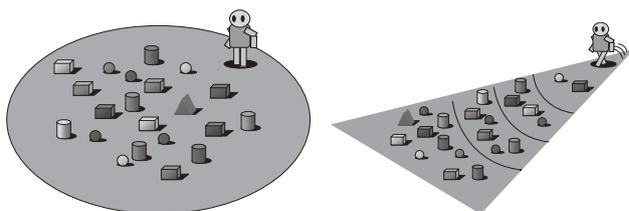
それぞれの実験環境において以下の 4 通りの条件でシミュレーション実験を行う。

- (1) No Bias, No Search
- (2) With Bias
- (3) With Search
- (4) With Bias, Search

顕著性による学習バイアスなしの場合の学習則は

$$\Delta w_{l \rightarrow i} = \epsilon a_l (I^i(t) - \text{threshold}) \quad (14)$$

とする。また能動的選択ありの場合、ロボットは視野内の複数の物体から顕著性のもっとも高い特徴をもつ対象物を能動的に選択する。



(a) An uniform environment (b) An incremental environment

Fig. 6 Two kinds of environments

3.2 実験結果

それぞれの条件で 10 回ずつ試行した結果、Fig. 7, 8 に示す学習曲線が得られた。横軸が学習ステップ数を、縦軸が正しく獲得された語彙数を示している。ただし養育者がラベルを教示し、ロボットが Hebb 学習のネットワークを更新するまでを 1 ステップとした。なお、正しいラベルと特徴量との結合度が $w_{l \rightarrow i} > 0.9$ を満たした場合に語彙を獲得したとみなし、全ての語彙を獲得するまでを 1 試行とした。

またそれぞれの条件での発話語数とそのうちの誤り語数のグラフを Fig. 9, Fig. 10 に示す。横軸が学習ステップ数を、縦軸が発話および誤りの語数を示している。さらに 1 つの語彙を獲得するまでに要した教示の回数の統計を Fig. 11, Fig. 12 に示す。横軸が語彙を獲得するまでに要した教示回数を、縦軸がその教示回数で語彙を獲得した語数を示している。

提案手法により語彙が非常に効率よく獲得され、一様分布環境では単純な Hebb 学習と比較しておよそ 1/3 の学習ステップ数で、段階的学習環境では単純な Hebb 学習と比較しておよそ 1/4 の学習ステップ数で全ての語彙を学習することができた。以下では、それぞれの条件の影響について検証する。

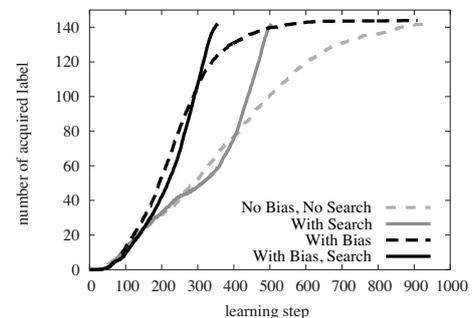


Fig. 7 Learning curves in the uniform environment

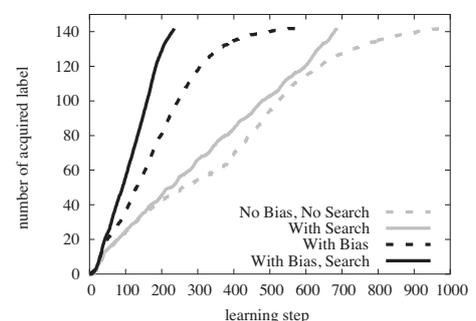


Fig. 8 Learning curves in the incremental environment

3.2.1 能動的選択の影響

学習曲線は注視対象の能動的選択の有無で傾向が異なる。一様分布環境について見ると、能動的選択がない場合には、学習後期の収束が非常に遅い。これは対象物がランダムに提示されるので、冗長な学習が多く行われているためだと考えられる。このことは Fig. 9(a), (c) において、全て正しいラベルを発話している期間が学習後期に長く続いていることからわかる。逆

