

学位論文

注視点に基づく手作業の理解と  
そのロボットへの実装に関する研究

小川原 光一

指導教官  
坂内 正夫 教授

## 概要

近年になり博物館や病院などの施設・家庭といった日常生活の場において人を直接支援することを目的としたロボットが相次いで研究・開発されてきている。このようなロボットの使用目的は使用者の目的に依存するため、ロボットの専門家ではない使用者がロボットに対して簡単に動作や作業を教示することのできる枠組みが求められている。この時、人間が人間に対して教示を行う方法との類似性から、実演教示の観察に基づきロボットが動作を獲得する方法が望ましいと考えられる。

本研究では、日常的に行われる手作業のうち把持物体と環境物体との連続的な相互作用として表現可能な作業を教示の対象とし、実演教示の観察に基づいた人間型ロボットに対する教示方法の確立を目的とする。本論文では、(1) 人間の教示作業を観察することでその作業の内容を理解するためのシステムの構成法、(2) 理解した内容を再利用性のある形で計算機上での中間表現である作業モデルとして表現する方法を提案し、開発した人間型ロボットを用いて作業の理解と再現を実証することによって提案手法の検証を行う。

従来の実演教示に関する研究では、対象とする作業についての十分な知識を事前に設計者がシステムに埋め込み、システムは単一の観察結果から教示動作を理解することを行っていた。しかし、この方法では認識システムが特定の作業に依存するものとなり、また作業毎に十分な知識を与える手間も膨大となる。本研究は、事前の知識は普遍性のある最小限のプリミティブ集合に限定し、まず基本プリミティブにより動作の概略を抽象化し、次にその情報からでは一意に解釈できない作業については繰り返し観察を行い情報量を増やすことによりあいまい性を解消する。同時に、作業に固有のプリミティブを自動的に獲得することで認識システム自体が対象とする作業ドメインに適応していく点が特徴である。

このときセンサ入力を一様に解析することは非効率的であり、ある時点において教示動作・もしくはロボットの再現動作のどの個所に着目して解析を行うべきかに関する戦略を適宜変更することで、段階的に作業モデルを生成する方略が望ましい。本研究では、観察データの中で注目する空間・時刻・センサを”注視点”という言葉で表し、手作業のモデルを生成するためにどこに注視点を設定しどのように注視点を解析するべきかを決定する注視戦略に基づいた段階的な作業モデルの生成法を提案する。

本研究では、作業モデル獲得の手順を次の3つの段階に分ける。

### 基本プリミティブに基づく作業の概略の認識

まず、人間の実演教示動作から作業の概略を獲得する。対象とする作業は把持物体と環境物体との動きを伴う相互作用であるため、センサの計測範囲の中からは動きのある個所を大まかに推定しそこを注視点として設定する。次に、基本プリミティブを使用して注視個所で行われる作業の抽象化を行う。基本プリミティブとして、把持の分類・腕の動作の分類・物体の色情報・物体の幾何形状等をあらかじめ設計しておく。

この時、システムへのセンサ入力として種々のセンサが考えられるが、それらは一般に測定範囲や測定対象及び情報の抽象度が異なるため、これらを均一に扱うことは効率的ではない。また逆に、あるセンサの結果を利用して別のセンサの測定範囲や処理対象に拘束をかけることにより、効率のよい解析が可能になる。本研究では、データグローブと視覚装置を利用し、まずデータグローブの情報より時空間上で手の動作が行われている個所を推定し、次にそこを注視点として視覚装置の解析範囲を拘束し、注視点近傍を詳細に観察することで操作物体の情報を獲得する段階的な作業モデルの生成法を提案する。

#### 複数回観察に基づく作業に固有のプリミティブの推定

上述の手法では、動作が行われている個所を推定し、基本プリミティブによって作業のモデルを生成したが、次の2つの問題がある。1つは、推定された動作から真の相互作用を推定することが困難であるという問題である。日常動作においては、注ぐ・かき回すといった直接的な接触を伴わない動作や、同時に多数の物体との接触を伴う動作が数多く存在するため、手の動作の近傍を探索するのみでは、相互作用を行う対象物体を確定することは難しい。2つ目の問題は、推定された動作がその作業を達成するために必須の動作であるか否かを判断することが困難であるという問題である。ある動作が検出されたとき、それが偶発的な動作であるのか、それとも意味を持った動作であるのかを上述の手法から判断することは難しい。

これらは単一の観察に起因する問題であり、本研究では本質的には同一の作業を表す複数の教示動作を観察し、各々に検出された相互作用候補を注視点とし、複数の結果を統合し相互に比較することによって、相互作用を行う物体と必須動作の正否の両方を同時に推定する手法を提案する。また、これによって獲得された動作は、その作業に固有の動作であり、その作業ドメインを構成する固有の動作プリミティブと考えることができる。本研究では、推定された動作プリミティブを、基本プリミティブと把持物体の対象物体座標系における相対軌跡によって表現する手法について述べる。作業モデルはこれらの動作プリミティブの連続形として表現され、動作プリミティブは同時にロボットによる動作の模倣・動作の認識の双方に利用できることを示す。

