

特別研究報告書

人とロボットの協調作業のための
RNNPBによる擬似シンボルの獲得

指導教員 奥乃 博 教授

京都大学工学部情報学科

大谷 拓

平成17年2月10日

人とロボットの協調作業のための RNNPBによる擬似シンボルの獲得

大谷 拓

内容梗概

近年、多くのヒューマノイドロボットが開発され、人間とロボットが協調作業をとることが必要になってきた。人間と機械が協調して作業を行なうためには、言語によるコミュニケーションが必要となるが、シンボルグラウンディング問題で挙げられるように、タスクを明示的な言語で表現することは難しい。そのため、人とロボットによる対話協調に関する研究のほとんどは、限定されたタスクにおける対話協調となっている。従って、様々なタスクに応用可能な対話協調を実現するには、ロボットに自己組織的にタスク表現を獲得させる枠組みが必要となってくる。

本研究では、ロボットに学習により擬似シンボルを獲得させ、獲得された擬似シンボルを人間とのインタフェースに応用する方法について開発した。このようなインタフェースが実現すると、人間ロボット間のコミュニケーションの円滑化および作業の効率化が期待できる。

本稿では、谷により提唱されたRNNPBの手法をロボットに適応し、人間とのコミュニケーションにRNNPBのパラメータ表現を擬似シンボルとして利用する方法について報告する。RNNPBとは、Jordan型のRNN(Recurrent Neural Net)の入力層にPB(Parametric Bias)を追加したものである。BPTT(Back Propagation Through Time)学習法により得られるPB入力エラーを、時間的に移動平均してPB値の修正量を算出する。この結果、PB値の変動(0~1の連続値)は入力層、出力層のダイナミクスを“緩やかに”表現したものになる。そしてPB値を閾値(0.5)処理することにより、擬似シンボル(0,1の組み合わせ)が得られる。

設定したタスクは、ロボットと人間による卓上物体の協調移動であり、作業中の腕、頭それぞれの関節角度およびカメラによる物体の位置情報を学習データとして用いる。学習は人間がロボットに直接手で動作を教示することにより行う。また卓上物体は中心を境に赤と青の二色に分れており、回転移動をした際の回転方向および、物体を押す際のハンドと物体の接触位置の判別が行えるようになっている。

実験として4パターンの動作を人間が教示することによりデータ収集を行い、PBの数を1~6個としたRNNPBを用意し、BPTT学習法によりそれぞれ10万回学習をさせた。

PBの数が1個の場合は、A:「手前から奥に物体を押し、首を振る動作」とB:「それ以外の動作」の2種類の動作が擬似シンボルとして獲得された。PBの数を2個に増やすと、AがC:「手前から奥に押す動作」とD:「首を振る動作」に分節化され、BがE:「右から左に押す動作と右回転動作」とF:「遷移動作」に分節化され、4種類の動作が擬似シンボルとして獲得された。さらに3個に増やすと、CがG、Hに、EがI、J、K、Lの4つに分節化された。そしてPBの数を4~6個に増やした場合は、最も複雑な動作であるFが次々と細分化されていったが、それ以外の動作の分節化はほとんど行われなかった。

以上により、獲得される擬似シンボルには木構造の階層性が存在することが確認された。PB数の変化に応じて次々と細分化されていく動作というのは、その複雑さ故に協調作業においては利用することのできない動作であり、また逆にPB数が変化しても細分化されない動作というのは、その単純さ故に協調作業においては有益な動作である。つまりPB数を変化により擬似シンボルの階層性を調べることは、獲得された擬似シンボルの信頼性、および有効性の評価を行う上で、有意義なことである。またタスクの学習に必要なPB数を決定する上でも重要な指標となる。

Acquiring Quasi-Symbolic Expressions by RNNPB for Human-Robot Collaboration

Taku OHYA

Abstract

Recently, many kinds of humanoid robots are developed, and it is important for them to collaborate with humans. For human-robot collaboration, it is necessary to communicate between humans and robots by symbolic languages. But as well as the problem of "symbol grounding", it is difficult for robots to express a collaboration task with explicit languages.

For that reason, most of studies about human-robot collaboration by languages focus on only the finite tasks. Therefore, robots have to acquire the symbolic expressions of a task for themselves to collaborate with humans by those expressions in many kinds of tasks.

In this study, we discuss the possibility of a quasi-symbolic interface that uses the representations robots have acquired through experience. Realization of the interface enables robots to communicate with humans smoothly and to perform a collaboration task efficiently.

In this paper, we use the RNNPB model proposed by Tani and utilize its PB dynamics as quasi-symbolic expressions to communicate with humans. The RNNPB model has the same architecture as the conventional Jordan-type RNN (Recurrent Neural Net) model except for the PB nodes in the input layer. The learning algorithm for the PB vectors is a variant of the BPTT (Back Propagation Through Time) algorithm. The back-propagated errors with respect to the PB nodes are accumulated and used to update the PB values. As a result, the PB values express the dynamics from input layer to output layer "slowly". And robots acquire the quasi-symbolic expressions (combinations both 0 and 1) converted from the PB values (between 0.0 and 1.0) by threshold value 0.5.

The target task is moving an object on a table by human-robot collaboration with each single-handed. Learning data are sensory motor joints at right hand and head, and position information of the object in the task. The method of data acquisition is teaching hand-motion directly with human-hand. And the object is bounded in center line by two colors (blue and red). This enables a

robot to classify the rotation direction and the pushing position of the object by color difference.

In an experiment, a robot acquired data of four patterns motions by human teaching. For comparison, we prepared six RNNPB models which have different numbers of PB nodes (from one to six), and the robot learned those data with each of the RNNPB models by BPTT algorithm for one hundred thousands times.

