

# ロボットによる卓上物体操作のための RNNを用いた道具身体化モデルの構築

中川 達裕\* 尾形 哲也† 谷 淳‡ 高橋 徹† 奥乃 博†

\* 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 ‡ 理化学研究所脳科学総合研究センター

## 1. はじめに

本研究の目的は、実ロボットの道具使用モデルの構築である。「道具を使う」ためには、道具の 1) 認識と 2) 利用という 2つの能力が必要となる。従来の道具を扱う研究では、この二つの問題を切り分けて研究されていた。しかし実世界の道具は多様であり、また各道具の利用法も多様であることから、認識と利用を切り分けた結果、問題が複雑になっていた。近年の研究で身体性の考慮が道具の機能理解につながることを示唆されている [1]。

人は道具を手を持ったとき、それを身体の延長であるかのように扱うことができる。本研究では道具を身体の延長と知覚することを「道具身体化 (tool-body assimilation)」と呼ぶ。これは人が道具を使う際に、認識と利用を同一の枠組で扱っていることを示唆している。

本研究では、道具身体化のプロセスをモデル化し、そのモデルを用いて既知道具、未知道具の認識・利用を行う手法を構築した。具体的には、卓上物体の移動をタスクとし、Multiple Timescales Recurrent Neural Network (MTRNN) をロボットの自己モデルとして利用した。MTRNN の振る舞いを変調させるための階層型ニューラルネットを付加したモデルを道具使用モデルとして利用する。実験により、既知の道具だけでなく未知の道具を用いた場合でもロボットが動作との組み合わせによって把持道具の認識を行い、提示された動作を再現できることを示す。

## 2. 道具身体化モデル

### 2.1 MTRNN による自己モデル

本研究では、ロボットの自己モデルとして谷ら [2] によって提唱された MTRNN を用いる。MTRNN は複数の時系列パターンを学習・汎化できる学習器で、Input-Output units (入出力層)、Fast-Context units (Cf)、Slow-Context units (Cs) と呼ばれる異なる時定数を持つニューロン群で構成され、Cf と Cs の各ニューロンは自己再帰結合を持つ。Cs の初期値 ( $C_{s0}$ ) を変更することで複数の時系列パターンを一つのネットワークで表現可能になる。

### 2.2 Second-order network による道具身体化モデル

道具の身体化は、自己モデルの一部を変調させることだと考えられる。そこで、MTRNN の各ノード間の結合重みの一部を決定する、パラメータ値 (PB 値) を入力に取る階層型ニューラルネット (変換モジュール) を付加した。(図 1 参照)。つまり MTRNN の入出力層と Cf 間の結合は 2 次ネットワーク (second-order network) となる [3]。

学習に用いるデータはロボットの関節の角度情報と、カメラ画像である。

## 3. 道具身体化モデルのロボットへの実装

### 3.1 テストベッドと取得データ

本稿で用いるテストベッドは、ヒューマノイドロボット HRP-2 を用いた。操作対象は、上面と側面を赤色に

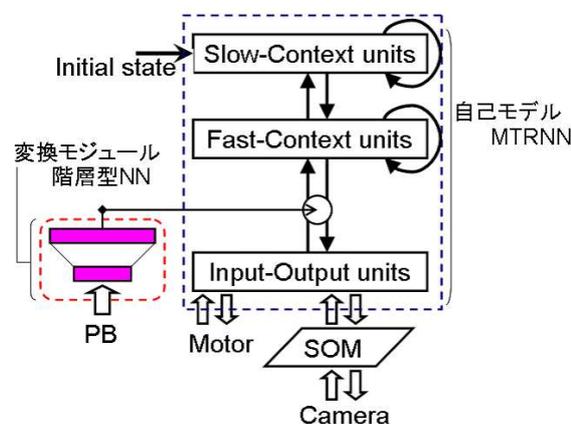


図 1: 道具身体化モデル

した円柱状の物体、用いる道具は I 字型、L 字型、T 字型の棒状物体である。操作対象は卓上に 2 つあり、一方はロボットの手の届く位置に、もう一方は道具を持たなければ届かない位置に置いた。