#### 再観察に基づく失敗回避動作の生成

上述の手法に従って構築された作業モデルに基づき、ロボットは教示作業の模倣を行うことが可能になる。しかし実際に再現する際には、いくつかの要因から模倣に失敗することがある。本研究では、失敗を回避する方法として、ロボットが再現動作を行う際失敗する個所について、(1)人間が明示的に失敗個所を指示し、その部分を再教示することで作業モデルを修正する方法、(2)ロボットが自身の動作を観察することで自動に失敗を回避する方法の2つを提案する。

(1)の方法では、人間が明示的に注視点を指定しその動作の再教示を行う。ここでは、失敗

の要因が観察データの誤差にあるとし、センサのパラメータを変更することで補償する方法を提案する。一般にセンサの測定範囲と精度にはトレードオフの関係があり、作業モデル獲得の段階では教示動作が未知であるため測定範囲を拡大しておく必要がある。しかし、再観察時には教示動作が予測できるため、測定範囲を狭め精度を向上させることで観測データの精度を向上させることが可能である。本研究では、入力センサであるステレオ視覚のズーム比率を2回の教示で変更することで、2回目の教示の際の把持物体の軌跡の推定精度を向上させる。

(2)の方法では、失敗の要因が作業実行時の外乱にあるとし、再現時にロボットが自身の動作を注視することで、作業モデルから予想される動作と実際の動作との差をフィードバックすることにより失敗の回避を行う。作業実行時の外乱としては予期せぬ接触などによって把持が崩れる場合が考えられ、このときまずロボットの腕の3次元幾何モデルを視覚データ中に投影し、腕を同定することでキャリブレーション誤差を推定する。次に把持物体の3次元幾何モデルを、上記の誤差を補正した上で視覚データ中の予想位置に投影し同定を行うことで、把持の崩れの基づく把持物体の移動量を推定する。最後に、この移動量が解消されるように腕を漸近的に駆動することで、握り直すこと無く把持の崩れの補償を行うことが可能になる。

本研究では作業モデルの構築と検証のための実験プラットフォームとして、人間の上半身の形状と機能を模したロボットを開発し、このプラットフォームを使用して上述の手法の検証を行う。

# 目次

概要	i
目次	iv
図目次	viii
表目次	ix
<b>第1章 はじめに</b>	<b>1</b>
1.1 観察に基づく作業の理解と獲得	3
1.1.1 人間の情報処理機能の工学的な実現に基づく動作の理解と獲得	3
1.1.2 特定の作業の習得を目的とした動作の理解と獲得	5
1.2 注視点に基づく手作業モデルの獲得法	9
1.2.1 注視点	9
1.2.2 注視戦略に基づく作業の段階的な獲得	9
1.2.2.1 基本プリミティブに基づく作業の概略の認識	10
1.2.2.2 複数回観察に基づく作業に固有のプリミティブの推定	11
1.2.2.3 再観察に基づく失敗回避動作の生成	12
1.3 本論文の構成	13
<b>第2章 基本プリミティブに基づく作業の概略の認識</b>	<b>15</b>
2.1 基本プリミティブの定義	15
2.1.1 把持プリミティブ	16
2.1.2 動作プリミティブ	18
2.1.2.1 隠れマルコフモデル	19
2.1.2.2 スポッティング認識	20
2.1.2.3 モデルのトポロジー	21
2.1.2.4 動作プリミティブのモデル化例1	22
2.1.2.5 動作プリミティブのモデル化例2	26
2.1.3 物体の幾何形状と色分布による分類	31
2.1.3.1 物体の幾何形状と色分布の構成	31

2.1.3.2	視覚による認識システム	32
2.1.3.3	物体領域の切り出し	33
2.1.3.4	位置と姿勢のロバスト推定法	34
2.1.3.5	環境物体の位置と姿勢の推定	36
2.2	注視点戦略に基づく段階的なセンサ解析	37
2.2.1	データグループの解析	38
2.2.2	ステレオ視覚装置の解析	38
2.2.3	動作再現例	40
2.2.3.1	教示動作の認識	41
2.2.3.2	ロボットによる人間行動の再現	41
<b>第3章</b>	<b>複数回観察に基づく作業に固有のプリミティブの推定</b>	<b>43</b>
3.1	プリミティブと作業モデルの表現	45
3.2	複数観察結果の統合	46
3.2.1	複数観察の必要性	46
3.2.2	複数観察結果の統合方法	46
3.2.3	多次元 DP Matching を用いた必須相互作用の推定	47
3.2.4	DP Matching における評価関数	48
3.2.5	必須相互作用区間の推定実験	50
3.2.5.1	相互作用区間候補推定に関する実験条件	50
3.2.5.2	必須相互作用候補の決定	50
3.2.5.3	必須相互作用区間の推定例	51
3.3	必須相互作用の汎化	54
3.3.1	相対軌跡	54
3.3.2	3次元追跡による軌跡の推定	55
3.3.3	模倣のための相対軌跡の汎化	57
3.3.4	重複する動作プリミティブのクラスタリング	60
3.3.5	認識器の生成	60
<b>第4章</b>	<b>再観察に基づく失敗回避動作の生成</b>	<b>63</b>
4.1	観察データの誤差の補償	63
4.1.1	センサのパラメータの変更に基づく教示動作の再観察	64
4.1.2	再観察の手順	64
4.1.3	再観察の結果	66
4.1.4	評価	68
4.2	作業実行時の外乱の補償	70
4.2.1	把持物体の位置・姿勢誤差の推定	70

