

二次リカレントニューラルネットワークを用いた 道具身体化モデルの構築

西出 俊 (京大) 中川 達裕 (奈良先) 尾形 哲也 (京大)
谷 淳 (理研) 高橋 徹 (京大) 奥乃 博 (京大)

Modeling Tool-Body Assimilation using Second-Order Recurrent Neural Network

*Shun NISHIDE (Kyoto Univ.), Tatsuhiro NAKAGAWA (NAIST),
Tetsuya OGATA (Kyoto Univ.), Jun TANI (RIKEN),
Toru Takahashi (Kyoto Univ.) Hiroshi G. OKUNO (Kyoto Univ.)

Abstract— In this paper, the authors present a tool-body assimilation model using a second-order recurrent neural network. The model is composed of a dynamics learning module, tool recognition module, and a feature extraction module, each using Multiple Time-scales Recurrent Neural Network (MTRNN), second-order hierarchical neural network, and Self-Organizing Map (SOM), respectively. The second-order hierarchical neural network inputs a parametric bias (PB), representing the tool the robot is holding. Experiments were conducted with HRP-2 holding no tool, I-shaped, T-shaped, and L-shaped tools. The model was capable of self-organizing the grasped tool in the PB using wave motion. Motion generation experiment has shown that the robot learned the characteristic of the hooked shape to pull an object.

Key Words: Tool-Body Assimilation, Neural Networks, Active Sensing, Humanoid Robots

1. はじめに

道具を使用する能力は人間の最も基礎的で必要不可欠な能力の一つである。人間社会には多数の道具が存在し、各道具特有の機能を備えている。ロボットを人間社会に導入する上で、道具の機能を把握し、使用する能力を付与することは不可欠である。

ロボットが人間と同様に道具使用能力を獲得するためには、人間が道具使用能力を獲得する過程に基づいてロボットの行動獲得機構を構築することが重要である。幼児は多数の試行錯誤を繰り返し、道具に関する知識を獲得し、汎化するといわれている [1]。初期のころ、幼児はダイナミックタッチ（振り動作など）[2]によって道具の機能を識別する。道具使用経験を繰り返していくうちに道具が自己の身体の一部であるかのように知覚されるようになる。この現象は神経生理学分野で「道具身体化」と呼ばれており、同様の機能が猿にも存在することが確認されている [3]。本研究の目標はロボットの能動知覚経験 [4] をもとに道具身体化モデルを自己組織的に獲得することである。

道具身体化モデルの構築において、以下の二つが課題として挙げられる。

1. 道具識別
2. 道具使用動作の設計

従来の研究では 1. か 2. のいずれかにのみ注目してきた。また、道具を表現する特徴量が事前に設計されていたため、未知道具に適応できないという問題点があった。

本研究では以下の二つのアプローチによってこれらの課題に対処する。

1. 道具特徴量の自己組織化と振り動作による道具識別
2. 道具とロボットの動作の汎化

1. のアプローチについて、我々は自己組織化マップ (SOM) を用いてカメラ画像から道具特徴量を自己組織化する。また、ダイナミックタッチの動作として振り動作を用い、道具の動特性を推定する。2. のアプローチについて、本研究ではニューラルネットワークを用いてモデルを構築する。ニューラルネットワークの汎化能力により、未知道具や動作にも対応することが可能になる。

道具身体化の研究は近年注目されてきており、関連研究としては鍋島ら [5] や疋田ら [6] が行った研究がある。鍋島らは、不可視領域内の物体を道具を用いて引き寄せるタスクをシミュレーションモデルを用いて行った。しかし、道具を表現する特徴量は事前に設計されており、柔軟物によって構成される道具など未知道具には適応することが困難であった。疋田らは道具把持状態の身体延長を saliency map によって表現した。本研究では、このような表現を用いて動作を生成することに主眼を置いている。