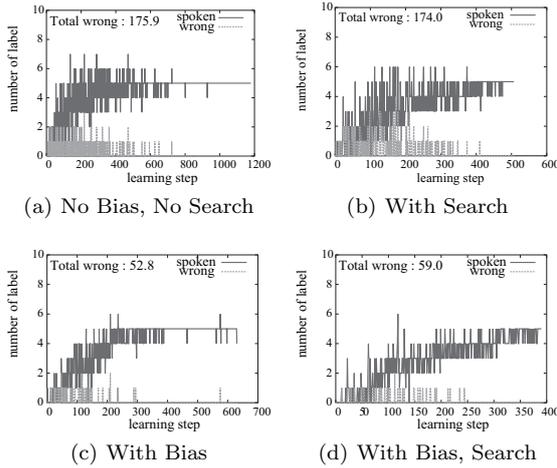


Fig. 9 The number of spoken labels and wrong labels in the uniform environment

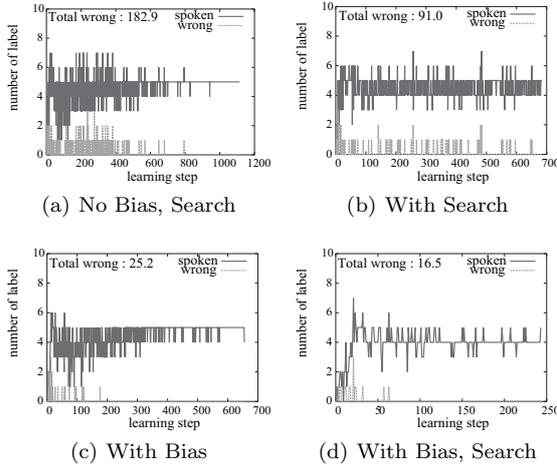


Fig. 10 The number of spoken labels and wrong labels in the incremental environment

に能動的選択がある場合には学習の収束性が非常によくなった。Fig. 11(a), (b) を比較すると、語彙の獲得に要する教示回数はほぼ同じであることから、能動的選択によって効率よく学習できる対象物を選択できているといえる。段階的学習環境においてもほぼ同様の傾向が見取れる。

3.2.2 学習バイアスの影響

学習曲線から、バイアスがある場合には学習中期から急速に語彙数を伸ばすことがわかる。Fig. 9, Fig. 10 を見ると、顕著性による学習バイアスがある場合 (Fig. 9(c), (d) および Fig. 10(c), (d)) とない場合 (Fig. 9(a), (b) および Fig. 10(a), (b)) で、誤ったラベルを発話する語数が大きく変化している。Fig. 11, Fig. 12 から学習バイアスがある場合には、語彙獲得までの教示回数のピークが左にシフトしており、少ない教示で効果的に正しいラベルとマッピングができていているといえる。そのため誤ったラベルを発話する語数が少なくなったと考えられる。

3.2.3 学習環境の影響

学習曲線から、段階的学習環境では学習初期の立ち上がりが早くなっている。これは限られた少数の対象物から段階的に学

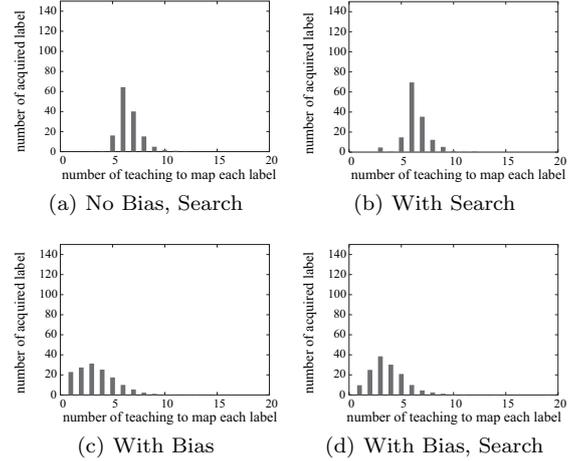


Fig. 11 The number of teaching upon mapping each label in the uniform environment

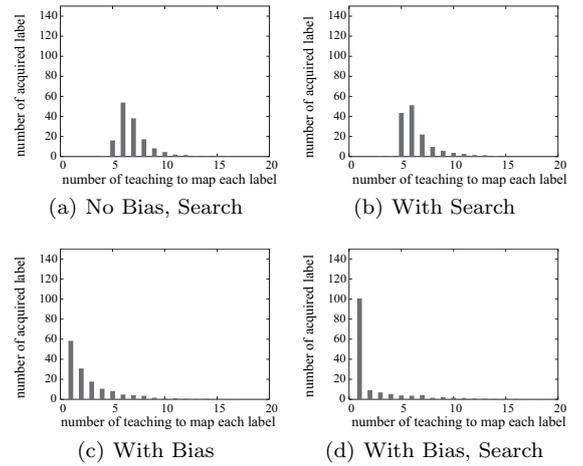


Fig. 12 The number of teaching upon mapping each label in the incremental environment

習していくためであり、Fig. 10 を見ると、学習初期からロボットは多くのラベルを発話していることがわかる。また顕著性による学習バイアスがない場合、学習初期の立ち上がりは早い新しい対象物が増えるにつれてパフォーマンスが悪くなっている (Fig. 13)。段階的学習環境では、学習データの分布に偏りが生じてしまい、統計的手法である Hebb 学習では学習中期以降にパフォーマンスが落ちてしまったと考えられる。