In the case of one PB node, two motions, A: [pushing the object from near to distance and head-motion for tracking the object] and B: [other motions], were acquired as the quasi-symbolic expressions. In the case of two PB nodes, the motion A was segmented C: [pushing the object from near to distance] and D: [head-motion for tracking the object], and the motion B was segmented E: [moving the object from right to left] and F: [changing-motion between A and B]. In the case of three PB nodes, the motion C was segmented G and H, and the motion E was segmented I, J, K, and L. And in the case of from four to six PB nodes, the most complicated motion F was segmented by degrees. But other motions were hardly segmented.

Changing numbers of PB nodes revealed that quasi-symbolic expressions have a hierarchy. And the motion which was segmented according to the number of PB nodes is unavailable in the collaboration by reason of its difficulty. Contrary to that motion, the motion which was not segmented according to the number of PB nodes is available by reason of its simplicity. It follows that finding out the hierarchy is significant to evaluate the reliability and the effectiveness of acquired symbols. And the hierarchy gives an indication of determining the number of PB nodes.

人とロボットの協調作業のための RNNPBによる擬似シンボルの獲得

目次

第1章	はじめに	1
第2章	関連研究	3
2.1	課題	3
2.2	動作レベルでの情報を扱った研究	3
2.3	言語レベルの情報を扱った研究	3
2.4	動作プリミティブを扱った研究	3
2.4.1	局所表現手法	4
2.4.2	HMM手法	5
2.4.3	RNNPB手法	5
第3章	動作プリミティブ獲得手法	7
3.1	RNN(Recurrent Neural Network)	7
3.2	RNNの学習法とRNNPB(RNN with Parametric Bias)	7
3.2.1	BPTT(Back Propagation Through Time)学習法	7
3.2.2	RNNPB(RNN with Parametric Bias)	8
3.2.3	PB値の生成式	8
3.2.4	パラメータ値生成例	9
3.3	動作プリミティブと擬似シンボル	10
第4章	システムの設計と実装	11
4.1	システム全体図	11
4.2	テストベッドおよび卓上物体	12
4.3	卓上物体の協調移動タスク	12
4.4	RNNPB設計	13
4.4.1	リアルタイムパラメータ計算手法	14
第5章	擬似シンボル獲得実験	15
5.1	実験方法	15
5.2	実験結果および考察	16

5.2.1	パラメータ 2 個の場合	16
5.2.2	パラメータ 3 個の場合	17
5.2.3	パラメータ (P_i) と動作の対応表	18
5.2.4	擬似シンボルの階層性	18
5.2.5	擬似シンボルを用いた動作生成	21
第 6 章	おわりに	22
6.1	結論	22
6.2	今後の展望	22
	謝辞	23
	参考文献	23

第1章 はじめに

近年、ヒューマノイドロボットやペットロボットを始め、数多くの機械が存在する現代社会において、人間にとっての機械の在り方について改めて考える必要がある。そこで、人間と機械の関係について以下のように分類する。

「人間の指示通りに動く機械」：車や飛行機のように人間が機械の仕様に従って操作を行なうという機械のことであり、機械の性能が高まるにつれ仕様が複雑化していくため、その機械を使う人間への負担が大きくなる。

「全自動化した機械」：洗濯機やエアコンのように、機械に対する人間の負担を減らすため全自動化した機械のことであり、完全に自動化しているため決められたタスクにしか使えず、タスクが複雑になるにつれ機械の設計自体が難しくなる。また故障などの予期せぬ事態に対しての適応力はない。

「人間中心機械」：人間の意図を読み取り補助をする機械のことであり、人間の意図を理解するためには、機械が完全な人間のモデルを内部に持つ必要があるが、それは現実には不可能である。

そこで、機械中心の設計でも人間中心の設計でもない新しい設計法として、人間と機械が協調して作業を行なうといった“人間機械協調システム”の概念が提案された [1]。人間と機械が相互に能力を補い合うことで双方の負担を減らし、システム全体としての作業効率の向上を狙うことがこのシステムの一般的な概念である。人間と機械が協調して作業を行なうためには、両者間における情報の共有 (共同注意 [2]) が必要不可欠となる。共有される情報を大きく分けると、動作レベルでの情報と言語レベルでの情報の2つに分けることができる。

動作レベルでの情報とは、現在の運動情報のことであり作業に身体的動作を含めば含むほどその重要性は高くなる。しかし、運動情報というのは常に動的に変化するものであるため、その情報をお互いが把握することは難しい。また言語レベルでの情報共有は、その抽象度の高さによって非常に高度なインタラクションを可能にさせるが、タスクを明示的な言語で表現すること自体が難しいという問題 (記号接地問題) がある。

そこで動作ほど具体的ではなく、言語ほど抽象度の高くない、新たな共同注意対象が必要となる。近年、脳科学の分野において、ミラーニューロンの存在が注目されている [3]。これは、霊長類の脳内において、他者の行動を観察するときと、自分で同一の行動を生成するときとで同じ部位が使われているといっ

た知見であり、言語をつかさどる部位であるブローカ野にミラーニューロンが存在すると言われている。この事実は、脳内で、動作を基本的な要素に分けるというシンボル操作的な処理を行なっている可能性を示唆している。

本研究では、以上のような背景をもとに近年盛んに研究がなされている動作プリミティブ (動作の基本となる要素) に着目し、人間とロボットが協調作業を行ない、学習により自己組織的に動作プリミティブを獲得させること、および獲得された動作プリミティブを擬似シンボルとして扱うことの有効性についての評価を行うことを目的とする。またロボットの学習には谷により提唱されている RNNPB モデルを用いる。

以下ではまず、第 2 章で人間とロボットの協調に関する研究をあげ、その課題を挙げた上で、第 3 章で本研究の提案手法を詳しく述べ、第 4 章で評価実験を行う。

第2章 関連研究

2.1 課題

人間とロボットが協調して作業を行うためには、何らかの共同注意対象が必要となる。そこで以下では共同注意対象として、動作レベルでの情報、言語レベルでの情報、および動作プリミティブそれぞれを扱ったいくつかの研究の概要および課題を述べる。

