

神経力学モデルによる身体図式に基づく空間地図の獲得

信田春満 西出俊 尾形哲也 奥乃博 (京都大学大学院 情報学研究科)

1. はじめに

生後間もない幼児は視野に映っている自分の手を自分の身体として認識していない。幼児は生後三ヶ月頃に頻りに自分の手先を見つめるハンドリガード [1] という行為を行い、この時期に視野内にある肌色の物体をその他と異なる身体として認識し、身体図式を獲得すると考えられる。本研究では身体図式を運動指令と視野内の手の動きの相互変換機能と捉える。この幼児の自己身体の発見メカニズムについて本研究では一つの仮説モデルを提案する。

またこの仮説モデルに基づき、空間地図に関する考察も行う。身体運動は頭頂葉の空間地図と前頭葉の運動制御の一体となったダイナミクスによってなされる [2] [3]。この空間地図の獲得について仮説モデルからの考察を行う。

2. 認知科学上の運動モデル

2.1 内部モデル

人の脳には内部モデルとよばれるシステムが存在する。内部モデルは順モデル [4] と逆モデルから成る。順モデルは運動指令から体の動きとその結果起こる感覚フィードバックを予測し、逆モデルでは逆にある感覚フィードバック (例えば視野内の手先の動き) を与えられたときにそれを生成する運動指令を予測する。すなわち内部モデルとは身体図式に相当する。

2.2 順モデルと自己主体感

順モデルには、運動指令により筋肉を動かし実際に得られた感覚フィードバックと、順モデルにより予測された感覚フィードバックを比較し一致する感覚フィードバックを自身の運動に由来する感覚フィードバックとして認識する機能がある [5] (図 1.) この機能によって人は自分が手を動かしたとき「この手を動かしているのは自分である」といった自己主体感 [7] を得ることができる。これらの機構は統合失調症の説明等に用いられる [6]。

3. 提案モデル

本研究では、運動指令として腕の関節角速度列を使用し、視覚フィードバックとして視野内の自身の手先位置及び自己身体と関係の無い視野内の移動物体 2 点を使用する。システムは視野内の 3 つの移動物体のどれが自己身体かが未知の状態では身体図式の獲得を行う。




図 1 順モデルと自己主体感

3.1 身体図式獲得モデル

我々は内部モデル (順逆モデル) を 4 章で詳述する神経力学モデル MTRNN (Multiple Time-scale Recurrent Neural Network) によって実装した。MTRNN は複数の入出力 (運動指令と視覚フィードバック) を同時に扱え、入出力間に存在する力学的関係性を学習可能である。また運動指令から視覚フィードバックを予測するなど部分入力から全体入出力を予測生成できる。提案手法は次の 3 フェーズからなる。

- 学習: 教師データから複数の入力間関係を学習する。視覚フィードバックには 3 つの移動物体を含みどれが自己身体かは未知である。
- 順モデル: 運動指令から自己の手先位置の動き (視覚フィードバック) を予測する。
- 逆モデル: 視野内での点の移動の軌跡から、それを再現する手先運動指令を生成する。

3.2 身体識別

運動速度指令と自己手先位置は単純なマッピングとはならないが、履歴を反映した関係性がある。対して運動速度指令と外界の移動物体には直接の関係はない。MTRNN は繰り返し学習 (パブリック) を通じて、運動指令と手先位置の関係のみを予測可能となる。

学習後の MTRNN に運動指令のみを入力し、視覚フィードバックの予測誤差の小さい点 (領域) を自己身体、大きい点 (領域) を他者として識別する。

4. 実装

4.1 概要

視野内に自己の手先と他の移動物体が複数存在する状態でロボットに手先をランダムに動かさせ、視野内の自己の身体を表す点を識別させた。システムの入出力を以下に示す。

運動指令 右腕関節 3 軸の角速度の時系列。

視覚フィードバック 視野内の自己の手先位置 (x,y) 及び外界の 2 つの移動物体の位置 (x,y) 。

実際には次の手順で実験を行う。

1. 3 体のロボット A,B,C を用意し A を自己身体とする。A と B は比較実験の為に同じハードウェアのロボットを用いる。
2. 3 体それぞれ手先を動かして各視野内の手先位置を取得する。A については運動指令も取得する。
3. A の運動指令及び A,B,C の手先位置を組み合わせたもの (視覚フィードバック) をデータとする。

第三章で示した 3 つのフェーズの内、学習と順モデルを図 2 に示す。逆モデルでは自身の手先位置のみから運動指令を計算する。実際の実験のフローチャートを図 3 に示す。以下は各部の説明である。