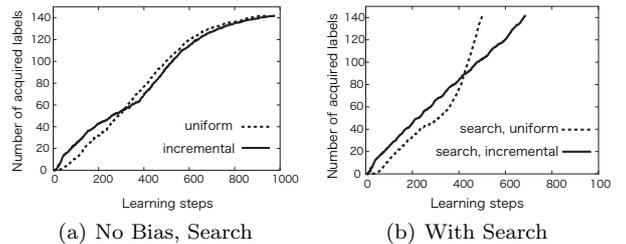


Fig. 13 Comparison between uniform and incremental environments (No Bias)

一方、学習バイアスがある場合には、一様分布環境の結果と比較して全般的にパフォーマンスが良くなっている (Fig. 14). Fig. 12(c), (d) を見ると、他の条件と比較して1回の教示でマッピングができていた語数が非常に多いことがわかる. 特に能動的選択と共に適用した場合 (Fig. 12(d)), 全体の語数の約7割にあたる100語程度を1回の教示で即時にマッピングすることができている. 学習バイアスによって顕著な特徴量に注目して学習することができるため、段階的学習環境では特に大きな効果を示すと考えられる.

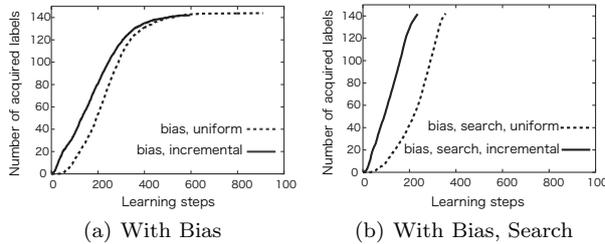


Fig. 14 Comparison between uniform and incremental environments (With Bias)

4. 実ロボットによる語彙獲得実験

次に提案システムをヒューマノイドロボットに実装し、実環境下においても語彙獲得が実現されることを示す. 実環境下では、同じ対象物でも視点が異なると見え方も異なる、また同じ色でも照明条件によって異なる色に見えるという問題が起こる. 実環境下での語彙獲得を検証するためにはこの問題を解決する必要があり、本章ではヒトの脳での処理をモデル化した、視点によらない物体認識システムを提案する. この物体認識システムを用いて実ロボットによる語彙獲得タスクを行う.

4.1 視覚特徴量の抽出

ヒトは実環境において非常にロバストな物体認識をすることができる. ヒトの脳では網膜に映った情報は低次視覚野から処理されていき、最終段のTE野から他の脳部位へ分配されている. 本研究ではこの低次視覚野からTE野までの流れをモデル化して物体認識に用いる.

4.1.1 ヒトの脳の視覚処理のモデル化

Tanaka [12] はTE野では異なっているが、関連した図形特徴を表現する数個の列が互いに重複していることを示唆する実験結果を示している (Fig. 15). そこで、TE野のモデルとして、教師なし学習によるニューラルネットワークの一種である自己組織化マップ (SOM) を用いる. SOMは次元圧縮によるベクトル量子化が可能であり、入力の種類に基づいてクラスタリングをすることができる.

また、低次視覚野のモデルとしてガボールフィルタを用いる. ガボールフィルタは Jones et. al. [13] によって低次視覚野であるV1野とよく似た特性を持つことが示されている.

4.1.2 特徴抽出器の獲得

ロボットは、それぞれの属性について観測された原特徴データを SOM によってクラスタリングし、原特徴をニューロンの数に量子化する. 学習後には各属性の原特徴がそれぞれの SOM

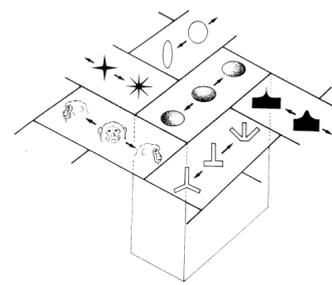


Fig. 15 A mimetic diagram of the minute space structure in area TE (Tanaka, 1996)

に入力され、各ニューロンの活性度を並べたベクトルを、観測された特徴量としてロボットは認識する (Fig. 16).