本研究では、道具使用動作の指標として身体の拡張に注目した。身体の拡張は動物が道具を使用する 4 つの要因の一つといわれている [7]。同様の研究が Stoytchev によって行われており、アフォーダンス表に基づいて道具とロボットの動作に対する対象物体の挙動の関係を学習した [8]。ただし、色情報を用いて道具を識別しており、また画像特徴量も与えていたため、想定した環境内にしか適応できなかった。本研究では、画像特徴量を自己組織化するため、未知道具も扱えるモデルを実現した。

以下、本稿の構成は次のようになっている。第 2 章では構築したモデルと学習手法について述べる。第 3 章では道具身体化プロセスについて述べる。第 4 章で

は実験の設定について述べる．第5章では行った実験結果について述べ、第6章で全体のまとめと今後の展望について述べる．

2. モデルの構築

本章ではモデル全体の概略を説明する．本モデルは特徴量抽出モジュール、ダイナミクス学習モジュール、道具識別モジュールの三つのモジュールからなっている．特徴量抽出モジュールには画像から特徴量を抽出するため、SOMを用いた．ダイナミクス学習モジュールにはリカレントニューラルネットワークの一種である、Multiple Time-scales Recurrent Neural Network (MTRNN) (Fig. 1) [9]を用いた．MTRNNモデルの詳細は次節で説明する．SOMとMTRNNは特徴抽出器と時系列学習器として相性がいいことが示されているため[10]、本研究でもこれらを用いた．道具識別モジュールはParametric Bias (PB) ノードをMTRNNの重みに連結する二次ネットワーク[11]によって構築した．ここで用いるPBノードはRecurrent Neural Network with Parametric Bias (RNNPB) [12]と同様の役割を果たし、PBの値を変更することでMTRNNの挙動を変えることが可能である．モデル全体を学習することで、ロボット/道具/物体のダイナミクスを学習し、異なる道具やロボット動作の関係をPB層やSlow Context層に自己組織化する．モデル全体の概略図をFig. 2に示す．

2.1 MTRNNモデル

MTRNN (Fig. 1) は二層からなるRecurrent Neural Network (RNN) であり、現時刻のモータ値 $M(t)$ と画像特徴量 $I(t)$ を入力し、次時刻のモータ値 $M(t+1)$ と画像特徴量 $I(t+1)$ を出力する予測器である．コンテキスト層はFast Context層 C_F とSlow Context層 C_S からなり、履歴情報を扱うことも可能である．異なる時定数を持つコンテキスト層により、従来のRNNより長く、複雑な系列を学習することが可能である．入力層の時定数が最も小さく、Slow Context層の時定数が最も大きい．第一層の各ノードは次のものを除き、全て




Fig.1 Composition of MTRNN

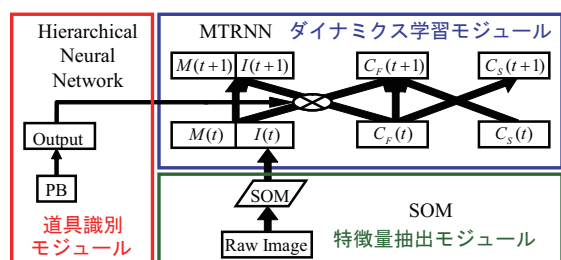


Fig.2 Overview of the Whole Model

第二層の各ノードに結合している： $[M(t), I(t)]$ 層から $C_S(t+1)$ 層、 $C_S(t)$ 層から $[M(t+1), I(t+1)]$ 層、 $M(t)$ 層から $I(t+1)$ 層、 $I(t)$ 層から $M(t+1)$ 層．モデルの学習にはBack Propagation Through Time (BPTT) アルゴリズム [13] が用いるが、詳細については紙面の都合上、省略する．