2.2 動作レベルでの情報を扱った研究

動作レベルでの情報共有を試みる研究はいくつかなされているが、特に産総研 [4] では、人間機械協調搬送に関する研究がなされており、人間とロボットが板型物体の協調搬送を行っている。ロボットは備えられている各センサ (視覚、腕部) によって人間が物体を押したことや引いたことに関する情報を得て、自動的に動かしたい方向へと移動することが可能である。また胸部および脚部のセンサによって不整地での歩行も可能としている。しかし運動情報というものは常に動的に変化するため、人間側が共同注意対象 (ロボットの運動状態) を捉え難いという問題がある。

2.3 言語レベルの情報を扱った研究

言語レベルでの情報を扱った研究は多くなされているが、特に早稲田大学の小林ら [5] は音声認識および音声を用いた人間とロボットとの対話協調の研究を行っており、認識手法として部分隠れマルコフモデルにおける状態と出力の相互依存関係を拡張し、連続音声認識に適用を行なっている。しかし、言語によるタスクの明示的な表現、および言語モデルの設計自体が困難であり、決められたタスクに限られた音声認識になるという問題がある。

2.4 動作プリミティブを扱った研究

近年ミラーニューロン発見を契機に動作プリミティブ (運動の構成単位) に基づいた運動認知、生成に関する研究が盛んになりつつある 2.4.1 節、2.4.2 節、2.4.3 節。図 1 は動作プリミティブを模式的に表したものであり、ロボットが運動を行う際にセンサから得られる連続的なデータフローを、いくつかの構成単位に分節化したものを動作プリミティブと呼ぶ。あるデータフローから分節化

された動作プリミティブが、別のデータフロー内の動作プリミティブとしても存在する場合があります、多様な動作を認識、生成する上で動作プリミティブに着目することは重要であると考えられる。




図 1: 動作プリミティブの定義 [9]

2.4.1 局所表現手法

ATR の川人ら [6] は MOSAIC と呼ばれる手法を用いている。MOSAIC では図 2 に示すように、動作のパターン毎にモジュール (学習器) を用意する。動作の認識時には、パターンとの予測誤差の値を各モジュールについて計算し、その誤差値が最も小さいモジュールを選択しそのモジュールに学習をさせる。また同図の Gate Selection によって各モジュールに重みを付け、モジュール同士を重ね合わせることで既知のパターンあるいは、新しい動作パターンを生成することができる。各モジュールが独立している (局所表現) ため、安定した動作生成が行えるという特徴がある。




図 2: モジュールセレクション

しかし、新たな動作を学習するたびにモジュールを追加していかなければならないため、学習が進むにつれシステム自体が肥大化してしまうという問題がある。

2.4.2 HMM手法

中村ら [7] は、見まね学習を通じてシンボルを獲得するミメシスという概念を提案し、その工学的モデルとして隠れマルコフモデルを用いている。モーションキャプチャーにより、運動パターンを収集し、各パターンを原始シンボルとして隠れマルコフモデルで表現する手法 (図 3) を提案し、シミュレーション実験を通じて示している。また原始シンボルを組み合わせることにより新たな動作生成を行うことも可能である。




図 3: 原始シンボルと隠れマルコフモデル

運動パターンのアナログデータを原始シンボルと呼ばれるデジタル信号へと変換することにより、動作認識および生成を行っているが、原始シンボル自体はあらかじめ定められたものであり、多様なプリミティブが存在すると考えられる実世界において十分とは言えない。

2.4.3 RNNPB手法

谷ら [8] は、川入らの MOSAIC による局所表現とは異なり、1つのリカレントニューラルネットに Parametric Bias (PB) と呼ばれるニューロンを加え、そのニューロンでの出力および入力により動作の認識および生成を行う手法 (分散表現) を提案している。誤差逆伝播法によって得られる PB への入力エラー量を固定時間分足し合せることにより、動作パターンが構造的に変化したときのみ PB 値が変化するようにしているため、動作を自己組織的にプリミティブへと分節化可能である手法となっている。

しかし RNNPB には設定すべきパラメータ数が多く、それらは経験的にしか決めることができないという問題がある。

- 分散表現によりシステムの肥大化を防いでいる

- 自己組織的に動作プリミティブを獲得可能である

以上2つの点を考慮して、本研究では谷らによって提唱されている手法を用いることにする。次章ではその手法について詳しく説明する。

第3章 動作プリミティブ獲得手法

3.1 RNN(Recurrent Neural Network)

図4に示すように、リカレントニューラルネットは文脈層と呼ばれるフィードバック型のユニットを持っているため内部記憶を持つ。そのため、通常のニューラルネットのような1つの入力に対して1つの出力を予測するというものではなく、連続的な入力に対して出力を予測することができる。つまり時間的に長さを持つ動作のような時系列データを扱うことのできる学習モデルである。

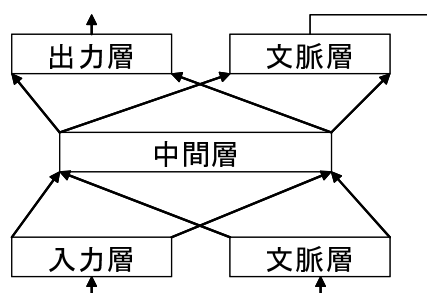


図4: RNN

3.2 RNNの学習法とRNNPB(RNN with Parametric Bias)

RNNのニューロン間重み学習法の基本は通常のNNの学習法である誤差逆伝播法(Back Propagation)を用いる。誤差逆伝播法は入力に対する出力と学習させる教師信号との誤差信号を、出力層から中間層、入力層へと順に逆伝播させることにより重み学習を行う。ところがRNNの場合、文脈層に対する教師信号が存在しないため、この方法では文脈層、中間層間の重みを学習することができない。そこで本手法では以下で説明するBPTTと呼ばれる学習法を用いる。