---

4.2.2	誤差の補償動作 . . . . .	72
<b>第 5 章</b>	<b>人間型ロボットプラットフォームを用いた実験例</b>	<b>73</b>
5.1	生成された作業モデル . . . . .	73
5.2	人間型実験プラットフォーム . . . . .	74
5.2.1	視覚系 . . . . .	75
5.2.2	アームとハンド . . . . .	77
5.2.3	体幹 . . . . .	78
5.2.4	CORBA に基づくソフトウェアアーキテクチャ . . . . .	79
5.2.5	データグローブ . . . . .	81
5.3	作業の再現：動作プリミティブの獲得 . . . . .	82
5.4	作業の再現：動作プリミティブ例 2 を認識に使用した例 . . . . .	83
5.5	作業の認識 . . . . .	85
<b>第 6 章</b>	<b>結論</b>	<b>86</b>
6.1	寄与 . . . . .	88
6.2	今後の展望 . . . . .	89
	<b>参考文献</b>	<b>90</b>

# 目次

1.1	注視点解析に基づく作業モデル生成の概要	10
1.2	作業の概略の認識	10
1.3	複数回観察に基づく動作プリミティブの推定	11
1.4	再観察に基づく失敗の回避	13
2.1	鎌倉の把持分類における掌の接触分布例	18
2.2	隠れマルコフモデル：状態遷移図	20
2.3	動作プリミティブを表現するための隠れマルコフモデル	21
2.4	HMM ネットワークの文法	23
2.5	手の動作認識のための階層的な HMM 表現	24
2.6	HMM への入力 (Dataglove and Polhemus)	25
2.7	HMM ネットワークの文法	29
2.8	物体プリミティブ例（上段：画像・中段：幾何モデル・下段：色相分布）	32
2.9	教示環境	33
2.10	物体の抽出	33
2.11	統合テンプレートマッチング法に基づく物体の位置と姿勢の同定法	35
2.12	幾何モデルの一致度に基づく物体認識	37
2.13	注視点戦略に基づく段階的なセンサ解析	38
2.14	ステレオ視覚を用いた注視点解析	40
2.15	教示動作の認識と再現	42
3.1	相互作用の不確定性	44
3.2	必須相互作用（プリミティブ）と作業モデル	45
3.3	要素に分割された観察結果	47
3.4	必須相互作用の評価	48
3.5	複数の教示動作	52
3.6	相互作用候補の抽出	53
3.7	多次元 DP matching による統合結果	54
3.8	データグローブからの運動軌跡の推定	55
3.9	把持物体の 3 次元追跡（カラー画像上）	56

---

3.10	把持物体の3次元追跡(距離データ上)	57
3.11	平均軌跡のx軸成分	58
3.12	汎化された軌跡の分散	59
3.13	動作プリミティブの統合	60
3.14	(左)動作プリミティブの軌跡の差の併進成分,(右)動作プリミティブの軌跡の差の回転成分	61
3.15	隠れマルコフモデルによる動作認識	61
3.16	学習に用いたサンプルの隠れマルコフによる対数事後確率の分布	62
4.1	把持物体のカラー画像と3次元幾何モデル	65
4.2	3次元追跡(x1 zoom, 精緻なモデル)	66
4.3	3次元追跡(x2 zoom, 粗いモデル)	66
4.4	3次元追跡(x2 zoom, 精緻なモデル)	67
4.5	視覚系のパン・チルト角速度の局所性	67
4.6	軌跡の並進成分の誤差	68
4.7	軌跡の回転成分の誤差	69
4.8	カメラ座標系における腕の位置・姿勢の推定	70
4.9	把持物体の微調整:1	71
4.10	把持物体の微調整:2	72
4.11	把持物体の微調整:3	72
5.1	実験プラットフォーム	75
5.2	ステレオ装置の測定範囲	76
5.3	視差の測定カーブ	76
5.4	輝度と距離画像(白:近い点,黒:遠い点)	77
5.5	ロボットアームとハンドの設計	78
5.6	ロボットのソフトウェア構造	80
5.7	触覚センサの分布	81
5.8	接触点分布による把持の認識	82
5.9	物体Bへの相互作用(上:教示動作,下:再現動作)	82
5.10	物体Cへの相互作用(上:教示動作,下:再現動作)	83
5.11	教示動作(右手のみ)	84
5.12	ロボットによる再現	84
5.13	新規動作プリミティブを用いた認識と再現	85

