

神経回路モデルを用いた 道具身体化モデルによる道具機能表現の獲得

山口 雄紀[†] 信田 春満[‡] 西出 俊[‡] 奥乃 博[‡] 尾形 哲也[‡]

[†] 京都大学 工学部情報学科 [‡] 京都大学大学院 情報学研究科 知能情報学専攻

1. はじめに

本研究では、ロボットの多様な道具使用を実現することを目標とする。従来の道具使用に関する研究では、道具の認識と利用動作の生成を切り分け、道具特徴量や動作選択は人手で設計されていた。しかし、実世界の道具には様々な特徴や使用方法があり、多様な状況に対応することが難しかった。認識と利用を1つの枠組で取り扱う道具学習、つまりロボットの身体性を考慮した学習が重要であることが近年の研究で示唆されている [1]。

人は道具を使うとき、道具が身体の一部であるかのように感じる。この現象は道具身体化と呼ばれる。道具身体化は神経レベルの処理としても行われていることが道具使用の訓練をされたサルを解析した実験から分かっている [2]。また、人は学習が進むと道具の機能をその形状から推定できることが示唆されている [3]。

本研究では、道具身体化モデルを構築し、既知道具・未知道具の認識・操作を行うことで検証した。具体的には、Multiple Time-scales Recurrent Neural Network (MTRNN) をロボットの自己モデルとして一旦学習し、道具を持ったときに自己の身体を拡張させるためのパラメータとなるニューロン群を付加することにより、自己組織的に道具機能を獲得させる。さらにここで獲得された道具の機能と道具形状を階層型ニューラルネットを用いて関連付けることにより、道具の形状からその機能を推定・使用できるようにする。実験により、既知道具だけでなく未知の道具についてもロボットが把持道具をその形状から認識し、提示された動作の再現が行えることを示す。

2. 道具身体化のための神経回路モデル

2.1 MTRNN を用いた自己モデル

図 1 に提案モデルの全体図を示す。本研究では、ロボットの自己モデルとして谷ら [4] によって提唱された MTRNN を用いる。MTRNN は複数の非線形時系列パターンを学習・汎化できる学習・予測器であり、入出力層 (IO)、Fast-Context 層 (Cf)、Slow-Context 層 (Cs) と呼ばれる時定数の異なるニューロン群からなる。各層の時定数は IO、Cf、Cs の順で大きくなる。ロボットが素手で様々な動作をして MTRNN を学習することにより、Cs 初期値空間に動作特徴が現れる。

2.2 パラメータバイアスニューロンによる身体拡張

MTRNN からなる自己モデルの各ニューロン群に各シーケンス中は値の変化しないパラメータバイアスノード (PB) を繋ぐ。ロボットが道具を持って様々な動作を行い、物体を操作する学習を行うことで PB 空間には道具の機能表現が自己組織的に獲得される。

2.3 階層型 NN による機能と形状および動作の関連付け

PB 空間に得られた道具の機能をその道具の形状と動作から連想するための機構を用意する。具体的には、道

具使用学習によって得られた各道具と動作に対する PB 値を出力とし、道具の形状と動作特徴量を表す Cs 初期値を入力とする階層型ニューラルネットを学習することにより、道具の形状からその機能を推定できるようになる。

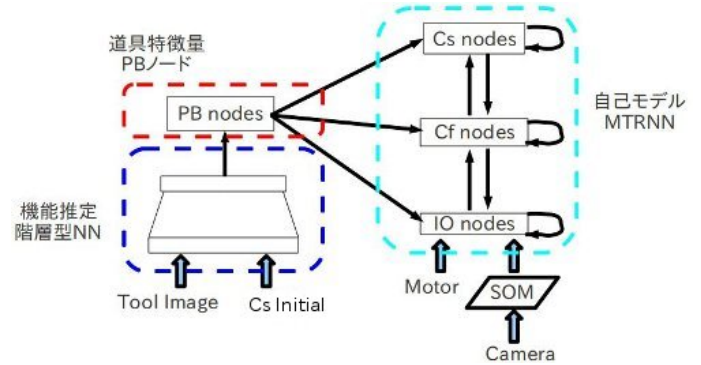


図 1: 道具身体化モデルの概要図

3. 道具身体化の学習・生成プロセス

道具身体化が起こるとき、人は既に獲得済みの自己の動作モデルを流用することにより、道具を持った自分の動作を効率的に予測することができる。

そこで、本研究ではまず自己の動作モデルを獲得した後、自己は固定したままそれに付加する形で道具を持った時の変化を学習することが重要であると考えられる。以下のプロセスはその考えに基づいたものであり、最初から道具学習と動作学習を一緒に行おうとすると道具特徴の獲得が難しいことを後に示す。本手法の道具身体化プロセスは以下の 6 つのフェーズからなる。フェーズ 1-3 が学習フェーズ、4-6 が認識・生成フェーズとなる。

1. 自己モデルの学習 ロボットは事前に設計した動作を素手で行い、データを取得する。取得されたデータを用いて BPTT により MTRNN の各ニューロン間の結合重みと各動作に対応する Cs 初期値を学習する。
2. 道具の機能学習 ロボットは様々な道具を持ってフェーズ 1 で学習した動作を行い、データを取得する。取得されたデータを用いて MTRNN 本体の結合重みは固定し、各ニューロンと PB ノードとの間の結合重みと PB 値のみを学習させる。このとき Cs 初期値にはフェーズ 1 で得られた同一動作に対応する値を用いる。
3. 形状からの機能推定機構の学習 フェーズ 3 で得られた PB 値を出力とし、それに対応する道具の静画像と動作を表す Cs 初期値を入力とするように階層型ニューラルネットを学習することにより、道具の形状と機能と動作を関連付ける。
4. 把持道具の機能推定 ロボットは自分の手を見る。把持道具の形状から各動作を行ったときにどのよう

Tool-Body Assimilation Model using Neuro Dynamical System for Acquiring Representation of Tool Function: Yuki Yamaguchi (Kyoto Univ.), Harumitsu Nobuta (Kyoto Univ.), Shun Nishide (Kyoto Univ.), Hiroshi G. Okuno (Kyoto Univ.), and Tetsuya Ogata (Kyoto Univ.)