学習したMTRNNを用い、初期 C_S 値から時系列を復元することが可能である． $C_S(0)$ と初期のモータ値 $M(0)$ 、画像特徴量 $I(0)$ を入力することで時刻0の出力が得られる．出力を再帰的に入力部に入れることで時系列全体を復元することができる．この計算方法を *Closed Loop* 計算と呼ぶ．一方、各時刻において観測モータ値と画像特徴量を入れて時系列を計算する方法を *Open Loop* 計算と呼ぶ．

2.2 道具識別モジュールの学習

道具識別モジュールの学習はMTRNNと同様、BPTTアルゴリズムによって行う．MTRNNの第 j 番目の入力ノードから第 i 番目の出力ノードの重みに連結する二次ネットワークの出力ノードを O_{ij} とし、学習誤差を E とする．逆伝搬されてきた学習誤差を用い、 k 番目のPBノードから O_{ij} への重みは以下の式で更新される．

$$w_{ijk}(n+1) = w_{ijk}(n) - \alpha \frac{\partial E}{\partial w_{ijk}} \quad (1)$$

ここで、 α は学習係数である．また、第 k 番目のPB値 p_k は O_{ij} の出力値 o_{ij} と学習係数 ε を用いて以下の式で更新される．

$$\Delta p_k = -\varepsilon \sum_{i,j} \frac{\partial E}{\partial o_{ij}} \frac{\partial o_{ij}}{\partial p_k} \quad (2)$$

2.3 特徴量抽出モジュール

本研究ではSOMを用いて画像特徴量を自己組織化する．SOMは入力層と出力層の二層で構成されている．出力層にはノードが二次元に配置されており、入力ベクトル v と同次元の重みベクトル w を持つ．入力ベクトルは画像で構成されており、 $[0.1, 0.9]$ に正規化した各画素が入力層のノードに入力される．出力層の発火度は重みベクトルと入力ベクトルのユークリッド距離 $\|w - v\|$ を用いて決定した．

3. 道具身体化プロセス

本章では道具身体化のプロセスについて述べる．道具身体化は以下の四つのフェーズによって行われる．

1. 自己モデルの学習
2. 道具識別モデルの学習
3. 道具の振り動作による把持道具識別
4. 道具を用いた動作生成

フェーズ1. とフェーズ2. は学習時に行われ、フェーズ3. とフェーズ4. は動作生成時に行われる．

3.1 自己モデルの学習

学習データ取得時、ロボットは対象物体に対し、様々な道具や動作を用いて能動知覚を行う．画像特徴量はSOMによって自己組織化される．獲得した動作系列

と画像特徴量系列を用いてダイナミクス学習モデル MTRNN を学習する．このフェーズでロボットの動作とそれに伴う視覚上の変化の関係が学習される．

3.2 道具識別モデルの学習

学習データ取得時，ロボットは様々な道具を使用する．道具識別モジュール(階層型ニューラルネットワーク)は MTRNN の重みを固定し，PB のみを更新する BPTT アルゴリズムによって学習される．この学習により，道具の類似度に基づいて PB 空間が自己組織化される．

3.3 道具の振り動作による把持道具識別

把持物体の動特性を推定するため，ロボットは道具の振り動作を行う．観測される画像特徴量系列と予測特徴量系列の差をもとに重み固定 BPTT によって PB のみを更新する．得られた PB はロボットが把持している道具の PB となる．

3.4 道具を用いた動作生成

第三フェーズで得られた PB を用い，MTRNN の C_S 値を決定することでロボットの動作を生成する．ロボットに目標物体画像を与え，重み固定 BPTT によって C_S 値のみを更新する．第三フェーズで得られた PB と C_S 値をモデルに入力し，*Closed Loop* 計算によって動作系列を計算する．得られた動作系列に沿って動作を生成することで，目標タスクを実現するロボット動作を生成する．

4. 実験設定

本実験ではヒューマノイドロボット HRP-2 (Fig. 3) と Fig. 4 に示す三種類の道具 (L 字型, T 字型, I 字型) を用いた．T 字型と I 字型に加え，道具未把持状態の動作を学習用に用いた．L 字型の道具はモデルの評価用に未知道具とした．