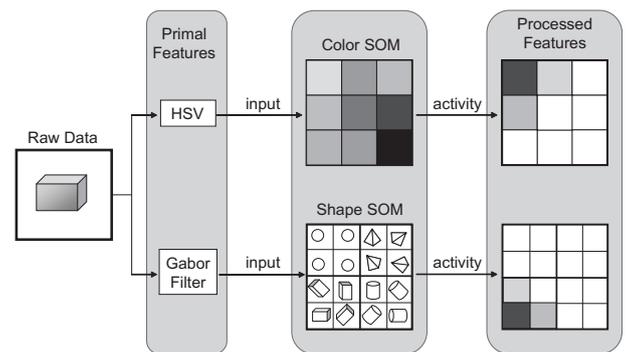


Fig. 16 The flow of feature extraction process

通常、SOMは最も距離の近い (類似度の高い) ニューロンが勝者として発火するが、ここではニューロンの活性度 a を以下のシグモイド関数の形で定義する.

$$a = 1 - \frac{1}{1 + \exp^{-\gamma(d - \text{threshold})}} \quad (15)$$

d は入力とニューロンの代表ベクトルとの距離であり、今回の実験ではベクトル間のユークリッド距離を用いた. 色、形状の SOM のニューロンの数をそれぞれ n_c, n_s とし、 i 番目のニューロンの活性度を a^i ($0 \leq a^i \leq 1$) とするとロボットの認識する特徴量 I は以下の式で表される.

$$I = \begin{pmatrix} a_c^0 \\ \vdots \\ a_c^{n_c} \\ a_s^0 \\ \vdots \\ a_s^{n_s} \end{pmatrix} \quad (16)$$

なお対象物はあらかじめ指定された背景色以外の領域として切り出されて認識される. 色の原特徴量として対象物の HSV 値の平均値を使い、形状の原特徴量としてガボールフィルタを用いた特徴ベクトルを使う. Fig. 17(a) にガボールフィルタを適用した例を示す. 原特徴ベクトル作成のために、ガボールフィルタをかけた画像に、互いに重なり合う受容野を格子状に配置

する．その受容野の中心からの距離で重み付けしたピクセル値の総和 P をとる．全ての受容野およびガボールフィルタのパラメータについて P を並べたベクトルを形状の原特徴量として用いる．実験では 3×3 の計 9 つの正方形の受容野を配置した (Fig. 17(b))．またガボールフィルタのパラメータは $r = (4, 8)$ $\theta = (0, 60, 120, 180, 240, 300)$ とした．よって形状の原特徴ベクトルは $9 \times 2 \times 6 = 108$ 次元となる．

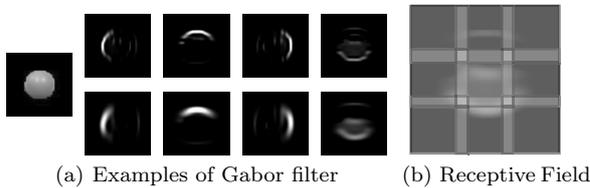


Fig. 17 Primal features on shape

4.2 視点の違いによらない物体認識

実環境下においては同一対象物であっても視点の違いによって全く異なる画像情報になってしまうという問題が起きる．そのため単純に画像特徴量とラベルのマッピングをすることは困難である．そこで連続して観測している画像特徴量は異なっても同じ対象物をあらわすクラスに属する，という連続性の仮定をおく．学習器は複数の小さな SOM が動的に増減，融合する構造を持つものとする．ひとつの小さな SOM を形状の特徴量をあらわすニューロンとみなして，小さな SOM 内の最も高い活性度をその SOM の活性度とする．この仮定のもとに，次のようにクラスタリングを行う．

- (1) 注視する対象物を決めると，ロボットは対象物と相互作用して画像特徴量のデータを集める．
- (2) その間に学習済みの SOM が発火した場合は，相互作用終了後に集めたデータをその SOM に入力し追加学習をする．
- (3) 全ての SOM が発火しなかった場合は新規対象物とみなして，新しい SOM を作成し，集めたデータを学習する．
- (4) 相互作用の間に複数個の SOM が発火した場合には，同じ対象物を視点の違いによって別の対象物と思い込んでいたとみなして，発火した SOM を融合する．

形状における特徴抽出 SOM の学習の流れを Fig. 18 に示す．色における学習も同様に行われる．なお SOM への追加学習や複数の SOM の融合の際には，SOM のニューロンの代表ベクトルと追加データを新たな学習データとして SOM の学習を行う．小さな SOM では学習が収束しない場合があるが，その場合には SOM のニューロンの数を自動的に増やして再学習することで，このような問題を解決する．

4.3 実環境下での語彙獲得タスク

4.3.1 実験設定

実験はカメラを備えたヒューマノイドロボットを用いて行った．実験環境を Fig. 19 に示す．環境中には色 3 種類 (Blue, Pink, Yellow)，形状 3 種類 (Ball, Box, Pyramid) の計 9 つの対象物が存在する．ロボットは首を振って対象物を注視する，歩行して対象物に近づく，キック動作をして対象物と相互作用する (Fig. 20(a))，対象物を指差して養育者にラベルの教示を求める (Fig.