な機能が現れるかを予測する．具体的には，道具の静画像と各動作を表す Cs 初期値を入力として階層型ニューラルネットの出力する PB 値を求める．

5. 動作シミュレーション フェーズ 4 で得られた PB 値と Cs 初期値を MTRNN に入力することで関節値と視覚の変化を各動作について予測する．
6. タスクに最適な動作の選択 人間に提示されたタスクを達成するのに最適な動作をフェーズ 4 でシミュレーションされた視覚予測の中から選択する．

4. ACTROID による道具使用学習実験

4.1 実験条件

テストベッドはヒューマノイドロボット ACTROID を用いた．操作対象となる物体は白い円柱の上面を赤く塗ったもの，使用道具は I 字，L 字，T 字型の棒状物体で，L 字型の棒を未知道具とし，学習時には使用しない．

取得データは関節データと画像データからなる．関節データは ACTROID の右腕の関節角 (7 次元) を用いた．画像データは ACTROID に搭載されたカメラの画像を縮小した 32 × 24 のグレイスケール画像を用いた．この画像データを Self-Organizing Map (SOM) を用いて 25 (5 × 5) 次元の画像特徴量に変換して用いた．関節データと画像データを正規化して得られる 32 次元ベクトルを MTRNN への入力とする．また，道具の形状を調べるための画像として図 2 の画像を使用した．

用いた動作は，ロボットの手先を初期位置 状態 1 状態 2 と動かす．各状態は手先の位置 { 対象物体の左手前，左奥，右手前，右奥 } と手先の向き { 正面，右斜め } で決定される．学習には 30 通りの動作を用いた．

提案モデルに未知道具の画像と引き寄せ操作を提示し，その動作を再現する関節値を予測させる．また，以下で定義する 2 つのモデルについて，同条件下で道具特徴獲得について比較する．

- 提案モデル：自己モデル学習後，道具身体化モデルを学習 (フェーズ 1 の後，フェーズ 2 を学習)
- 同時学習モデル：道具と動作を道具身体化モデルのみで学習 (フェーズ 1 とフェーズ 2 を同時に学習)




図 2: 道具の静画像 左から素手, I 字, L 字, T 字

4.2 実験結果と考察

既知道具では提示した動作の生成に成功した．未知道具である L 字型の棒を持った手の画像と引き寄せタスクを提示したときにモデルが生成した関節値 (7 次元) で実際に ACTROID を動作させたところ，引き寄せタスクに成功した．その様子を図 3 に示す．


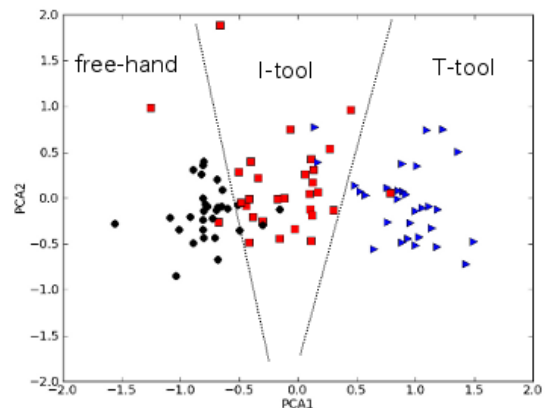



図 3: 未知道具 (L 字型の棒) による引き寄せ操作の再現

図 4 に道具学習の結果得られた PB 値の第 1, 第 2 主成分の分布を示す．図 4-a より提案モデルの PB 値は道

具ごとにクラスタリングされていることが分かる．一方，図 4-b から同時学習モデルは分布が散らばっており，道具特徴を獲得しているとは言えない．



a: 提案モデル：自己モデル学習後，道具身体化モデルを学習



b: 同時学習モデル：道具身体化モデルのみで学習

図 4: 道具特徴量を獲得する PB 空間の分布 黒：素手，赤：I 字，青：T 字

5. おわりに

本稿では，道具身体化モデルを構築し，実ロボット上に実装して実験によりモデルの検証を行った．実験の結果，道具の形状からその機能を推定し，提示されたタスクが再現可能であることを確認した．また，未知の道具を把持した場合でも，引き寄せタスクの再現に成功した．

本来は動作を事前に設計するのではなく，ロボットが自由に体を動かす中で重要な動作パターンを自律的に獲得していくことが望まれる．今後は，自律的な自己モデルの学習法を模索すると共に道具やタスクの種類を増やすことにより，モデルの検証を行う予定である．

謝辞 本研究の一部は JST さきがけ，科研費基盤 (B)，科研費学術創成の支援を受けた．

参考文献

- [1] Alexander Stoytchev, Behavior-Grounded Representation of Tool Affordances, ICRA, 2005
- [2] 入来篤史, 道具を使うサル, 医学書院, 2004
- [3] C. F. Michaels, Z. Weier, and S. J. Harrison, Using vision and dynamic touch to perceive the affordances of tools, Perception, Vol. 36, pp. 750-772, 2007.
- [4] 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