3.2.1 BPTT(Back Propagation Through Time) 学習法

まず図5のように学習すべき時系列データ(Step0 ~ StepT)に対して、各ステップ毎の誤差信号 δ を計算する。このときStep0における文脈層の入力はランダムな値を代入する。次に最終StepTにおける文脈層の誤差信号 δ を0とする。最終StepTにおける文脈層の出力はどんな値でも良いため、この0という値には意味はない。最終StepTにおいて出力層および文脈層からの中間層への誤差信号 δ が求まると、入力層および文脈層への誤差信号を計算することがで

きる。ここで図 5 に示すように、Step T における中間層から文脈層への δ を、Step $T - 1$ における文脈層への誤差信号 δ として用いると、Step $T - 1$ における各層への誤差信号 δ が計算できることになる。この手順を繰り返すことにより、Step $T \sim$ Step 0 まで誤差信号 δ を伝播することができる。この Step $T \sim$ Step 0 までの誤差信号伝播を 1 回の学習として、この学習を複数回繰り返すことにより、RNN は時系列データを学習することが可能となる。

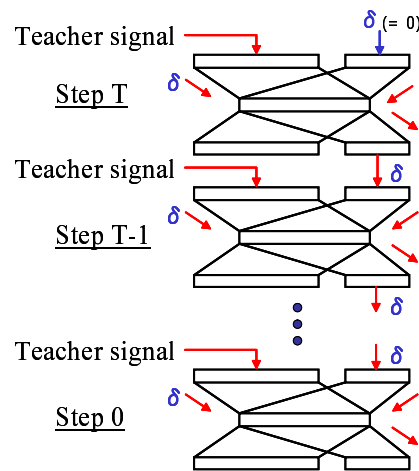


図 5: BPTT

3.2.2 RNNPB(RNN with Parametric Bias)

本手法では谷ら [9] により提唱された RNNPB(図 6) と呼ばれる学習モデルを用いる。これは RNN の入力層に PB(Parametric Bias) と呼ばれるパラメータノードを加えたものであり、時系列データの学習を行うと、その出力の時系列変化を共通パターン毎に分節化し、パラメータ値の時間的にゆるやかな変化として表現することが可能となる。また、そのパターンに対応したパラメータ値を入力することで、希望のパターンを出力させること、そしてパラメータ入力を変化させることで、1 つの RNN に複数のパターンを埋め込むことも可能である。パラメータ値の計算法は次節で計算式とともに詳しく説明する。

3.2.3 PB 値の生成式

$$\delta \rho_t^i = k_{bp} \sum_{step=t-d/2}^{t+d/2} \delta_t^{bp^i} + k_{nb}(\rho_{t+1}^i - 2\rho_t^i + \rho_{t-1}^i) \quad (1)$$

$$p_t^i = \text{sigmoid}(\rho_t) \quad (2)$$

この 2 つの式によってパラメータ値が計算される。(1) 式の第一項の $\delta_t^{bp^i}$ はス

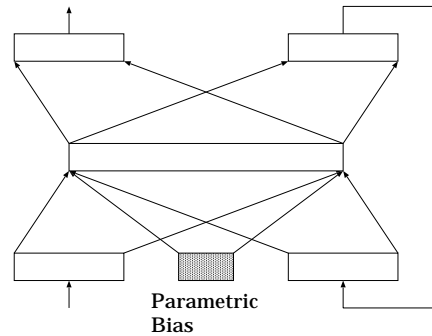


図 6: RNNPB

ステップ t における出力の誤差をバックプロパゲーションにより i 番目のパラメータノードに逆伝播したものであり、その値を固定区間 d の間で足し合わせることによって、局所的な誤差の影響を緩和させている。これによって、動作系列が構造的に変化したときにだけパラメータ値が変化ようになる。(1) 式の第 2 項の ρ_t^i はステップ t における i 番目のパラメータノードの値であり、パラメータ値自体が急激に変化するのを防ぐために前後ステップの値を用いて平均化を行っている。また、 k_{bp} および k_{nb} は経験的に決めた定数値である。そして (2) 式で、シグモイド関数を通してパラメータ値を生成する。

3.2.4 パラメータ値生成例

図 7、および図 8 のグラフは 2 つのシミュレーションデータ (各 100 ステップ) に対して、それぞれ 10 万回の学習を行った後のパラメータ値の出力結果を示したものである。このときデータ 1 に対しては 1 つのパラメータ、データ 2 に対しては 2 つのパラメータを用意している。波形データは sin 波形および定常直線の組み合わせであり、それぞれのパターンをパラメータによって分節化が行われていることが分かる。




図 7: シミュレーションデータ 1




図 8: シミュレーションデータ 2

3.3 動作プリミティブと擬似シンボル

本研究での擬似シンボルとは、前記のパラメータ値を閾値(0.5)処理によってシンボル(0, 1)に落したもののことを指し、この擬似シンボルを介して人間とロボットがインタラクションを行う。具体的には、ロボットが学習によって得られたパラメータ値を音声(人手で与えた動作番号)に変換し外部出力し、それにより協調者がロボットの内部状態の理解および擬似シンボルの意味付けを行いインタラクションを試みる。ここでパラメータ値を閾値処理した理由は、パラメータ値を連続値としてそのまま出力すると人間側の理解が困難になるという点にある。また閾値処理により情報量を落している点から“擬似”シンボルと本稿では呼んでいる。