# 表目次

2.1	日常動作における把持の分類	17
2.2	注ぐ動作における動作プリミティブ	22
2.3	動作プリミティブの結合による行為の記述	23
2.4	ジェスチャの認識	26
2.5	風炉薄茶点前の動作順序	27
2.6	動作プリミティブ	28
2.7	動作プリミティブの結合による行為の記述	29
2.8	認識結果:(指形状 + 姿勢変化 + 触覚)	30
2.9	認識結果:(指形状 + 姿勢変化 + 触覚 with Garbage)	30
2.10	認識結果:(指形状差分 + 姿勢変化 + 触覚)	31
2.11	認識結果:(指形状 + 姿勢変化 + 触覚 with Garbage)	31
2.12	検出された形状差	36
2.13	データグローブのデータより検出された作業の情報	39
3.1	把持物体と環境物体との相対関係 ( 教示動作 1 )	53
3.2	把持物体と環境物体との相対関係 ( 教示動作 4 )	54
4.1	再観察の手順	66
4.2	ズーム比率 x1 の時の誤差	69
4.3	ズーム比率 x2 の時の誤差	69
5.1	相互作用を表す属性	73
5.2	ハードウェア制御のためのソフトウェアモジュール (CS)	79
5.3	データグローブの仕様	81

# 第1章 はじめに

従来ロボットは、主に製造ラインなどの産業用途で限定的に使用されてきたが、近年になり博物館や病院などの施設及び家庭といった人が日常生活をおくる場所において、人を直接補助することを目的としたロボットが相次いで研究・開発されてきている [1, 2, 3, 4, 5, 6, 7, 8, 9, 10]。これらのロボットは、人の形状を模したもの [1, 2, 6, 8, 10]、車いすなどの日常使われる道具を智能化したもの [3]、部屋など周囲の空間自体をロボット化したもの [4, 9]、エンターテインメントを指向したもの [7] など形状も目指すものも様々であるが、日常空間において人と接し何らかの支援を行う能力を備えているという点では一致している。

こういったロボットのうち人間型ロボットについては、これまで日常空間における移動手段を確保する目的で2足歩行の実現に関する研究が精力的に行われ一定の成果を収めてきた [6]。これが一段落した現在、研究の主眼はロボットによる作業の代行や協調作業によるより知的な人間支援の実現 [10] に移行しつつあるが、現在主に研究されているのは操縦型のロボットによる作業の代行 [10] や物体の協調搬送 [11] といった人の動作に単純に追従する形の支援の実現法である。

しかし、人を真の意味で支援するためにはロボットが能動的に活動する必要があり、そのための動作計画をたてるためには対象とする作業を理解し何らかの内部表現（作業モデル）に変換して獲得する能力が必須となる。

従来の産業用ロボットに対する作業モデルの獲得方法として、Teaching Pendant 等の教示装置もしくはロボットアームを直接教示者が動かす Teach by guiding によりロボットアームの軌跡を直接教示する方法、もしくは仮想環境やロボットプログラミング言語によってセンサフィードバックを含めた系を構築する方法が一般的にとられてきた [12]。これは、産業用ロボットに要求される動作はコントロール可能な環境中での繰り返し動作であることがほとんどであり、一旦作業環境が決定されるとロボットの動作も一意に決定されることから、ロボットアームの決まった軌道を実行モデルとして獲得すれば十分であるという特徴があるからである。

しかし日常空間におけるロボットの利用方法は一般にユーザの目的に依存するため、必要に応じてユーザがロボットの動作を簡単に拡張し得る枠組みが必要となる。さらに、ユーザは一般にロボットの専門家ではないため、前述のような産業用ロボット向けの煩雑な教示方法はふさわしくない。その代わりとなる自然な方法として、人が行う作業の実演教示を観察によってロボットが理解・習得し、作業のモデル化を行うとともに作業の実行系・認識系を適応的に獲得することができれば、人が見まねによって動作を獲得していく過程との類似性が

ら理想的な方法であるといえる。

ここで人の動作獲得過程の最も初期にあたる幼児の動作獲得に注目すると、初期には親の表情やしぐさを視覚によって観察し直接的な模倣を行うことにより動作指令と動作結果との関連を学習し基本的な動作を獲得しているといわれている [13]。この初期の知覚に関して、対象の特定の特徴に先天的に反応するニューロン [14] や、特定の意味を持った動作に反応するニューロン [15] といった、対象を抽象化つまりプリミティブに分解し作業モデルを生成するための認識器の存在が知られている。