4.1 データ取得

本実験では Fig. 5 に示すように，二つの立てた赤い円筒形物体を卓上に配置した．手前の物体はロボットの手が届く範囲にあり，奥の物体は道具を使用した場合のみ操作することが可能である．実験時，ロボットは左腕の 7 自由度 (肩ロール, 肩ヨー, 肩ピッチ, 肘ピッチ, 手首ロール, 手首ヨー, 手首ピッチ) を用いて動作を生成した．T 字型と I 字型の道具把持, 道具未把持の三状態で Fig. 6 に示す 9 通りの動作を用い，計 27 動作系列を取得した．各動作は初期姿勢から二つ



Fig.3 HRP-2



Fig.4 Tools used in Experiment





Fig.5 Scene of Experiment

Number	Motion Type
1	Initial \rightarrow (lf, d00) \rightarrow (lf, d45)
2	Initial \rightarrow (lf, d00) \rightarrow (ln, d00)
3	Initial \rightarrow (lf, d00) \rightarrow (ln, d45)
4	Initial \rightarrow (lf, d00) \rightarrow (rf, d00)
5	Initial \rightarrow (lf, d00) \rightarrow (rn, d00)
6	Initial \rightarrow (lf, d45) \rightarrow (lf, d00)
7	Initial \rightarrow (lf, d45) \rightarrow (ln, d00)
8	Initial \rightarrow (rn, d00) \rightarrow (lf, d00)
9	Initial \rightarrow (rn, d45) \rightarrow (lf, d00)



d00 : wrist facing vertical
d45 : wrist facing diagonal (45 degrees)

Fig.6 Training Motions

の姿勢に移行する動作になっている．画像データはロボットの中央カメラで取得した画像を 16×12 に縮小したものをを用いた．各画素は RGB 値を持っている．画像特徴量である SOM の出力は 9 次元とした．データは 15 steps/sec で 6 秒間取得し，各データの最小値と最大値に基づいて $[0.1, 0.9]$ に正規化した．

4.2 モデルの構成

本モデルの構成を Table 1 に示す．入力層, Fast Context 層, Slow Context 層の時定数はそれぞれ, 2, 5, 70 とした．

5. 実験結果

本章では実験の結果について述べる．

5.1 道具の識別

道具身体化モデルの第三フェーズでは道具の振り動作によって把持道具を示す PB を求める．各道具につき，Table 2 に示す 8 種類 (各 4 動作) を行い，それぞれについて PB を求めた．Table 2 に示す Motion Patterns の番号は Fig. 6 の番号に対応する．

得られた PB の分布を Fig. 7 に示す．Fig. 7 より，二つの顕著な特徴が見られる．

1. 道具を持たない状態の PB が道具把持状態の PB に対して離れた位置に分布している．

Table 1 Construction of Model

No. of Motor Input Nodes	7
No. of Image Feature Input Nodes	9
No. of Fast Context Nodes	45
No. of Slow Context Nodes	15
No. of Parametric Bias Nodes	2
No. of Input Nodes for SOM	576

Table 2 Motion Set for PB Determination

Motion Set	Motion Patterns
A	2, 3, 6, 8
B	1, 4, 5, 6
C	1, 5, 6, 7
D	4, 5, 7, 9
E	4, 6, 8, 9
F	1, 6, 8, 9
G	1, 6, 7, 9
H	5, 6, 7, 9




Fig.7 Self-Organized PB Space of Tools

2. 未知のL字型の道具のPBがT字型とI字型の道具のPBの中間的な位置に分布している。

1. より、ロボットが道具を把持した場合、道具を持たない時に比べ、自己モデルの動特性が大きく変わること学習した。2. より、L字型の道具はT字型とI字型の中間的な動特性を持つことを学習した。

