

顔特徴量の発見と選好性の獲得 - 応用行動分析による自閉症児の学習モデル -

Acquiring the Preference to the Faces Through the Interaction with Caregiver - Learning model of autism children in ABA therapy -

渡辺 絢子 (阪大)

正 荻野 正樹 (JST ERATO)

正 浅田 稔 (阪大, JST ERATO)

Ayako WATANABE, Osaka University, 2-1, Yamadaoka, Suita, Osaka
Masaki OGINO, JST ERATO Asada Project
Minoru ASADA, Osaka University, JST ERATO Asada Project

This paper proposes a system that models the interaction in Applied Behavior Analysis(ABA). ABA is a education for Autism children to acquire the ability of communication, and is a kind of reinforcement learning. In the education, when an autism child looks at caregiver's face, then he/she can get a reward from the caregiver. By modeling the interaction and implementing the model to a robot, robot acquires the ability of looking at human face without initial knowledge about face.

Key Words: Face Detection, Interaction, HLAC features

1 はじめに

コミュニケーションの学習とは相手とのやりとりを学習することであるが、適切な情報に注意が払われていなければ結びつけるべき情報の獲得が困難となる。コミュニケーション時にどの視覚パターンに注意を払えばよいかの問題は、(1)重要となる視覚パターンの発見、(2)獲得した視覚パターンのコミュニケーションにおける意味付け、の問題が含まれる。このため注意の選好性はコミュニケーションの学習にとって重要な要素であると考えられる。

人間の認知発達においては、注意の選好性はほとんど生得的であると考えられている。例えば幼児は顔のようなパターンに対する選好性は生得的に持っていると考えられている。新生児は生まれて間もない頃から顔に注目し [1]、生後数日の赤ちゃんでも 11 時間から 12 時間以上母親と接していると、母親の顔を区別することができるようになることが知られており [2]、一般に視力が低いとされている乳児でも、顔に似たパターンに対する選好性を持つ [3] とされている。しかし、最近、Ian らは 6 分程度の視覚情報を随伴性の有無によってクラス分けした学習データから、顔パターンの識別器が学習可能であることを示しており、顔パターンの識別も生得的ではなく学習によって獲得可能である可能性を示している [4]。また、自閉症児は、通常の人と注意の選好性が異なるために、コミュニケーションの学習が困難になっているという説もあり [5]、臨床的に自閉症児に対して行動分析的手法 [6] でアイコンタクトに対する選好性を学習させ、その上で社会的な認知能力を向上させる試みもなされている [7]。

Ian らの顔識別器の学習モデルや自閉症児のアイコンタクト学習は、相互作用を通じたカテゴリー化の問題として、あるモーダルの情報をもとに別のモーダルのカテゴリー化を促進する学習モデルとしてとらえることができる。本研究では、そのようなコミュニケーションを通じたカテゴリー化の例として、自閉症児に対し行われている応用行動分析を基盤としたアイコンタクト学習のインタラクションのモデル化を行う。コミュニ

ケーションを通じた相互作用が視覚情報のカテゴリー化を促進させ、それがさらに選好性へと影響を与え、さらにそれが後の視覚情報のカテゴリー化を促進する発達モデルの可能性を提案する。

2 学習モデル

2.1 コミュニケーションルール

応用行動分析では、認知的な行動を十分細かい簡単な行動要素に切り分け、その切り分けた行動ごとに自閉症児を報酬(褒める)によって行動を強化する療育法である [6]。特にアイコンタクトを学習させる場合、セラピストは自閉症児が欲しいようなものを持ってまず自閉症児の注意を引く。しかし自閉症児が手を伸ばして来ても、すぐには渡さず、自閉症児がたまたまセラピストの顔を見たときにはじめて欲しいものを渡す。療育段階が進むにつれて、自閉症児はセラピストの顔を見るようになり、最終的には目を見るようになっていくとされており、この能力は、その後の社会的な認知能力の療育にとって重要な段階であるとされている [7]。