取得データは画像データとモーターデータである。画像データは、HRP-2 に搭載されたカメラからの画像を縮小した  $16 \times 12$  のカラー画像を用いた。上記の画像データを Self-Organizing Map (SOM) を用いて  $3 \times 3$  の特徴量ベクトルに変換する。変換し 9 次元の画像特徴量として用いた。モーターデータは左腕の関節角情報 7 次元 (肩 Pitch, 肩 Roll, 肩 Yaw, 肘 Pitch, 手首 Roll, 手首 Yaw, 手首 Pitch) を用いた。画像特徴量とモーターデータを正規化し、90 ステップ (66ms/step) の 16 次元ベクトルを得る。

### 3.2 道具身体化のプロセス

本手法は、4 フェーズから構成される。

**フェーズ 1: 自己モデルの学習** 意図する物体操作となるようプログラムした複数のモーションを道具を持たない状態でロボットが生成し、データを取得する。取得されたデータを用いて MTRNN を 30000 回学習させる。学習には BPTT を使い、各ニューロン間の結合重みと各動作に対応する  $C_{s0}$  を求める。

**フェーズ 2: 変換モジュールの学習** ロボットは道具を把持した状態と道具を持たない状態で、フェーズ 1 で学習した動作を生成し、データを取得する。得られたデータを用いて変換モジュールのみの学習を行い、各道具ごとに自己組織化された PB 値を得る。具体的には、MTRNN の結合重みを固定した状態で、変換モジュールを延べ 20000 回学習させる。これによって変換モジュールと MTRNN 間の結合重みと各道具に対応する PB 値が求まる。このとき  $C_{s0}$  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。

**フェーズ 3: 変換モジュールの同定 (把持道具の身体化)** ロボットは試し振りを行う。具体的にはフェーズ 2 と同様に、フェーズ 1 で学習した動作を生成し、データを取得する。得られたデータを道具身体化モデルに入力する

Tool-Body Assimilation Model using Recurrent Neural Network for Robot to Move Objects on a Table Tatsuhiko Nakagawa, Tetsuya Ogata, Jun Tani, Toru Takahashi, and Hiroshi G. Okuno

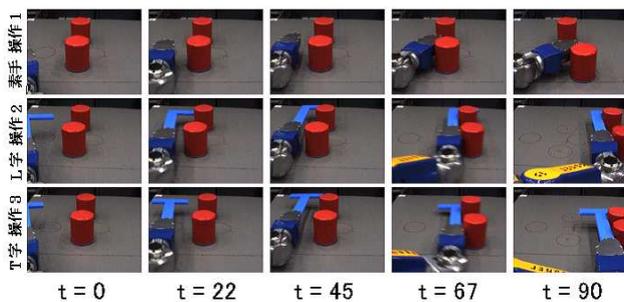


図 2: ロボットから見た操作 1, 2, 3 の様子

ここで視覚画像を予測し、実際に得られる画像情報との誤差が最小になるような変換モジュールの PB 値を計算する。

フェーズ 4: 道具を用いた動作の生成 フェーズ 3 で得られた PB 値を使用し、人間に提示される目標状態を達成するような  $Cs_0$  を計算する。得られた  $Cs_0$  を道具身体化モデルに入力することで、道具を用いた動作を生成する。

#### 4. 評価実験：未知道具を用いる動作の連想

##### 4.1 実験条件

MTRNN のサイズは入出力層が 16, Cf が 45, Cs が 15 とした。変換モジュールは入力層, 出力層の 2 層からなり, 入力層は 2 とした。

用いる道具は L 字型, T 字型, I 字型の棒状物体, 用いる操作は, ロボットの手先を初期状態 (S) → 状態 1 → 状態 2 と動かすことで生成される。各状態は手先の位置 {左手前 (ln), 左奥 (lf), 右手前 (rm), 右奥 (rf)} と手先の向き {正面 (d00), 右斜め (d45)} で決定される。学習に用いたのは次の 6 通りの操作である。

- 操作 1 S → (lf, d00) → (lf, d45)
- 操作 2 S → (lf, d00) → (rf, d00)
- 操作 3 S → (lf, d00) → (rm, d00)
- 操作 4 S → (lf, d45) → (lf, d00)
- 操作 5 S → (lf, d45) → (rf, d00)
- 操作 6 S → (lf, d45) → (rm, d00)