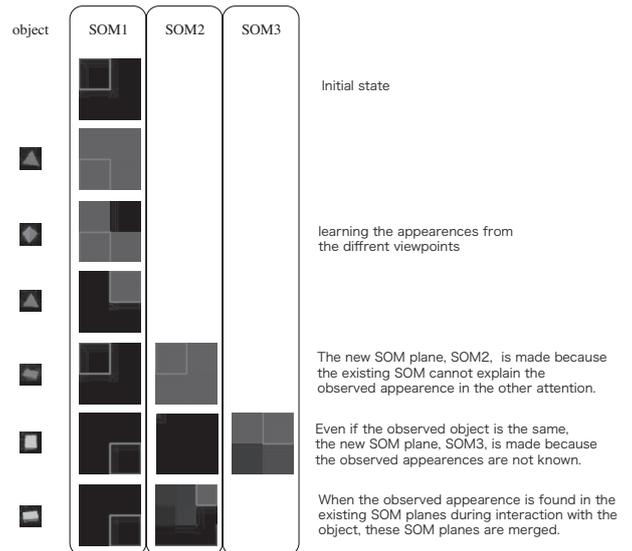


Fig. 18 The flow of learning of the shape SOM

20(b)) などの行動をとることができる．ロボットは能動的に対象物と相互作用し，さまざまな視点から対象物を観察しながら，視点によらない特徴抽出器を獲得していく．またそれと同時に，養育者とのコミュニケーションを通して対象物に関する語彙を学習する．ロボットは相互作用を終えると，集めたデータを用いて色と形状の SOM を再学習して更新する．その後，対象物を指差して，知っているラベルを発話する．養育者はラベルが誤っていれば訂正し，正しいラベルを教示する．発話内容が正しい，または発話されなかったときには，発話されていない正しいラベルを教示する．注視対象についての語彙を教示されると，ロボットは注視対象の顕著性が閾値以下になるまで注視した後に，別の対象物を注視する．

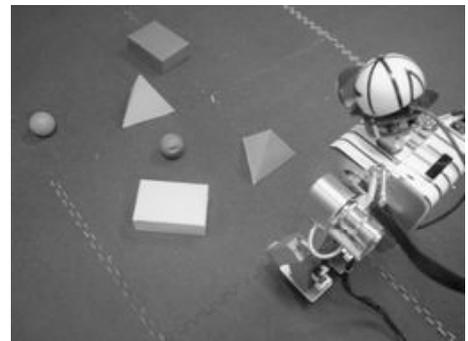


Fig. 19 A real robot environment

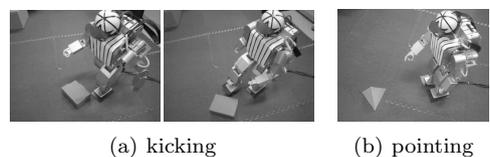


Fig. 20 Examples of robot's behaviors

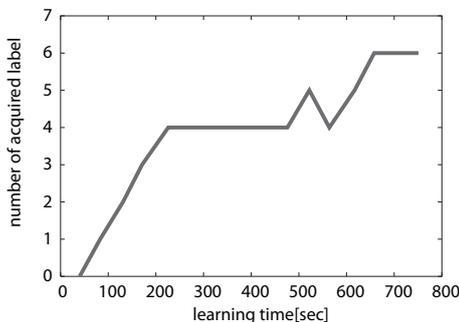
実験では、ロボットは色、形状の SOM の学習と並行してラベルのマッピングを行っていく。なお SOM の融合の際にはラベルの結合度についても融合する。i 番目の SOM に j 番目の SOM を融合するときの結合度の更新は以下であらわされる。

$$w_{l \rightarrow i}(t+1) = w_{l \rightarrow i}(t) + w_{l \rightarrow j}(t) \quad (17)$$

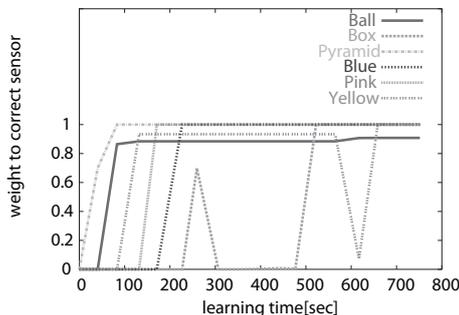
$$w_{l \rightarrow j}(t+1) = 0 \quad (18)$$

4.3.2 ヒューマノイドによる語彙獲得

実験の結果を Fig. 21 に示す。学習初期から効率よく語彙を獲得できているが、200[sec] 以降鈍化している。これは同じ箱型の対象物でありながら大きく視点の異なる 2 つの SOM を作成してしまい、これらを融合するための能動的な視点の変化に時間がかかったためであった。ロボットは対象物に歩いて近づく、キックするなどの行動で物体への視点を能動的に変化させるが、視点の大きな変化に時間がかかり、SOM の融合が起こるまで正しく学習できなかったと考えられる。600[sec] 付近のラベル "Yellow" の結合の急激な変化も、照明条件の違いによって新しい SOM を作ったために、SOM の融合までの間、結合度が低下したと考えられる。