本研究では、画面上に表示されたバーチャルなロボットモデルを自閉症児に見立てて、画面に対峙した養育者が、ロボットが自分の方を見たと感じたときに報酬を与える (Fig. 1)。

2.2 システム全体の概観

Fig. 2 に提案システムを示す。システムは大きく分けて画像処理システムと学習システムからなる。画像処理システムでは、ボトムアップとトップダウンの二つのプロセスによってカメラ画像の中でロボットが注意すべき場所が計算される。ボトムアップなプロセスでは画像の顕著性に基づいて注意点の候補が選択され、トップダウンなプロセスでは学習システムで学習された画像特徴量を検出して注意点の候補とする。学習システムでは、ロボットが報酬を得たときに、その前後の画像群を記憶し、それらの画像群を識別する画像特徴量を学習する。以下ではシステムの詳細について述べる。

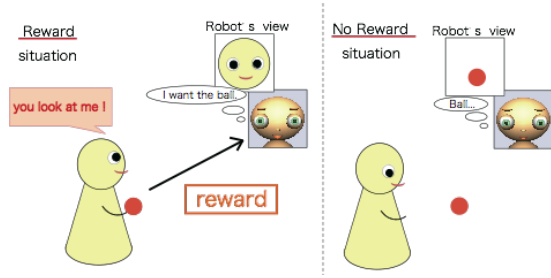


Fig.1 Communication rule

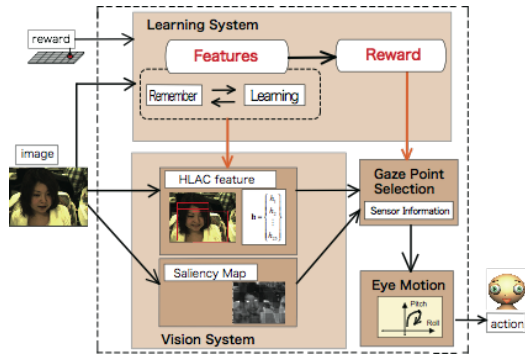


Fig.2 An overview of the proposed system

2.3 HLAC 特徴量

本研究では、高次局所自己相関 (HLAC) 特徴 [8] を使って識別器を構成した。2 値画像に対する HLAC 特徴量は 25 次元で構成される。平行移動について同じ作用をもつ特徴量を 1 つの特徴量としている。各特徴量は、局所パターンの対応する画素の値の積を全画像に対して積分を行って求められる。ひとつの HLAC 特徴量が、ひとつのフィルタを用いた全画像に対する積分値となるため、位置に因ることなく、特徴的なオブジェクトの存在を検出することができる。本研究では、カメラ画像を画像セグメントに切り分け、その画像セグメントごとに HLAC 特徴量を求めた。

目的とするオブジェクトを含む画像セグメントの HLAC 特徴量 \mathbf{h}^{ref} を学習した後、入力画像から得た特徴量 \mathbf{h} と学習した特徴量との差 d を用いて、その後のインタラクションにおいて目的とするオブジェクトを検出することが可能となる。

$$d = \|\mathbf{h} - \mathbf{h}^{ref}\| \quad (1)$$

この HLAC 特徴量の距離 d がある閾値 ϕ より小さいとき、そのセグメントに特別なオブジェクトが含まれている、つまりラベル $l = 1$ とすることができる。

$$l = \begin{cases} 1 & \text{if } d < \phi \\ 0 & \text{else} \end{cases} \quad (2)$$

2.4 学習アルゴリズム

2 つの画像群「ラベルあり」と「ラベルなし」が与えられたときに、2 つの画像群を識別するための最もよい画像特徴量を探索する。

まず、「ラベルあり」の画像群 $\mathbf{A} = \{X_1^a, X_2^a, \dots, X_N^a\}$ の中から、代表となる基準画像 $X^{ref} \in \mathbf{A}$ を選ぶ。そして、基準画

像 X^{ref} を L 個のセグメント $\{Z_i^{ref}\}$ に区切る。オブジェクトと認識するための HLAC 距離 d の閾値 ϕ を仮に定め、基準画像の i 番目のセグメント Z_i^{ref} に対し、以下の手続きを行う。