さらに成長するにつれ、視覚に加えて言語や触覚等を加えたマルチモーダルな感覚・運動系を構築しより複雑な動作パターンを動作プリミティブとして自動的に獲得するとともに、一連の作業の中での動作パターンの位置づけを動作の意味として構造化していくと考えられる。このあたりの仕組みについては未解明な部分が多いが、あらかじめ想定することの困難な環境において動作を適応的に獲得することが要求されるロボットに対しても同様にボトムアップ的なアプローチを採ることは妥当である。

そこで本研究では、この動作獲得過程の初期の部分を実学的に実現することによって実演教示の観察に基づき人間型ロボットが作業を獲得する枠組みの基盤を確立することを目的とし、それを実現するための手法として以下の5つの方法を提案する。

- あらかじめ設計された普遍性のある基本プリミティブによって観察から動作の概略を認識する方法
- 複数の観察結果を統合することによりその作業に本質的な動作を推定し作業に固有の動作プリミティブとして獲得する方法
- 記号化された基本プリミティブおよび動作プリミティブによって作業のモデルを構築する方法
- 動作プリミティブを動作の再現と動作の認識の双方に使用可能な形でモデル化する方法
- 明示的な指示もしくは自律的な再観察にもとづき動作の失敗を回避する方法

このとき、作業を観察する際に観察すべき個所を示す注視点の概念を提唱し、どこに注視点を設定しどのように注視点を解析するべきかを決定する注視戦略にもとづき段階的に作業モデルを獲得する方法を提案する。また、人間型ロボットプラットフォームを開発し、日常生活における視覚と手と物体との密接な相互作用を伴う手作業を対象作業として観察に基づく作業の獲得・認識・再現実験を行うことによって提案手法の実証を行う。

本章では、従来の観察に基づく動作獲得方法に関する研究について概説し、それらの手法の問題点とその問題点に対処するための本研究の取り組みについて述べる。次に提案する注視点解析に基づく作業の解析・動作獲得方法について述べ、具体的に記述可能な作業の範囲と生成される作業モデルについて説明する。

## 1.1 観察に基づく作業の理解と獲得

作業の実演教示を観察することによりロボットがその作業を習得していく枠組みは、初心者もしくは子供が作業に熟練した人間もしくは大人のお手本動作を見ることで作業を覚えていく過程との類似性から、ロボットの専門家ではない一般人がロボットに対して動作を教示する手段として適していると考えられる。

そのためには、観察によって作業を習得していく過程を知覚・運動系を含めてモデル化し、アルゴリズムとして計算機上を実現することが必要となる。この時、必ずしも人間の習得過程をモデル化する必要はないが、過去の AI 研究での学習成果を現実世界に適用しよう試みて失敗してきた経緯から、このような身体的な動作を獲得するためには、計算機上の計算モデルのみではなく、知覚・運動を担い外界との相互作用を行う身体を含めた系を考えることが本質的に必要であるとの認識が示されている [16]。これは、一般的な知能の獲得研究に関しても言えることであり、知覚・計算・運動を同時並行的に扱い知能モデルの構築・検証を行うためのツールとして、身体性を持つロボットを用いることの重要性が指摘されている。

ここで、ロボットを用いて教示動作の観察にもとづき動作の理解と獲得を試みる研究例を概観すると、大きく分けて (1) 人間の情報処理機能の工学的な実現に基づきボトムアップ的に動作の理解と獲得を試みるアプローチと、(2) 特定の作業の習得を目的としてトップダウン的に動作の理解と獲得を試みるアプローチの 2 つに分類される。

### 1.1.1 人間の情報処理機能の工学的な実現に基づき動作の理解と獲得

一つは人間の脳機能を理解するという目的の下で、脳の神経生理の知見に基づき計算機上に脳もしくは認知のモデルを構築し、そのモデルを検証する意味でロボットを用い人間の脳機能の仕組みを探るアプローチである [17, 18, 19]。

猫やサルに対する電気生理学実験の結果から、哺乳類の脳の後頭葉にある視覚野は形・色・動き・奥行きなどの異なる視覚刺激に反応する部位に分けられることが報告されている [14]。人間の脳についても、近年の人の脳の非侵襲計測で同様のことが報告されており、認知の過程でこの多数の知覚モジュール間の組み合わせ爆発を解決するバインディング問題の解明が研究対象となっている [20]。この知見は、人間が対象を抽象表現するための要素知識（基本プリミティブ）を先天的に持っていることを示している。

一方行動の獲得に関しては、成人の舌を出す動作や様々な表情を新生児が「模倣」する現象が報告されている。Meltzoff と Moore は、新生児に対する模倣実験から生後数日の幼児は視覚情報と固有の感覚情報の両者を生得的に共通の形式で表現しているとの仮説を立てている。これによって視覚の情報と自身の運動に起因する感覚情報を直接比較することができるため、原始模倣はその比較と照合の過程ではないかと主張している [13]。