第4章 システムの設計と実装

4.1 システム全体図

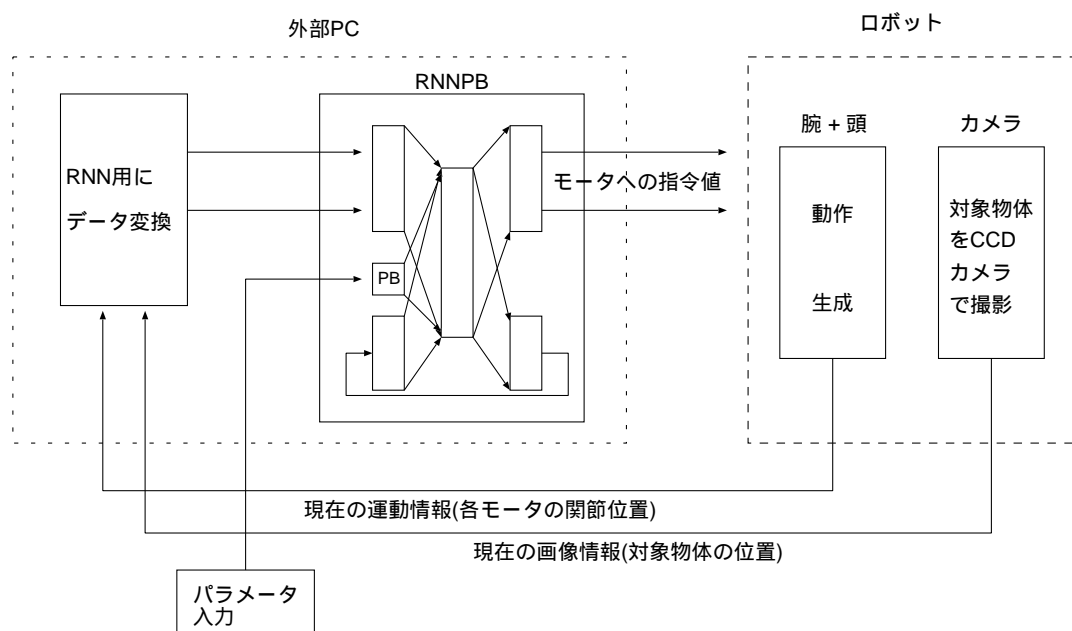


図9: システム全体図

システムの全体図は図9に示した通りである。リアルタイム処理を可能にするために、モータの制御以外のモジュールは外部PCを用いて行なっている。具体的には、CCDカメラによって得られた画像の処理計算、およびRNNPBによる次ステップでの各モータへの指令値計算を外部PCで行っている。

ロボット内蔵のPCと外部PCとで通信を行っているデータは、右腕4関節(腕ピッチ、腕ロール、腕ヨー、ひじ)、左腕4関節、頭部3関節(ピッチ、ロール、ヨー)の全角度11次元のデータであり、外部PCからは指令角度が0.1秒毎に送られ、内蔵PCからは常に現在の角度が送られてくる。外部PCでは、ロボットの各モータの現在関節角度(000~fffの16進3桁の値)をRNN入力用にデータ変換(0~1の連続値)、およびロボットからの画像情報をもとに物体の位置座標の抽出を行っている。そして得られたデータをRNNPBに入力として与えることにより、ロボットへのモータ指令値の計算を行い、ロボットに指令値を送信する。

それに対しロボットは、外部PCから送られてくる指令値をもとに動作生成

を行う。それと同時にロボットに内蔵された PC は各モータの現在関節角度を外部 PC に送信する。さらに CCD カメラにより画像情報が外部 PC へと送信される。

またパラメータの入力値は、「動作生成」の際にはキーボード入力により、「動作認識」の際には外部 PC の計算結果により決定される。

4.2 テストベッドおよび卓上物体




図 10: Robovie



図 11: 卓上物体

本研究のテストベッドは図 10 に示されるヒューマノイドロボットである。これは ATR 製の RobovieIIs を改良したものであり、頭部にモーター 3 自由度、腕部にモーター 4 自由度がある。センサーは、頭部にマイクとカメラを搭載している。また、内部に PC(CPU Pentium400[Mhz]) を搭載しており、モータ駆動のための C ライブラリが用意されている。

また、協調作業対象として図 11 に示す中心を堺に二色に分かれた箱型の物体を用いる。

4.3 卓上物体の協調移動タスク

実験を行ったタスクは図 11 の卓上物体を人間とロボットがお互いの片手で押ししたり、回転させたりして移動させていくというものを設定する。その際、カメラからの画像情報を元に物体の赤色、青色部の中心座標を抽出を行っている。具体的には画像の全ピクセルに対して、抽出したい色に応じて RGB で閾値処理を行い、処理された画像に対して領域が最大となる部分の中心座標を抽出し

ている。また学習の際には、カメラの中心に物体の中心が一致するように頭部のモータを動かすことにより、物体追跡を行う。物体の色を、中心を境に二色に分けているのは、物体の回転移動における右回転、左回転、および物体を押し位置を区別しやすくするためであり、より多くのプリミティブが獲得されるタスクとする狙いがある。

4.4 RNNPB 設計

ロボットに実装した RNNPB(図 12) は、現在のセンサ・モータ状態を入力とし、次のセンサ・モータ状態を出力(予測)する(入力・出力共に 11 ニューロン)。コンテキスト層に 20 ニューロン、中間層に 40 ニューロン、および PB 層に 1~6 ニューロンを用意した。コンテキスト層および中間層に設定したニューロン数は経験的に決めたものである。また PB 層のニューロン数は、RNNPB の表現能力および汎化能力に大きく影響するため、いくつか用意して実験を行なうことにより最適なニューロン数を決定する必要がある。

具体的な入力情報は、右腕 4 関節角度、頭部 3 関節角度、および物体の赤色、青色それぞれの 2 次元中心座標、合わせて 11 次元のデータである。PC 間通信では左腕の関節角度も送っているが、実際には左腕を動かさないため RNNPB の学習用データに左腕関節角度は用いていない。