1. ラベルあり」の画像群 \mathbf{A} 、「ラベルなし」の画像群 \mathbf{B} の中のそれぞれの画像 $X_n^a \in \mathbf{A}$, $X_n^b \in \mathbf{B}$ を基準画像同様、 L 個のセグメント $\{Z_{n,i'}^a\}$, $\{Z_{n,i'}^b\}$ に区切る
2. それぞれの画像群が持つセグメント $\{Z_{n,i'}^a\}$, $\{Z_{n,i'}^b\}$ と基準画像のセグメント Z_i^{ref} の間の、HLAC 特徴量の距離 $\{d_{i,i'}^a\}$, $\{d_{i,i'}^b\}$ を求める

$$d_{i,i'}^{(a,b),n} = \|\mathbf{h}_{i'}^{(a,b),n} - \mathbf{h}_i^{ref}\| \quad (3)$$

ここで、 $\{\mathbf{h}_{i'}^{(a,b),n}\}$ は画像群の中のセグメント $\{Z_{n,i'}^{(a,b)}\}$ が持つ HLAC 特徴量、 \mathbf{h}_i^{ref} は基準画像のセグメント Z_i^{ref} が持つ HLAC 特徴量である。

3. それぞれの画像群の中のセグメントで、基準画像のセグメント Z_i^{ref} に HLAC 特徴量の距離が最も近いセグメント $\{Z_{n,i'_{min}}^a\}$, $\{Z_{n,i'_{min}}^b\}$ を求める

$$i'_{min}^{(a,b)} = \operatorname{argmin}_{i'} d_{i,i'}^{(a,b),n} \quad (4)$$

4. その距離を最小とするセグメントが持つ HLAC 特徴量の距離 $\{d_{i,i'_{min}}^a\}$, $\{d_{i,i'_{min}}^b\}$ が、定めた閾値 ϕ より小さいとき、そのセグメントを持つ画像内に特別なオブジェクトがあるというラベル $\{l_n^a\}$, $\{l_n^b\}$ を付加する

$$l_n^{(a,b)} = \begin{cases} 1 & \text{if } d_{i,i'_{min}}^{(a,b),n} < \phi \\ 0 & \text{else} \end{cases} \quad (5)$$

5. それぞれの画像に貼られたラベル $\{l_n^a\}$, $\{l_n^b\}$ が、元来貼られていたラベル「ラベルあり (1) ($X \in \mathbf{A}$)」、「ラベルなし (0) ($X \in \mathbf{B}$)」に一致している割合 μ を求める

$$I_n^{(a,b)} = \begin{cases} 1 & \text{if } l_n^a = 1 \text{ or } l_n^b = 0 \\ 0 & \text{else} \end{cases} \quad (6)$$

$$\mu = \frac{\sum_{n=1, (a,b)}^N I_n^{(a,b)}}{2N} \quad (7)$$

全ての基準画像のセグメント $\{Z_i^{ref}\}$ に対し、1~5 の手続きを行い、さらに HLAC 距離の閾値 ϕ を少しずつ増加、または減少させながら、高い $\mu(\phi_{max})$ を求める。そして一致率 μ の上位 K 個を学習候補とし、それぞれ基準画像中のセグメント番号 i_k ($1 \leq k \leq K$) と HLAC 特徴量の距離の閾値 ϕ_k の組み合わせを求める。上位 K 個のセグメント $\{Z_{i_k}^{ref}\}$ を用いて重要なオブジェクトの HLAC 特徴量を、上位 K 個の閾値 $\{\phi_k\}$ を用いて、インタラクションで利用する閾値 Φ を決定する。

$$\mathbf{H} = \frac{\sum_{k=1}^K \mathbf{h}_{i_k}}{K} \quad (8)$$

$$\Phi = \phi_\kappa \quad (\kappa = \forall k) \quad (9)$$

ただし、本研究においてそれぞれの画像群が含む画像枚数を $N = 30$ 、区分するセグメント数を水平方向に 10 個、垂直方向に 10 個とし、計 100 個とした。さらに、 $K = 10$ とした。