5.2 目標指向の動作生成

本実験では、ロボットが対象物体を引き寄せるタスクを行った。ロボットに各道具を把持させ、Fig. 8に示す目標画像から C_S 値を道具身体化モデルのフェーズ4に示す手法で求めた。L字型、T字型、I字型の道具それぞれで生成された動作を Fig. 9, Fig. 10, Fig. 11に示す。L字型とT字型の道具では対象物体を引き




Fig.8 Goal State Image



Fig.9 Generated Motion (L-Shaped)




Fig.10 Generated Motion (T-Shaped)




Fig.11 Generated Motion (I-Shaped)

寄せることに成功し、I字型の道具では物体に触れるだけという異なった動作を生成した。本実験結果はロボットは道具のL字部分には引き寄せる機能があることを学習したことを示しており、モデルの汎化能力の有効性も示された。

6. おわりに

本稿ではニューラルネットワークで構成された二次ネットワークを用いた道具身体化モデルについて述べた。T字型、I字型、L字型の三つの道具で実験を行った。道具識別実験の結果、道具未把持状態と道具把持状態で、自己モデルの動特性が大きく異なることを確認した。未知のL字型道具の動特性推定と汎化能力による動作生成にも成功した。今後はより多種の道具に対し、様々な物体挙動を扱えるモデルに改良したい。

謝辞

本研究は Global COE , 科研費基盤研究 S(19100003) , 科研費学術創成 (GS0208) , 科研費特別研究員奨励費 (20-161) , 理研の支援を受けた。

- [1] A. Streri and J. Féron, "The development of haptic abilities in very young infants: From perception to cognition," *Infant Behavior and Development*, Vol. 28, pp. 290-304, 2005.
- [2] J. J. Gibson, "The Senses Considered as Perceptual Systems," *Boston, MA, Houghton Mifflin*, 1966.
- [3] A. Maravita and A. Iriki, "Tools for the body (schema)," *Trends in Cognitive Science*, Vol. 8, No. 2, pp. 79-86, 2004.
- [4] R. Bajcsy, "Active Perception," *IEEE Proc., Special issue on Computer Vision*, Vol. 76, No. 8, pp. 996-1005, 1988.
- [5] C. Nabeshima, Y. Kuniyoshi, and M. Lungarella, "Towards a Model for Tool-Body Assimilation and Adaptive Tool-Use," *Proc. ICDL*, pp. 288-293, 2007.
- [6] M. Hikita, S. Fuke, M. Ogino, and M. Asada, "Cross-modal body representation based on visual attention by saliency," *Proc. IROS*, pp. 2041-2046, 2008.
- [7] B. B. Beck, "Animal tool behavior: The use and manufacture of tools by animals," *New York: Garland STMP Press*, 1980.
- [8] A. Stoytchev, "Behavior-Grounded Representation of Tool Affordances," *Proc. ICRA*, pp. 3060-3065, 2005.
- [9] Y. Yamashita and J. Tani, "Emergence of Functional Hierarchy in a Multiple Timescales Recurrent Neural Network Model: A Humanoid Robot Experiment," *PLoS Computational Biology*, Vol. 4, No. 11, e1000220, 2008.
- [10] H. Arie, et al., "Creating novel goal-directed actions at criticality: A neuro-robotic experiment," *New Mathematics and Natural Computation*, Vol. 5, pp. 307-334, 2009.
- [11] J. B. Pollack, "The Induction of Dynamical Recognizers," *Machine Learning*, Vol. 7, pp. 227-252, 1991.
- [12] J. Tani and M. Ito, "Self-Organization of Behavioral Primitives as Multiple Attractor Dynamics: A Robot Experiment," *IEEE Trans. on SMC Part A*, Vol. 33, No. 4, pp. 481-488, 2003.
- [13] D. Rumelhart, G. Hinton, and R. Williams, "Learning internal representation by error propagation," *D. E. Rumelhart and J. L. McClelland, editors Parallel Distributed Processing (Cambridge, MA: MIT Press)*, 1986.