(a) The number of acquired labels



(b) The connection weight of each label

Fig. 21 Experimental results using a real robot

また別の試行における、1 つ目の形状の SOM に対する顕著性の実験開始からの変化と語彙の学習をまとめたものを Fig. 22 に示す。最上部には注視している対象物の、相互作用終了時点での画像が示されている。その下のラベルはそれぞれロボットが発話したラベルと、養育者が教示したラベルである。また、下部に特徴抽出器である形状の SOM の活性度を示している。この活性度は形状の SOM の再学習を終えた時点で、最上部の画像を入力したときの活性度をあらわしている。以下では学習の詳細を順に説明する。

- (1) 初期状態では形状 SOM は存在していないので、はじめの十数秒間の対象物との相互作用で集めたデータを使って新規の SOM を作成する。養育者からラベルの教示を受けた後、顕著性の馴化項 S_1 が閾値 (=0.3) 以下になるまで注視して次の対象物に移る。ラベル "Box" は色 SOM の黄色をあらわすニューロンと 1 つ目の形状 SOM に結びつく。
- (2) 1 つ目の SOM が発火しないので新規の SOM を作成する。1 つ目の SOM は活性度が低い状態なので、自発的回復によって S_1 は上昇する。ラベル "Ball" は青色をあらわすニューロンと 2 つ目の形状 SOM と結びつく。
- (3) 1 つ目の SOM と同じ形状の対象物であるが、視点が変わるため同じ対象物とは解らず新規の SOM を作成する。対象物が青色であるため、青色をあらわすニューロンと結びついているラベル "Ball" が発話される。しかし養育者に "Not Ball" と教示され、青色のニューロンとの結合は弱められる。結果、"Ball" は 2 つ目の SOM のみと強く結びつき、正しい語彙が獲得された。また再び "Box" と教示され、現在このラベルは黄色、青色のニューロンと 1 つ目、3 つ目の形状 SOM と結びついている。
- (4) 再度最初の対象物を注視し、相互作用の間に 1 つ目と 3 つ目の SOM が発火したため融合する。融合によってラベル "Box" との結合度が高まり、顕著性の知識項 S_2 は低下する。正しいラベルである "Box" が発話されたため "Yellow" が教示された。
- (5) ラベル "Box" は黄色のニューロンとも結びついているため発話される。養育者によって "Not Box" と教示され黄色との結合は弱められる。結果、"Box" と 1 つ目の SOM の結合が強く結びつき、正しい語彙が獲得された。結合が強くなったため S_2 は小さくなり、1 つ目の SOM はほかのラベルとは結びつきにくくなる。

5. おわりに

本論文ではロボットが顕著性に基づいて注視対象を選択し、ラベルとのマッピングに顕著性をバイアスとしても用いることで効率的な語彙獲得を行うシステムを提案した。シミュレーションによって提案システムの有用性を検証し、非常に効率的に多数の語彙を獲得できることを示した。また提案システムをヒューマノイドロボットに実装し、実環境における語彙獲得タスクに適用した。視点の違いによらない特徴抽出器を学習しながら正しい語彙が獲得されることを示した。