図 2 実装概要




図 3 実験フローチャート




図 4 HIRO(左), NAO(右)

4.2 ロボットシステム - HIRO・NAO

自己身体には川田工業株式会社、ゼネラルロボティクス株式会社の開発した上半身ヒューマノイドロボット HIRO(図 4 左)を使用する。また外界の移動物体の片方の座標取得には Aldebaran Robotics 社の NAO(図 4 右)を使用する。

本研究では HIRO の頭部及び手先の関節は固定した上で右腕の関節三軸のみを動かし実験を行う。HIRO の腕部は肩軸のピッチ (-180°, +120°), ヨー (-90°, +90°) 及び肘軸のピッチ (-160°, +10°) の三軸を操作できる。括弧内は可動範囲である。その他の仕様として台座からの上半身身長は 600mm, ロボット質量は 20kg, 腕長は 500mm 以内である。また, NAO の腕部は肩軸のピッチ, ロール及び肘軸のロールとヨーの四軸を操作できる。HIRO の手先には視野内での手先座標を取得する為の赤色のマーカーを設置する。




図 5 運動パターン生成アルゴリズム




図 6 MTRNN のノード構成

4.3 ロボット動作生成部・変換部

以下のようにデータを作成する(図 5)。

1. ロボットの手先を視野の中心に配置する。
2. ロボット正面から約 50cm 離れた仮想平面 (5 × 5 に分割) 内の一カ所をランダムに選択し, 手先を移動させる。
3. 再度同様に手先を移動させる。
4. 1~3 を 2 回施行し, 1 回めは自己身体, 2 回めはそれ以外として関節角度列, 視覚画像列を記録する。(2 回目は視覚のみ取得)
5. 1~3 とは別に NAO を動かして手先座標のみ取得する。
6. 1~5 のデータを合計 100 セット取得する。

得られる手先軌道は $(5^5)^2 = 625$ パターンあるため 100 セットの軌道は全て異なる。

得られたデータから, 関節角度列は関節角速度列へ変換する。また視覚画像列は OpenCV を用いて手先位置を計算し手先位置座標 (x,y) 列に変換する。最終データ形式は, 関節角速度列 (3), 自他の視覚座標 (6) の計 9 次元のデータ 100 セットとなる。サンプリング時間は 50[ms] であり, データ長は 48 ステップである。

4.4 神経力学モデル - MTRNN

上記したように本研究では内部モデルとして谷らによって提案された MTRNN [8] を用いる。MTRNN はパラメータノードを持ち各ノード群事に時定数を持つ RNN(Recurrent Neural Network) であり, 現在の状態を入力として次状態を出力する予測器として用いられる。MTRNN は複数の非線形時系列情報を学習しそれらをパラメータノード上のパラメータ空間に汎化でき, 汎化能力により未学習のパターンについても予測生成を行なうことができる。また各ノード毎の時定数が大きいノードほど内部状態の更新が緩やかになる。各ノード群は図 6 及び表 1 のようになっている。以降の章で用いられる学習・認識・生成とは次の意味である。

学習 教師信号に近い出力を出せるよう各ニューロン間の重みを更新するとともに, 各データに対応する $C_{st=0}$ を求めること。

認識 あるデータに対して, どの $C_{st=0}$ ベクトルから生成を行なうとそのデータを再現できるかを調べること。

生成 認識で得られた $C_{st=0}$ から時系列を生成すること。詳細については学習の節で述べる。

表 1 MTRNN のノードの説明

ノード名		説明
IO(mot)	2	運動指令値入出力ノード．本システムでは 3 ノード．
IO(eye _i)	2	視覚座標入出力ノード．2x3=6 ノード．
Cf	5	FastContext ノード．比較的小さな時定数を持つ．40 ノード．
Cs	70	SlowContext ノード．比較的大きな時定数を持つ．Cs はパラメータノードでもあり初期値 $C_{s_{t=0}}$ を指定することにより対応する時系列を生成できる．8 ノード．

表 2 自他予測誤差

-	予測誤差	標準偏差
自己身体	$6.00 * 10^{-2}$	$1.92 * 10^{-2}$
その他 (HIRO)	$2.77 * 10^{-1}$	$8.83 * 10^{-2}$
その他 (NAO)	$1.87 * 10^{-1}$	$4.82 * 10^{-2}$