3 報酬に基づく画像群のグループ分け

ロボットの内部には「要求している」状態と「要求していない」状態が存在するとし、ロボットが「要求している」が、報酬が与えられない時には、「報酬無し」のラベルが貼られた画像として記憶する。

ロボットは報酬が得られたときの画像を「ラベルあり」の画像として記憶し、要求の状態が高いときに、報酬が与えられない場合、そのときの画像を「ラベルなし」の画像として記憶する (Fig. 3).




Fig.3 The robot Remember images when it gets Reward

3.1 注視システム

ロボットは入力画像から、Saliency Map [9] と HLAC 特徴量を用いて注視点を決定する。注視決定までの全体図を Fig. 4 に示す。選択器は、確率 P で HLAC 特徴量で導かれた注視点を選択し、確率 $(1 - P)$ で Saliency Map で算出された注視点を選択する。そして、決定された注視点を中心として、視野を定義する。この視野の大きさは、特徴量の学習に用いるセグメントと同じ大きさであり、学習が進行するに従って小さくなっていく。




Fig.4 Gaze system

注視点選択器は、得られた報酬によって、学習した HLAC 特徴量を見る確率を高めていく。更新式は以下である。ここで r_t は 1 回の学習で得た報酬、 P_t は t 回報酬を与えられた時の、学習した特徴量を注視する確率である。また、 α は学習率であり、本稿においては $\alpha = 0.2$ とした。

$$P_t = P_{t-1} + \alpha r_t \quad (10)$$

「報酬が得られる」と学習された特徴量を注視する。そして、通常の場合では報酬を得る毎に、得られた報酬に応じて、報酬に関連した特徴量を見る確率を上げていく。このことにより、報酬による顔特徴量への選好性を実現することが可能である。

3.2 学習の流れ

ロボットは顔が分からない状態から学習を開始する。実験者は、顔を偶然に見た時、報酬を与える。そして、ロボットは顔について学習を行う。次に、ロボットは顔を見ることが可能になる。そして学習を繰り返す。しかし、実験者が報酬を与えるルールから、学習した特徴量のばらつきが小さくなり注視する視野が小さくなった時には、顔を見ても報酬が得られなくなる。そして、偶然に目を見たときに、報酬を得ることができる。そして、目について学習を行うことができるようになる。

学習の流れを Fig.5 に示す。 $v(h)$ は学習した HLAC 特徴量の分散である。学習のばらつきが小さくなった場合には、さらに細かい学習を行っていく。



Fig.5 Stream of Learning

4 実験

4.1 実験設定

実験はシミュレーションロボットを用いて行った (Fig. 6)。ロボットと実験者は対面しており、カメラはロボットディスプレイ上部に設置された。報酬は設定されたキーによって与えられる。実験者は、ロボットが実験者を見たと感じたときに、段階に応じてロボットに報酬を与える。




Fig.6 Settings

実験は 2 種類行った。まず、本論文の提案手法にて、ロボットによる顔特徴量の発見、さらにそれを利用した選好性の獲得が可能であることを示す。この実験の枠組みで、インタラクションによる学習への影響を検証する。そして 2 番目に、自閉症児は健常児と比較して動き情報にあまり反応しないのではないかと報告されている [10] ことから、注視点移動の際、動き情報を利用しない場合に、顔特徴量の発見と選好性の獲得が可能であるかを検討する。

4.2 実験結果

学習の結果、重要なオブジェクトであると検出されたセグメントを Fig.7 に示す。一致率 μ が高く、上位となったセグメントを赤い枠で示した。報酬情報を区別する画像特徴量として、最初は顔が選択され、学習が進むと目が選択されている。