本研究では、学習を加速するバイアスを Hebb 学習の学習効率へのバイアスとして表現した。Hebb 学習は、脳のシナプスの

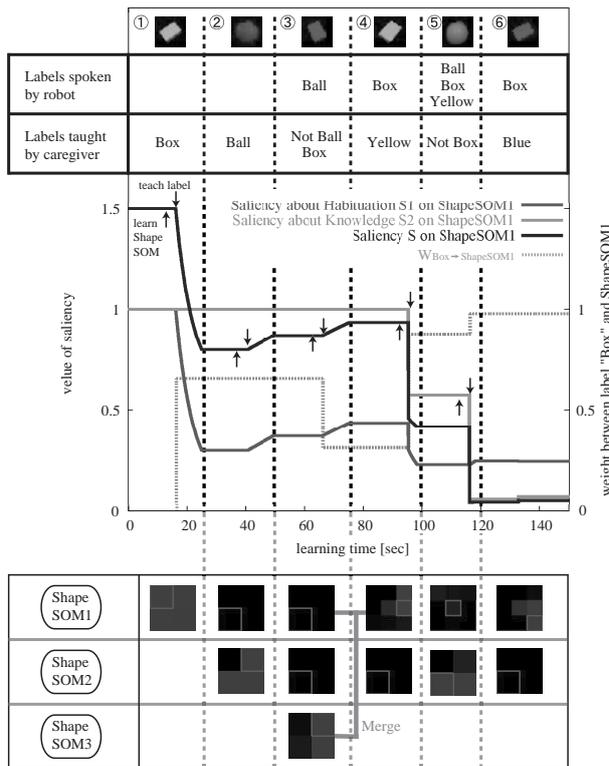


Fig. 22 Saliency changes in shape SOM 1 at the first several step

可塑性についての類推を行いやすいという意味でわかりやすいモデルであるが、情報論的な意味がわかりにくくシステムの定量的な比較が難しいという欠点がある。脳のモデル化においても、Hebb 学習を規範とした古典的な定式化に対して、近年では、より情報量的な意味がはっきりした情報量において定式化される傾向がある。実際、言語学習モデルにおいても相互情報量を用いたモデルが提案されており、そのモデルを使って実際の母子の相互作用の記録を使った検証も行われている [14]。実際の学習においては、相互情報量を計算するためには経験したすべての観測データを保持しておく必要があり、今回扱ったような学習の加速を逐次的な学習バイアスとして表現することが難しい。情報量最大化から逐次型学習則を導き、そこにどのように今回の提案手法で考慮した顕著性による学習の効率化を導入することができるかは今後の興味深い問題である。

本研究では語彙獲得をセンサー情報の表象と語彙に対応した表象（ラベル）の対応付けの問題として扱ったが、語彙獲得における対応付けの二つの大きな問題については扱っていない。一つは、カテゴリー化の問題であり、もう一つは、階層的なセンサー表現への問題である。一つ目の問題は、ある語彙がセンサー情報のどこまでの範囲に対応するのかを決定することである。この問題に対しては、相互情報量を最大にする手法や獲得した同じ状況を表現する言語の整合性をとることによってカテゴリー化を行う手法が提案されている [14, 15]。提案手法では、結合加重のノルムを正則化する条件を導入し、さらに結合加重の値がある閾値を超えることが語彙獲得と定義しているため、広い範囲のセンサー情報に対して高い結合を持たせることは困

難である。結合加重の大きさに制限を与えつつカテゴリーに対応した範囲のセンサー表象との対応関係をつくる学習則の開発については今後の課題である。

二つ目の問題として、異なるセンサーの組み合わせに対する語彙や包含関係にある語彙（"色"と"赤"など）に対する語彙獲得の問題である。センサー情報の組み合わせについては、センサー空間でマルチモーダルなセンサー情報の組み合わせを表象した空間を構成し、その表象空間に対してラベルとの結合の学習を行うことで、提案する学習則はそのまま適用可能である。包含関係についても、すでにセンサー表象空間で構造化されているとすれば対応付けを考えることができるが、学習が効率的になるためには本研究で提案した学習バイアス以外の学習バイアスを考える必要があると考えられる。ヒトの言語学習においては、Markman [5] の提案する事物全体原理（「未知の事物がラベルづけられるとき、ラベルの対象はその事物の部分でも特性でもなく、事物それ自体の全体である」と定義される）や事物カテゴリーバイアス（「未知の事物に対してつけられたラベルを、その事物を含むカテゴリーに対するラベルと判断する」）などの学習バイアスがあるとされており、これらの学習バイアスが階層構造があるときの学習の効率化を行っていると考えられる。

本研究では語彙獲得を加速する要因として、注意というものが学習の効率化に果たす役割を考慮し、学習者の感じる顕著性が学習に影響を与えるものとしてモデル化を行った。しかし、語彙獲得が加速される要因には他にもいくつかの可能性が考えられる。まずは獲得した語彙についてカテゴリー化が進み、新しい語について対応する表象への推測が容易になることがあげられる。これに関しては、上記で述べた階層関係の理解の問題と文法構造の理解が密接に関連していると考えられ、引き続き語彙の構造化の問題として取り組んで行きたい課題である。もう一つの重要な学習の加速要因として、認知能力が向上することによって教示者の意図を推定しやすくなり養育者と学習者の注意が一致することがあげられる。養育者と教示者が環境について同様の顕著性を感じることができれば、養育者から学習者へ効率よく教示を行うことができ、また学習者も養育者の意図の推定が容易になるからである。エージェント間の顕著性の推定と学習の効率化のモデル化についても今後の重要な課題の一つである。

参 考 文 献

[1] 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”, 電子情報通信学会論文誌, vol.80, pp.1546–1533, 1997.
 [2] 石黒, 國吉, 大津: “インターモーダル学習による概念の獲得”, 日本機械学会ロボティクス・メカトロニクス講演会'04 講演論文集, 2004.
 [3] Luc Steels and Frederic Kaplan: “AIBO’s first words. The social learning of language and meaning”, Evolution of Communication, vol.4, no.3, pp.3–32, 2001.
 [4] 岩橋: “ロボットによる言語獲得: 言語処理の新しいパラダイムを目指して”, 人工知能学会誌, vol.18, no.1, pp.49–58, 2003.
 [5] E. M. Markman: “Categorization in children: Problems of induction”, Cambridge, MA: MIT Press, Bradford Books, 1989.
 [6] B. Landau and L. B. Smith and S. Jones: “The importance of shape in early lexical learning”, Cognitive Development, vol.3, pp.299–321, 1988.