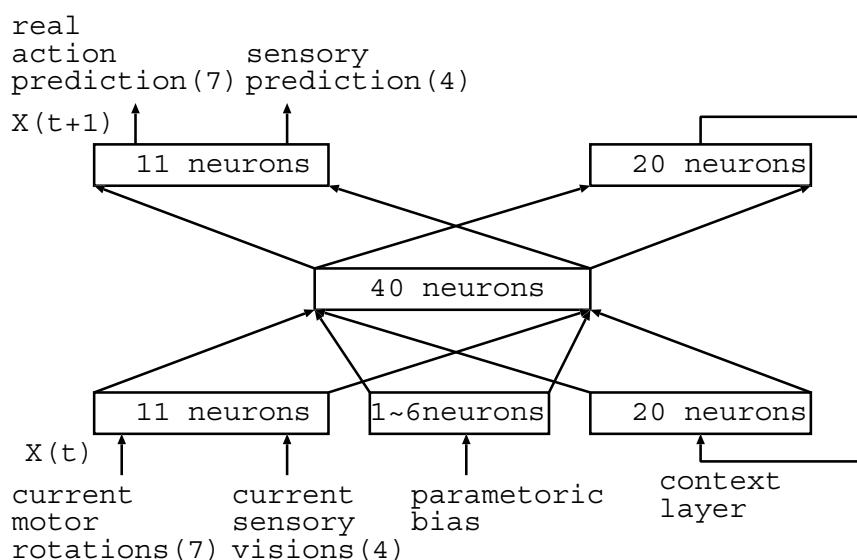


図 12: RNNPB

4.4.1 リアルタイムパラメータ計算手法

学習時におけるオフラインでのパラメータ計算手法については前章にて説明を行ったが、動作をリアルタイムで認識する際にはオンラインでのパラメータ計算手法が必要となる。オフラインでは、計算したいステップから前後数ステップ分のデータを用いてパラメータ計算を行っているが、オンラインでは過去のステップのデータのみで計算を行わなければならない。またリアルタイムでは計算時間にも制約が生じるため、過去の全てのステップ分のデータを用いて計算するわけにはいかない。そこで本研究では、参照窓範囲 (ParaWin) を設定し、その範囲内の各ステップに対してオフラインでのパラメータ計算手法を適用する。そして最後に ParaWin ステップ分のパラメータ値を平均したものをオンラインでのパラメータ計算結果とし、次ステップでのパラメータ入力とする。

第5章 擬似シンボル獲得実験

5.1 実験方法




図 13: 教示風景

図 13 のように直接ロボットに人間が手で動作を教示することにより、タスク達成に必要な学習データを収集させる。学習データとしては、モータ情報である右腕 4 関節の角度、頭部 3 関節の角度、および卓上物体の位置情報である赤色、青色それぞれのカメラ画像内 2 次元中心座標、総計 11 次元のデータを各ステップ (0.1 秒) 毎にサンプリングする。擬似シンボル獲得のための学習実験として、以下に示す 4 つのパターンの実験を行った。1 パターンのステップ数は 50(5 秒) であり、このステップ内に一度だけ各動作を行っている。

- 動作 1 : 横に置いた物体を右から左に押す (その後静止)
- 動作 2 : 横に置いた物体を右から左に押し、手前から奥に押す (中心を押す)
- 動作 3 : 横に置いた物体の右側 (赤色部) を押すことによる右回転移動 (その後静止)
- 動作 4 : 動作 3 の右回転移動をし、縦になった物体を手前から奥に押す

5.2 実験結果および考察

パラメータの数が1~6個である6つのRNNPBを用意し、上記の4パターンの動作(200ステップ分)により得られる学習データをもとに、BPTT学習法によりそれぞれ10万回の学習を行なった。以下のグラフは、6つのRNNPBのうち、例としてパラメータ数が2個および3個であるものに対して、学習後の各ステップの出力波形およびパラメータ値をプロットしたものである。ただしグラフに載せている出力波形は11次元の中から代表的な8次元のみである。

5.2.1 パラメータ2個の場合




図 14: 動作 1




図 15: 動作 2




図 16: 動作 3





図 17: 動作 4



5.2.2 パラメータ 3 個の場合




図 18: 動作 1




図 19: 動作 2




図 20: 動作 3





図 21: 動作 4



学習により得られた以上のグラフは、ロボットが自己組織的に動作を RNNPB のパラメータ値によって分節化した結果である。自己組織的に得られた動作が、人間との協調作業において有意義な動作であるかを判断するために、得られたグラフに対して人間が意味付けを行なう。意味付けの方法としては、動作 2(あるいは 4) には動作 1(あるいは 3) の動作が含まれているため、それぞれの共通部分におけるパラメータ値を読むことにより、パラメータ値と動作との対応付

けを行なうことができる。例えば図 18 および、図 19 を見た場合、動作 1 の 0 秒から 1.7 秒までの動作と、動作 2 の 0 秒から 2.7 秒までの動作はどちらも右から左に物体を押し動作で共通であり、パラメータ値も同じであるので、パラメータ値と動作との対応付けができる。これはつまりロボットが自己組織的に動作を分節化し、右から左に押すという動作を擬似シンボル (パラメータ値の組合せ) として獲得できたことを意味する。

5.2.3 パラメータ (P_i) と動作の対応表

以下の表は、図 14~ 図 17、および図 18~ 図 21 のグラフを元に、各パラメータ値と動作との対応を取ったものである。パラメータ 2 個を用いた場合に表 1 に示す 4 つの動作を擬似シンボルとして獲得できたことがわかるが、動作 1 および動作 3 の異なる 2 つの動作を同一の擬似シンボルとして獲得しているなど、十分に分節化が行えたとは言えない。さらにパラメータの数を 3 つに増やした場合、分節化されていなかった動作 1 および動作 3 の動作を異なるシンボルとして獲得することができた。