図 2 に例を示す。上から順に道具なしの操作 1, L 字把持の操作 2, T 字把持の操作 3 である。

フェーズ 1 でロボットは操作 1 ~ 操作 6 を自己モデルとして学習する。続いて, フェーズ 2 では L 字型と T 字型の各道具について操作 1 ~ 操作 5 を学習する。フェーズ 3 でロボットは試し振りとして操作 1 ~ 操作 4 を行う。フェーズ 4 でロボットに操作 5 を提示し, その動作の再現に必要な関節角の情報を予測させる。

##### 4.2 実験結果と考察

既知道具では提示した動作の予測が可能であった。図 3 に未知道具の I 字を把持したときの予測結果の一部を示す。破線は提示した動作のモーター値, 実線はロボットの予測した動作のモーター値である。縦軸は各モーターの角度情報を正規化した値, 横軸はステップ数を表す。フェーズ 4 において, 操作 5 についてはほぼ正しい予測が可能であると言える。これより, 本手法を用いることで未学習の形状の道具についても, その特徴を予測可能である。

また, 実験の結果得られた PB 値を図 4 に示す。L 字型, T 字型の変換モジュール学習時に得られた PB 値 (図中: 学習), I 字型の操作 1 ~ 4 で試し振りを行ったときの PB 値 (図中: 操作 1 ~ 4), 加えて操作 3 ~ 操作 6 で試

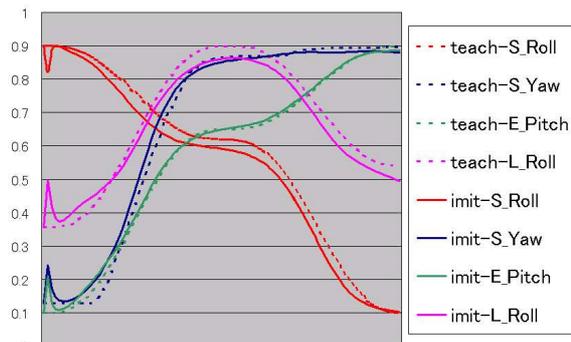


図 3: I 字の道具を把持した状態での操作 5 の連想

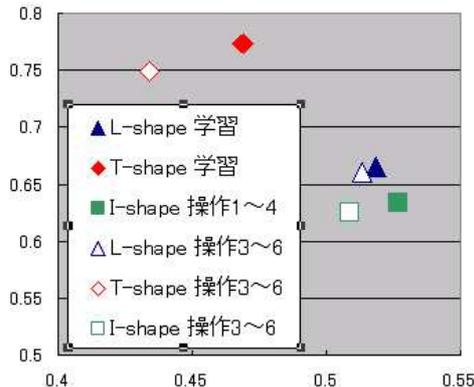


図 4: 試し振りによって得られた PB 値

し振りを行ったときの PB 値 (図中: 操作 3 ~ 6) も併記する。道具ごとに異なった PB 値のクラスが形成された事が確認できた。

#### 5. おわりに

本稿では, 実ロボット上に道具身体化のモデルの構築を行い, そのモデルの挙動をシミュレーション上で確認した。実験の結果, 道具身体化の過程において, 道具形状が動作との組み合わせで判別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, 試し振りを行い道具の身体化を行えば, その動作をロボットが再現可能なことを確認した。

今後の予定としては, 動作と道具の種類を増やすことで, 本モデルの限界の検証を行う予定である。また, 自己組織的に得られた道具の特徴と実際の道具機能が関連付けて理解されているかを検証するために, 指示された目標状態を達成可能かどうかを判断する機能を実装する予定である。

#### 謝辞

本研究は科研費学術創成研究, 基盤研究 (S), 及びグローバル COE の支援を受けた。

#### 参考文献

- [1] Alexander Stoytchev, “Behavior-Grounded Representation of Tool Affordances” ICRA 2005
- [2] Yamashita Yuichi, Tani Jun, “Emergence of functional hierarchy in a multiple timescale neural network model: a humanoid robot experiment” PLoS Computational Biology, 4, 11, e000220-1-e1000220-18 (2008)
- [3] Pollack, J., “The induction of dynamical recognizers. Machine Learning”, 7, 227-252.