- [7] Deb K. Roy: “Learning Visually-Grounded Words and Syntax for a Scene Description Task”, *Computer Speech and Language*, vol.16, pp.353–385, 2002.
- [8] A. Toyomura and T. Omori: “A Computational Model for Taxonomy-Based Word Learning Inspired by Infant Developmental Word Acquisition”, *IEICE Information and Systems*, vol.88, no.10, pp.2389–2398, 2005.
- [9] A. Cangelosi and A. Greco and S. Harnad: “Symbol Grounding and the Symbolic Theft Hypothesis”, In Amgelo Cangelosi and Domenico Parisi. editors, *Simulating the Evolution of Language*, London: Springer Verlag, pp.191–210, 2002.
- [10] Y. Sugita and J. Tani: “A Holistic Approach to Compositional Semantics: a connectionist model and robot experiments”, In *Advances in Neural Information Processing Systems 16*. The MIT Press. 2002.
- [11] 小島, 長谷川: “ヒューマノイドロボット上の自己増殖型ニューラルネットワークを用いた視聴覚情報からの能動的・追加的概念獲得”, *信学技報 PRMU2005-57*, pp.35–40, 2005.
- [12] K. Tanaka: “Inferotemporal cortex and object vision”, *Ann. Rev. Neurosci*, vol.19, pp.109–139, 1996.
- [13] Judson P. Jones and Larry A. Palmer: “An Evaluation of the Two-Dimensional Gabor Filter Model of Simple Receptive Fields in Cat Striate Cortex”, *Journal of Neurophysiology*, vol.58, pp.1233–1258, 1987.
- [14] D. Roy: “Learning Visually Grounded Words and Syntax of Natural Spoken Language”, *Evolution of Communication*, 4, 1, pp. 33-56(24), 2001.
- [15] P. Vogt: “Anchoring of semiotic symbols.”, *Robotics and Autonomous Systems*, 43, 2, pp. 109–120, 2003.

知能ロボットの研究に従事。工学博士。電子情報通信学会, 情報処理学会, 計測自動制御学会, システム制御情報学会, IEEE などの会員。
(日本ロボット学会正会員)

菊池 匡晃 (Masaaki Kikuchi)

1981年12月21日生。2006年大阪大学工学部工学研究科修士課程知能・機能創成工学専攻修了。現在株式会社東芝に在職。エージェント技術に関わる研究に従事。

荻野 正樹 (Masaki Ogino)

1972年12月12日生。1998年大阪大学大学院基礎工学研究科物理系博士前期課程修了。2002年大阪大学大学院工学研究科知能機能創成工学専攻博士後期課程単位取得退学。2002年大阪大学大学院工学研究科産学官連携研究員。2004年大阪大学大学院工学研究科特任研究員。2006年科学技術振興機構 ERATO 浅田共創知能システムプロジェクト研究員。現在に至る。工学博士。バイオメカニズム学会, 人工知能学会の会員。
(日本ロボット学会正会員)

浅田 稔 (Minoru Asada)

1953年10月1日生。1982年大阪大学大学院基礎工学研究科博士後期課程修了。同年同大学基礎工学部助手。1989年同大学助教授, 1995年同教授。1997年同大学大学院工学研究科教授。2005年より科学技術振興機構 ERATO 浅田共創知能システムプロジェクトプロジェクトリーダーと兼任。この間, 1986年から1年間米国メリーランド大学客員研究員。1989年情報処理学会研究賞, 1992年IEEE/RSJ IROS '92 Best Paper Award, 1996年日本ロボット学会第10回論文賞受賞, 1998年人工知能学会研究奨励賞, 1999年日本機械学会ロボティクス・メカトロニクス部門貢献賞, 2001年文部科学大臣賞・科学技術普及啓発功績者賞, 2001年日本機械学会ロボティクス・メカトロニクス部門賞: 学術業績賞, 2004年人工知能学会研究会優秀賞, 2006年科学技術政策研究所 科学技術への顕著な貢献 in 2006 (ナイスステップな研究者)「イノベーション部門」, 2007年大川出版賞をそれぞれ受賞。