図 7 自他予測誤差

MTRNN の各ノードの更新は次式で行われる．

$$u_{i,t+1} = \begin{cases} (1 - \frac{1}{\tau_i})u_{i,t} + \frac{1}{\tau_i}[\sum_{j \in N} w_{ij}x_{j,t}] \cdots (t \neq 0) \\ 0 \cdots (t = 0 \text{ and } i \notin Cs) \\ C_{s_{i,0}} \cdots (t = 0 \text{ and } i \in Cs) \end{cases} \quad (1)$$

$$y_{i,t} = \text{sigmoid}(u_{i,t}) = \frac{1}{1 + \exp(-u_{i,t})} \quad (2)$$

$$x_{j,t} = y_{j,t-1} \quad (3)$$

t : 時刻

u_i : 時刻 t のニューロン i の内部状態

τ_i : ニューロン i の時定数

$x_{j,t}$: 時刻 t のニューロン j の出力値

$y_{i,t}$: 時刻 t のニューロン i の出力値

w_{ij} : ニューロン j からニューロン i への結合重み

N : ニューロン i へ結合しているニューロンの集合

4.4.1 各ニューロンの学習

MTRNN の学習には通常の RNN と同じく BPTT (Back Propagation Through Time [9]) が用いられる．IO ニューロン群の入力値 $x_{j,t}$ は教師信号及び前時間の前ノードの出力から以下のように計算される．

$$x_{j,t} = (1 - p) * y_{j,t-1} + p * T_{j,t-1} \quad (4)$$

$T_{i,t}$: 時刻 t の j 番目のニューロンへの教師信号

p : 教師入力比 (IO ノードのグループ毎に固有)

w_{ij} と $C_{s_{t=0}} = C_{s_{i,0}}$ は以下の式により更新される．

$$w_{ij}^{(n+1)} = w_{ij}^{(n)} - \eta \frac{\partial E}{\partial w_{ij}} \quad (5)$$

$$C_{s_{i,0}}^{(n+1)} = C_{s_{i,0}}^{(n)} - \alpha \frac{\partial E}{\partial C_{s_{i,0}}} \quad (6)$$

$$E = \sum_t \sum_{i \in IO} (y_{i,t} - T_{i,t})^2 \quad (7)$$

n : 更新回数

E : 予測誤差

η, α : 学習係数

重みはネットワークの性質を決めるもので全データで共有される．パラメータ $C_{s_{t=0}}$ ベクトルは各データに固有のもので，学習によって学習パターン間の力学的構造に基づいて自己組織化される．そのため $C_{s_{t=0}}$ 空間には多様な未知のパターンが埋めこまれている．

なお，学習～生成の過程において IO ノードに外部からのデータを何割入れるかが指定できる (式 (4) の p)．

データの「認識」は結合重み w_{ij} を固定した BPTT によって $C_{s_{t=0}}$ を求めることによって行われる (式 (6))．認識での IO ノードの入力値は式 (4) によって行われる．教師データの与えられないノードは $p=0$ とする．

4.5 実験準備

100 セットのデータ中 80 セットを用いて MTRNN の学習を行った．学習時には運動指令と自他両方の教師信号を入力する．どの IO ノードが自己かは未知である．

5. 身体識別・身体図式獲得実験

5.1 自己身体 of 識別

未学習 20 セットのデータを使用し，MTRNN に運動指令のみから認識を行い得られた $C_{s_{t=0}}$ から 3 つの移動点の生成を行った．次に各点の予測誤差を式 (8) に従って計算した．

$$E_{eval} = \frac{1}{\max_t} \sum_t \sqrt{\sum_{i \in IO} (y_{i,t} - T_{i,t})^2} \quad (8)$$

得られた予測誤差は表 7，図 2 である．自己身体 of の予測誤差はそれ以外に比べ 3.86 倍小さく，予測精度により自己身体 of とそれ以外が識別可能であると言える．

5.2 順モデルの性能評価

前節で得られた自己の手先位置座標 of の予測誤差 (順モデル of の予測誤差) を評価した．前節 of の通り誤差は $6.00 * 10^{-2}$ であった．すなわち視野内の端から端までの 6% (凡そ 3cm) of の誤差 of の順モデルを構築できた．

5.3 逆モデルの性能評価

逆モデル of の予測誤差を評価した．自己の手先位置座標を表すノードに，未学習 20 セットのデータ of の自己視




図 8 Cf 空間地図




図 9 手先位置-色対応




図 10 空間地図内の手先位置毎の面積比

覚座標列を入力し（その他のノードは $p=0$ として入力を与えない）、運動指令を正しく予測できるかを調べた。予測誤差は 9.99×10^{-2} (標準偏差 3.19×10^{-2}) であった。すなわち関節角速度が教師信号に対し、最大値の 10% ほどの誤差の逆モデルを構築できた。