表 1: パラメータ 2 個の場合

P_1, P_2	動作
0, 0	動作 1 and 動作 3
0, 1	遷移動作 (動作 2、4 中)
1, 0	首振り動作 (動作 2 の後)
1, 1	手前 奥 (動作 2、4 中)

表 2: パラメータ 3 個の場合

P_1, P_2, P_3	動作
1, 0, 0	右 左 (動作 1)
1, 1, 0	手前 奥 (真ん中押し)
0, 1, 0	静止 (動作 1 の後)
1, 1, 1	首振り (動作 2、4 の後)
0, 0, 0	右回転 (動作 3)
0, 0, 1	遷移 (動作 4 中)
1, 0, 1	手前 奥 (縦押し)
0, 1, 1	静止 (動作 3 の後)

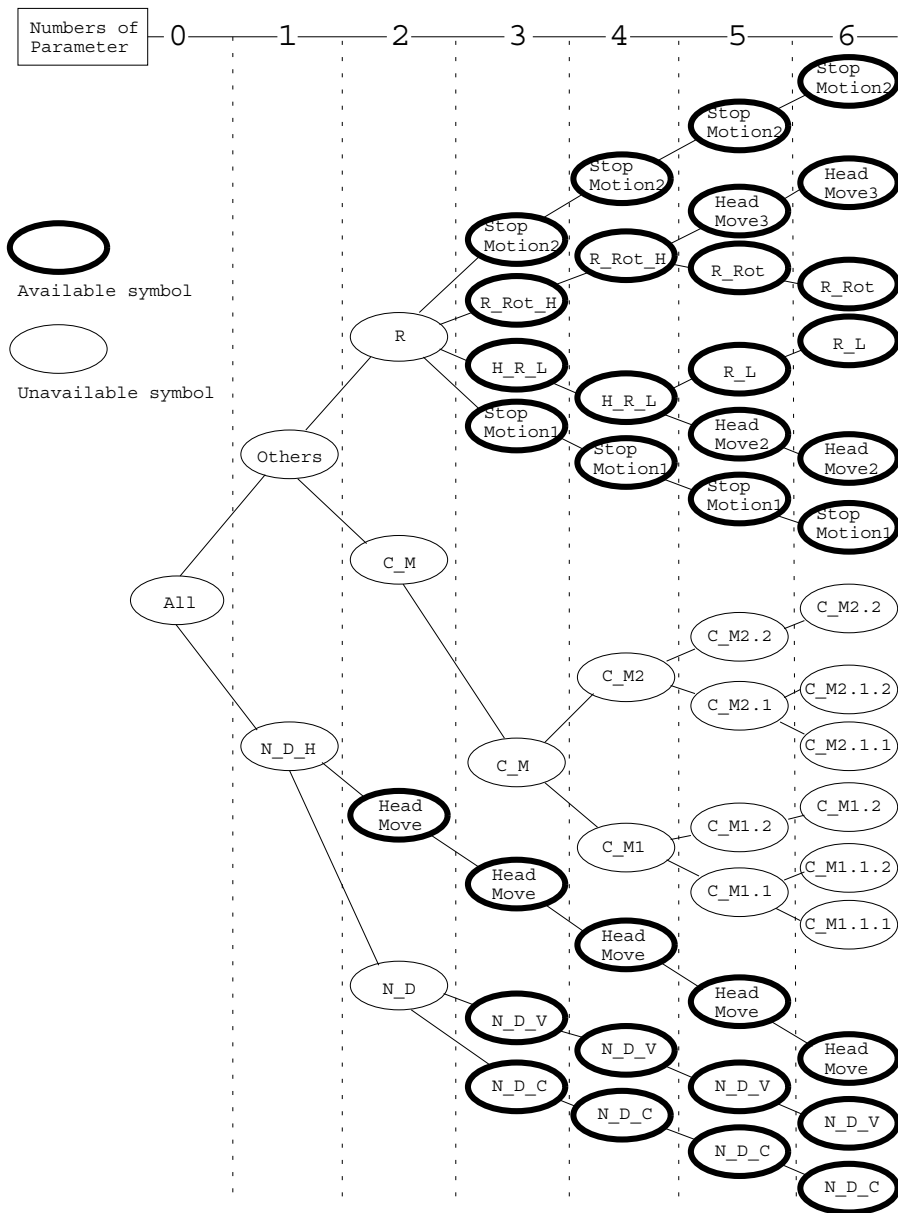
5.2.4 擬似シンボルの階層性

5.2.3 節と同一の方法で残りのパラメータ数の学習結果に対して対応表を作成したところ、各パラメータ数に応じて獲得される擬似シンボルには、図 22 に示されるような階層性が見られた。図中の太丸で囲まれた擬似シンボルは実際に利用可能な擬似シンボルであり、細丸で囲まれた擬似シンボルは分節化が不十

分、あるいは動作自体が複雑なため利用不可能な擬似シンボルを表す。

この図の顕著な特徴としては、動作の中で最も複雑なものである「遷移動作 (C_M)」にあたる動作が、パラメータを増やすにつれてより細かに分節化されていくということが挙げられる。これはパラメータを増やすことにより RNNPB の表現能力が高まり、より複雑な動作まで理解可能となったことによる結果と考えられる。しかし、パラメータの数を増やすにつれ擬似シンボルの数が増大するため、逆に人間側の擬似シンボル意味理解が困難となる。人間とロボットが協調作業を行う際に、擬似シンボルをインタフェースとして用いることを考えた場合、このことは重大な問題となる。また実際、「遷移動作」に対応する動作はシンボルとしては獲得できたが、物体を協調移動させる際にはその複雑さ故に使うことが困難な動作である。逆にパラメータ数を少なくすると RNNPB の表現能力が乏しくなり、動作パターンの学習自体が行えなくなる。