この生得的な原始模倣の可能性を生理学的に説明する知見として、サルの脳で発見されたミラーニューロン (mirror neuron) の存在が挙げられる。サルの脳の運動前野には、コップをつ

かむといった自身の意味を持った特定の動作に反応して活動し、運動パターンを識別していると思われるニューロンが数多く存在するが、この中の一部のニューロンは人間の実験者が行う同じコップをつかむ動作をサルが見た場合にも同様に活動することが報告されている [15]。運動前野は、感覚からの刺激に対応した適切な運動指令を見つける場所であり、通常は2次元パターン・色・3次元形状などの入力に反応するが、ミラーニューロンと呼ばれるこの種のニューロンは他者の意味を持った特定の行為にも反応しており、霊長類における見まねの基礎と考えることができる [18]。このコップをつかむ例では、特定の把持形態や対象物に選択的に反応するため、反応を起こす仕組み自体は先天的に備えているが、反応自体は後天的に学習されたと考えられる。この知見は、人間は手と対象物との相互作用を動作プリミティブとして新規に獲得し既存の知識体系の中に構造化する仕組みを持っており、さらにこの動作プリミティブは動作の生成に利用されるだけでなく、動作の認識にも用いられることを示している。

これらの知見をもとに、生得的に備わっていると考えられる上記のいわば認知のための要素機能（基本プリミティブ）を工学的にモデル化し検証することで、脳機能の解明を図る研究が行われている。

Mataric らは、ミラーニューロンが知覚から運動へのマッピングを行う絶対位置や動きの速さに依存しない普遍的な運動プリミティブ (sensory-motor primitive) であると捉え [19]、正規化された速度ベクトル列によって有限個の運動プリミティブを設計し、エアロビクス・ダンス・アスレチック等の任意の全身運動における腕の動きを運動プリミティブ列に分解することで動作モデルを獲得し、またその動作モデルから同じ運動を再構成する手法を提案した [21]。また運動プリミティブ自体を自動的に獲得する方法として、速度の変化を指標に観察した動作をセグメントに分割し、各セグメントを時間軸方向に正規化された速度ベクトル列に変換し、主成分分析を行い次元を落とした空間でクラスタリングを行う手法を提案した [22]。しかし、この手法の適用対象は全身運動の獲得と再構成に限定されており、ミラーニューロンの本来の特徴である物体との相互作用は扱っていない。また、k means クラスタリングを用いており、あらかじめ運動プリミティブの種類数を人間がアドホックに決定している。本研究では、物体との相互作用を伴う作業を対象とし、上述の知見をもとに種類数が未知の新規の動作プリミティブを獲得し、あらかじめ備えている基本プリミティブと新規に獲得される動作プリミティブによって作業モデルを構成する手法を提案する。

また稲邑らは、認知心理学の研究領域で提案されているコミュニケーション信号を随意的に生成し認知するための情報処理能力であるミメシスという概念に着目し、動作パターンの表出と記号化を全結合型の隠れマルコフモデル [23] を用いて同時に表現する手法を提案して、観察に基づきヒューマノイドの種々の歩行パターンを獲得する手段に利用している [24]。この隠れマルコフモデルはその特定の動作を表すシンボルと見なすことができ、またこのモデルから尤度を最大にする出力列を計算することでヒューマノイドの歩行を再構築することが可能である。隠れマルコフモデルは時空間上を確率的に変動する信号パターンを少ない状態量で表現することができ、本研究においても動作のモデル化に利用する。

川人と宮本らは、けん玉やテニスサーブといった腕の動的な動きを必要とする動作を獲得

するために、観察によって動作軌跡の最適な経由点を推定し [25, 26]，経由点間をスムーズに遷移する腕の軌跡を順と逆のモデルを用いた順逆緩和計算による双方向神経モデル [17] を用いて高速に計算する方法を提案した。順逆緩和計算は、小脳で計算されているとされる腕の運動軌道生成の計算モデルを参考に提案された多関節腕の運動指令を決定する計算アルゴリズムであり、この実験結果は人間の動作の計測結果とよく一致する。本研究では動力学的な条件を考慮せず、把持物体の動作軌跡を表現するために軌跡を一定間隔で静的に補間する方法をとるが、例えばハンマーを扱うような動力学を必要とする動的な動作に提案手法を適用するときには、上記の手法を用いて経由点の間隔を最適化し動力学的な整合性を保つように動作指令を生成することによって動作を実現することができる。