6. 空間地図の自己組織的獲得

四章で述べたとおり、学習済み MTRNN の C_s 空間の初期値は動作パターンを表象する。これに対し Cf 空間（すなわち Cf の 40 個の各ニューロンの発火率ベクトル）が何を表象するかを解析した。その結果 Cf 空間は各時間の手先位置を表象しており、その空間地図は身体構造によって歪められたものであることが分かった。

6.1 手先位置空間地図

ロボットから得られた 100 データに存在した $C_{st=0}$ の範囲内からランダムに $C_{st=0}$ 20000 点を作り、それぞれの点から運動指令と視覚の生成を行った。その各 22 ステップ目（手先が 5×5 グリッドの一回目の到達点にいる時間）の Cf ベクトルを抽出し、PCA をかけて二次元に圧縮した。各点を二次元平面上にプロットし、各点の色は 22 ステップ目の手先位置を表すようにしたものが図 8 である。手先位置と色の対応は図 9 の通りであり例えば赤は手先が右に有ったことを示す。

図の通り Cf ベクトルは手先位置と対応していることが分かった。これが一般的な現象であるかを調べるため Cf, C_s の数、学習の乱数シードの組み合わせを計 48 通り調べたがすべてのデータでこのような対応が見られた。これは Cf 空間が手先位置の地図と成っていることを表している。

6.2 身体構造による空間地図の歪み

48 通りについて Cf 空間内で手先が右上、右下、左上、左下のそれぞれにある場合を表象する Cf 空間の面積を調べた。図 8 の図を 40×40 のグリッドに区切り、各セルの Cf 空間に対応する手先位置が上記 4 カテゴリのいずれに対応するか計算し、セルの個数を数えた。

図 10 は 4 カテゴリの Cf 空間での面積比の平均と標準偏差である。このように手先が上にある事を示す Cf 空間はその逆より大きな面積を割り当てられることが分かった。ロボットの目は手より上部にあり、このような物理的な身体の構造が Cf 空間の非対称性を生んだものと考えられる。

我々のモデルでは第一章の前頭葉運動制御部と空間地図が C_s と Cf に対応し MTRNN という一つのダイナミクスの中で相互に影響しながら働いている。本実

験で得られたように人においてもその身体構造が脳内の空間地図を歪めていることが考えられる。

7. おわりに

本研究では内部モデルに基づく、視野内に複数の移動物体を含む状態からの身体図式獲得モデルを提案した。提案モデルを神経力学モデル MTRNN で実装しロボットから取得したデータで学習を行ったところ、自己身体とそれ以外で有意な予測精度差が現れ、これらを予測精度の観点から分離可能であることが分かった。

また、学習済みの MTRNN の Cf 空間に手先位置を表象する空間地図が自己組織的に獲得されていること、その空間地図は身体の物理的な構造により非対称な形に歪められていることが分かった。

8. 謝辞

本研究の一部は JST さきがけ、科研費基盤 (S)(B)、科研費学術創成、GCOE の支援を受けた。

参考文献

- [1] Burton L. White “The first three years of life”, Simon & Schuster, 1993
- [2] Graziano, M.S.A. and Gross, C.G. “Spatial maps for the control of movement”, Current Opinion in Neurobiology - vol.8, No.2, pp.195-201, 1998.
- [3] K. Sekiyama “Dynamic spatial cognition: Components, functions, and modifiability of body schema”, Japanese Psychological Research, 2006.
- [4] Jordan, M.I. and Rumelhart, D.E. “Forward models: Supervised learning with a distal teacher”, Cognitive Science: A Multidisciplinary Journal, vol.16, no.3, pp.307-354, 1992
- [5] R.C.Miall and D.M.Wolpert “Forward Models for Physiological Motor Control”, Neural Networks, Vol.9, No.8, pp.1265-1279, 1996.
- [6] Frith, C.D. and Blakemore, S.J. and Wolpert, D.M., “Explaining the symptoms of schizophrenia: abnormalities in the awareness of action”, Brain Research Reviews, vol.31, No.2-3, pp.357-363, 2000.
- [7] S.Gallagher “Philosophical conceptions of the self: implications for cognitive science”, Trends in Cognitive Sciences - Vol.4, No.1, Jan. 2000.
- [8] Y.Yamashita and J.Tani “Emergence of Functional Hierarchy in a Multiple Timescale Neural Network Model: a Humanoid Robot Experiment”, PLoS Comput. Biol., vol.4, no.11, 2008.
- [9] P.J.Werbos “Backpropagation through time: What it does and how to do it”, Proceedings of the IEEE - Vol.78, No.10, pp.1550-1560, 2002.