Fig.7 Important Segment

次に、学習前と学習後のロボットの注視点の変化を Fig. 8 に示す。学習前は環境の僅かな変動によって、注視点が不安定と

なってしまうが、学習後は安定的に人間の顔の辺り、特に目の辺りを捉えることが可能となっている。



(a) Before Learning (b) After Learning

Fig.8 Gaze line

また、目に注視する程度について、学習前と学習後における違いを示すために、1分間、学習前と学習後において視線を検出した。Fig. 9 は目から注視点の距離を算出し、その分散を求めたものである。学習後にはよく目を注視することができていることが分かる。




Fig.9 Variance from eye

インタラクションと学習を繰り返すことにより、学習結果を利用した注視点に影響される画像群が、学習するべきオブジェクトに集中するようになり、学習をよく行えるようになる。学習初期の学習結果と、学習を数回繰り返した後の学習結果を Fig.10 に示す。



Fig.10 Change of segment that has important object

動き情報を含めた実験では、一般的に人間がよく行うアピール動作を行うと、ロボットは高い確率で人間の方を注視した。しかし一方、動き情報なしの実験においては、輝度の高いある一点を注視したまま、視線が人間の方を向いたのは、光が変動した一瞬であった。

動き情報を用いない場合と、動き情報を用いる場合において、同じ学習をさせたときの学習回数と学習結果を Fig. 11 に示す。動き情報を用いない場合は、通常より学習回数が必要であり、それと同時に、注視点決定に動き情報を用いて、「人間」の方を向くということは、顔やその他の学習を促進させると考えられる。

5 おわりに

本研究では、コミュニケーションを通じたカテゴリー化と選好性の獲得のモデルとして、応用行動分析による自閉症児のアイコンタクト学習の療育に注目し、自閉症児の学習モデルを構築した。提案モデルでは、画像情報の中で報酬情報と関連が強




Fig.11 Difference of Learning Time

い情報として顔そして目の画像特徴量を学習可能であることを示した。近年、視線と注意に関して自閉症児に特徴的な性質が存在する計測結果が得られ始めている。提案モデルにおいても自閉症児の計測結果と比較を行うことにより視線モデルの精緻化を行うことを考えている。また、本モデルは自閉症児の学習モデルとして提案したが、コミュニケーションを通じた表情のカテゴリー化、顔の向きに対するカテゴリー化に関しても一般化可能であると考えられる。今後は、より一般的な認知発達学習の枠組みとしてモデルを発展させていくことを考えていくことを予定している。

参考文献

- [1] John Morton and Mark H. Johnson. Conspic and conlern : A two-process theory of infant face recognition. *Psychological Review*, Vol. 98, No. 2, pp. 164–181, 1991.
- [2] Philippe Rochat. *The Infant's World*. Harvard University Press. Cambridge, Massachusetts through Tuttle - Mori Agency, Inc., Tokyo, 2001.
- [3] Mark H. Johnson. Subcortical face processing. *Nature Reviews Neuroscience*, Vol. 6, pp. 766–774, October 2005.
- [4] Ian Fasel, Nicholas Butko, and Javier Movellan. Modeling the embodiment of early social development and social interaction: Learning about human faces during the first six minutes of life. In *Society for Research in Child Development Biennial Meeting*, 2007.
- [5] Leo Kanner. Autistic disturbances of affective contact. *Nervous Child*, Vol. 2, pp. 217–250, 1943.
- [6] O. Ivar Lovaas. Behavioral treatment and normal educational and intellectual functioning in young autistic children. *Journal of Consulting and Clinical Psychology*, Vol. 55, No. 1, pp. 3–9, 1987.
- [7] 江口博美. <http://www.kids-power.net/>.
- [8] 大津展之他. 行動計量学シリーズ パターン認識 理論と応用. 朝倉書店, 1996.
- [9] L. Itti, C. Koch, and E. Niebur. A model of saliency-based visual attention for rapid scene analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 20, No. 11, pp. 1254–1259, November 1998.
- [10] Frederick Shic, Brian Scassellati, David Lin, and Katarzyna Chawarska. Measuring context: The gaze patterns of children with autism evaluated from the bottom-up. *ICDL*, 2007.