また、前記の動作プリミティブの模倣にもとづく獲得とも関連するが、従来一般的であったように設計者の構築した身体運動や物体操作の物理としての理解の体系を明示的にロボットに埋め込むのではなく、外界との相互作用の中から外界に対する理解を創発的に獲得するメカニズムの実現を目指す「認知ロボティクス」という新たな枠組みが提唱されている [27, 28]。外界との相互作用から多様な行動の創発を目指すアプローチとして Brooks らによる先行研究があるが [29]，この方法論はあらかじめ設計してある粒度の異なる動作モジュールの競合解決の問題に置き換えられるため、多足歩行やナビゲーションなど単純な行動はロバストかつ高速に実現されたが、遥かに複雑な行動の実現や状況の変化に応じて新規の行動を獲得する能力には結びつかなかった [28]。「認知ロボティクス」は、認知科学・発達心理学・神経科学などより得られる知見から、人間と外界との相互作用をロボットと外界との相互作用に置き換え人間の理解の枠組みを探っていくアプローチであるが、新しい枠組みであり現状は方法論自体を模索している段階である。

これらの研究例は比較的新しい研究分野に属し、基本的には脳の処理系の末端の要素機能に着目してその機能を同定することから全体を推し量ろうとするボトムアップ的な取り組みがなされているが、要素機能を組み合わせたときの総体としての挙動の解明にまでは踏み込んでいないのが現状である。そのため、比較的単純な全身運動の獲得・生成が実現されているのみで、対象物体との相互作用を含む知的な相互作用の解明を目指す場合、これらの要素機能をどのように組織化しどのようにして技と呼ばれるまでの高度な知覚・運動系を獲得できるのかに関しては全く手つかずの状態である。

### 1.1.2 特定の作業の習得を目的とした動作の理解と獲得

もう一つのアプローチは、ロボットがある目標とする作業を再現できることが最終的な目的であり、それを実現するための簡便な教示方法の一つとして観察に基づく人間動作の理解を試みるアプローチである。このアプローチに属する研究では、環境物体との相互作用を伴う高次の知的な作業を直接扱っており、一般的には扱う作業領域を限定し、操作対象物の位置と抗力の軌跡を直接モデル化するか、もしくはその領域で発生し得る相互作用（プリミティブ）を事前に全て設計することにより有限種類の相互作用の連続形として教示動作のモデル

化を行う。

ロボットが教示動作を獲得する場合、最も簡単なのは人間が把持する操作物体の3次元空間での軌跡と物体に生じる力（抗力）をそのままロボットアームに取りつけた操作物体で再現することである。古くは、研削作業を例に教示者の操作する研削機器の水平方向の軌跡と垂直方向の力の変化を記録し、ハイブリッド制御によってロボットアームによる同一動作の実現を可能にした浅田と浅利の研究があり [30]、最近では、Ude らによって教示者の手の軌道を視覚により観察しスプライン曲線にフィッティングすることで観測誤差による振動を除きかつ滑らかな軌跡をモデル化する手法 [31] が、また Delson と West によって人間の教示する複数の動作軌跡について動作間の軌跡の違いを許容誤差と考えて一つに統合する手法 [32] が提案されている。しかし観測結果から得られる軌跡をそのままモデル化する方法は、全く同一の環境下での繰り返し動作には適しているものの異なる環境への適用性がなく、特に本研究で対象とする日常動作においては、把持物体の軌跡を全般にわたってモデル化することは作業の再現性を考慮すると意味のない情報となる。しかしながら、把持物体と環境物体とが相互作用を行っている区間の相対軌跡は動作の模倣と認識の観点から重要な情報であり、かつ異なる環境下においても再利用できるため、本研究では相互作用区間の相対軌跡を抽出してモデル化する方法を提案する。このとき、対応する複数の相対軌跡（後述）を統合するために Delson と West の手法 [32] を用い、教示動作毎の軌跡のずれを相互作用の許容誤差としてモデル化する。

Atokeson らは、振り子を振り上げ平衡状態を保つ倒立動作において、動作のパラメトリックなモデル及びノンパラメトリックなモデルを設定し、1回の観察結果と数回の試行から必要なパラメータを学習する手法を提案した [33]。この手法は、振り子の物理量などが若干変化した場合にも、元々の学習済パラメータを初期解としてさらに数度の試行を繰り返すことによってパラメータの再推定を行うことができるため、同じ物理モデルで記述できる動作に対しては、実行環境の変化を吸収するようにモデルパラメータが修正されることで実行環境への馴化が実現されている。同様に川村らは、動力学的整合性を保ちながら時間軸方向への馴化を実現する手法を提案している [34]。しかしこれらの手法は、あらかじめ運動の物理モデルの見当がついている場合には有効であるが、一般にパラメトリックの場合には物理モデルを自動推定することは非常に困難であり、ノンパラメトリックの場合には単純な動作にしか適用できないとの欠点がある。また手作業に関していえば、日常動作を簡単な物理モデルで記述できる可能性を示唆する報告 [35] はあるものの、一般的な作業を記述するための物理モデルの構成法については全く分かっていない。

一方、対象とする作業ドメインで起り得る局面を網羅した有限個の作業状態 (State) を人間が設計し、教示者の動作がどのような状態遷移を経て終了状態に至ったのかを視覚等によって解析することで作業モデルを獲得する研究が多く行われている。ロボットが作業を再現するときには、同じ状態変化を引き起こすロボット動作をモデルに沿って連続的に生成すればよい。