さらにパラメータの数を 7 個以上にした場合は、動作 1 における「右から左に押す動作」と動作 2 における「右から左に押す動作」の 2 つの同一であるべき動作を、その表現能力の高さ故に異なる動作として獲得してしまった。これはいわゆる過学習と呼ばれる状態であり、汎化性能を失っているという点でこれもまた協調作業において問題となる。つまり「右から左に押す」という協調作業において同一の動作を、2 種類の異なる擬似シンボルとして表現するのは冗長であり、人間側の記憶負担となる。



[Acquired Quazi-Symbolic Expressions]

All	: 4 Motion Patterns	R_L	: Pushing Object from Right to Left
N_D	: Pushing Object from Near to Distance	R_Rot	: Right Rotation
N_D_C	: N_D by Center Pushing	R	: R_L and R_Rot
N_D_V	: N_D by Vertical Pushing	C_M	: Change Motion
		Head Move	: Head Motion for Tracking Object

図 22: 擬似シンボルの階層性

5.2.5 擬似シンボルを用いた動作生成

実際に獲得された擬似シンボルを用いて動作生成を行った。図 23～26 は、それらのうちいくつか代表的な動作について撮影したものであり、図中の矢印の方向へと対象物体を移動させている。本実験ではロボット単体での動作のため、キーボード入力によりパラメータ値を与えているが、人間とロボットが協調作業を行う場合は、音声を用いる方がより自然であると思われる。具体的には獲得された擬似シンボルに番号付けを行い、その番号を音声によって人間がロボットに指示を出す。




図 23: R_L




図 24: N_D_C




図 25: R_Rot




図 26: N_D_V

第6章 おわりに

6.1 結論

人間とロボットによる物体の協調移動タスクを設定し、直接人間がロボットの腕に振れ、動きを教示することによる学習パターン収集を行い、RNNPBを用いて学習実験を行った結果、協調作業を行うために必要ないくつかの動作を、ロボットが擬似シンボルとして獲得できることが確認された。具体的にはパラメータノードを3個とした場合に、「1:右 左」「2:手前 奥(真ん中押し)」「3:静止1(1の後)」「4:首振り」「5:右回転」「6:遷移」「7:手前 奥(縦押し)」「8:静止2(5の後)」の8つの動作パターンが擬似シンボルとして獲得された。

また、パラメータノード数を変化させて学習実験を行なった結果、獲得される擬似シンボルの数はパラメータノード数によって変化した。これはパラメータノード数の変化により、RNNPBの表現能力が変化した結果である。そして、パラメータノード数を増やすことによって複雑な動作をより細かく分節化していくことが分かり、擬似シンボルには木構造の階層性が存在することが確認された。この階層性において、パラメータノード数の変化に応じて次々と細分化されていく動作というのは、その複雑さ故に協調作業においては利用することのできない動作であり、また逆にパラメータノード数が変化しても細分化されない動作というのは、その単純さ故に協調作業においては有益な動作であると言える。つまりパラメータノード数の変化により擬似シンボルの階層性を調べることは、獲得された擬似シンボルの信頼性、および有効性の評価を行う上で、有意義なことである。さらに、タスクの学習に必要なパラメータノード数を決定する上でも重要な指標となる。

またパラメータノード数3の場合に獲得された擬似シンボル(パラメータ値(0,1)の組)をRNNPBへの入力として与えたところ、学習によって得られた動作パターンを生成可能であることが確認された。

6.2 今後の展望

今回の実験により、いくつかの動作を擬似シンボルとして獲得することができたが、それが実際に協調作業において必要な動作であるのかどうかを、実際に擬似シンボルを用いて協調作業を行なうことにより定量的に評価する必要がある。また、パラメータノード数の変化により擬似シンボルに階層性が存在す

ることが確認され、その階層性に対していくつか考察を行なったが、それらが一般的に言えることであるかどうかを別のタスクに対して実験することにより検証する必要がある。

謝辞

本研究に際して御指導、ご指摘を賜りました、京都大学大学院情報学研究科奥乃博教授、尾形哲也講師、駒谷和範助手に深甚たる謝意を表します。

最後に、本研究に際しご協力を頂いた奥乃研究室の皆様に深く感謝致します。

参考文献

- [1] 早川泰久: 親和性の高い人間機械協調のためのヒューマンスキルの識別と支援に関する研究.
- [2] 大竹正海: 模倣を主体とした人間とロボットのコミュニケーション～コミュニケーションにおける空間的共同注意の役割～, 早稲田大学大学院理工学研究科修士論文.
- [3] Gallese, V. and Goldman, A.: Mirror neurons and the simulation theory of mind-reading, *Trends in Cognitive Sciences*, pp. Vol. 2, No. 12, pp. 493–501 (1998).
- [4] 原田研介: 手先反力を考慮したヒューマノイドロボットによる押し作業, 日本ロボット学会学術講演会.
- [5] 小川哲司, 小林哲則: 部分隠れマルコフモデルにおける状態・出力間依存関係の拡張と連続音声認識への適用.
- [6] M.Haruno, D. and M.Kawato: MOSAIC model for sensorimotor learning and control, *Neural Computation*, pp. 13, pp.2201–2220 (2001).
- [7] 稲邑哲也, 中村仁彦: ミメシス原理にもとづく運動認識・生成から知能への接近, 第8回ロボティクスシンポジア, pp. pp.246–251 (2003).
- [8] Tani, J.: Learning to generate articulated behavior through the bottom-up and the top-down interaction processes, *Neural Networks*.
- [9] Tani, J. and Ito, M.: Self-Organization of Behavioral Primitives as Multiple Attractor Dynamics: A Robot Experiment, *IEEE Transactions on Systems, Man, and Cybernetics Part A: Systems and Humans*, pp.

Vol.33,No.4,pp.481-488 (2003).

- [10] 松永昌樹: 人間とロボットの協調作業における動作プリミティブ創発に関する研究, 早稲田大学理工学研究科修士論文.