國吉らは、Pick & Place 動作における指先と環境物体との位置関係を有限数定義し、指先と物体の双方を視覚により常時観察することにより状態遷移を検出しロボットによる Pick &

Place 動作を実現した [36]。Morrow と Khosla は、特定の組立作業を有限状態オートマトンで表現し、センサフィードバックを含む状態間の遷移動作を動作プリミティブ (sensori-motor primitive) として有限個定義して、この連続形によって作業を記述した [37]。しかし、これらの方法では定義された位置関係やオートマトンが作業に依存するため、対象とする作業が変わると作業状態を設計し直す必要があるという欠点がある。

末広と高瀬は、作業過程における面と点との接触状態の遷移に着目して、ある接触状態から別の接触状態への状態変化を実現する動作を基本単位とするスキルを提案した。各スキルは必要に応じて力制御やセンサフィードバックを伴うサーボレベルでの制御を内包しており、これにより作業を記号による抽象表現で記述するとともに、精密な動作の要求される作業の実行を可能にした。また状態変化毎に作業座標系を適切に設定することで状態の変化を起こす動作が二次元3自由度の動作として表現されることから、本来三次元6自由度作業を一般性を損なうことなく2次元での動作に投影することで、起こり得る接触状態変化の種類を少なくする工夫をしている [38]。

池内らは、作業に関する知識をもとに高速かつロバストな視覚システムを構築するタスク指向視覚 [39] と呼ばれる枠組みを提案した。この一環として、任意の凸物体同士の面と面との接触状態の変化が有限の状態数で記述できることを利用し、視覚のみから面接触状態遷移列を獲得し同じ状態遷移をロボットハンドによって再現することにより組立作業を獲得する枠組み Assembly Plan from Observation (APO) を提案した [40]。各状態遷移には対応するロボット動作である Sub skill が存在し、各 Sub skill は状態遷移の種類に応じて触覚フィードバック制御もしくは視覚フィードバック制御を内包する。

津田らは、ある接触状態を有限の局所接触状態の組合わせによってモデル化し、このモデルの連続形である接触状態遷移を実演教示の観察によって獲得する手法を提案した。さらに、ロボットアームを用いた作業の再現実験により手法の有用性を検証すると共に、末広と高瀬の手法と比較して3次元6自由度の組立作業を解析する際の有用性を考察している [41, 42]。

これらの方法は、凸物体同士の接触を伴う任意の組立作業を記述可能であるという点においてプリミティブの普遍性が高い。しかし、作業の解析方法が接触状態を検出することに依存しているため、注ぐやかき回すといった直接的な接触を伴わない日常動作の解析にはそのままでは適用できない。

また他に、玩具の組み立て作業を対象に動作の実行条件と実行結果の依存関係をモデル化し人間とロボットの協調行動を実現した例 [43] や、Air Hockey 競技の局面の状態を分類しロボットによる競技の認識と動作の熟練を行った例 [44]、組立作業の動作モデルに隠れマルコフモデルを用いた例 [45, 46] などがある。

これらの研究のうち視覚センサ等を用いて受動的に作業の観察を行う例では、観察時のセンサの使用戦略がロボットの行う作業の内容に強く依存するため、使用戦略の開発には多くの労力を必要とする。三浦は、効率的なセンサ使用戦略を自動的に生成するためには作業の実行に必要な十分な情報を得るための戦略を規定すればよいと主張した。さらに、面接触状態の遷移で記述可能な組立作業を例にとり、実演教示の観察によって得られる局所的な成功確率

の分布と視覚の不確かさ分布との重複比率から，作業成功のための最適なセンサ使用戦略を自動獲得する手法を提案した [47]．

以上に述べたのは，物体同士の相互作用をモデル化する手法であり，大きく分けて軌跡の情報を取り扱う方法とプリミティブによって作業を記述する方法の2通りに分類されるが，この両方を組み合わせた例はあまりない．これは，軌跡を扱う研究は単一の動作（相互作用）自体のモデル化を想定しており，一方プリミティブによる記述は連続する相互作用の遷移を記述することに重点をおいているからである．また後者の場合に動作の再現を行う時には，環境の差異を吸収するために接触点とその方向をモデル化し実行時に直線運動と触覚フィードバックによって動作を実現する例が多く，軌跡の情報を直接しない場合が多い．

しかし，直接的な接触を伴わない日常動作においてはこのような明確なフィードバック制御をあらかじめ設定することは手間がかかり，また作業に固有のプリミティブを自動的に獲得する場合にそのプリミティブの動作制御則をも自動的に獲得することはさらに困難である．そのため，本研究では作業全体を記号化されたプリミティブを用いて記述し，各相互作用は単一の動作と見なせるため把持物体の対象物体座標系における相対軌跡によって表現する方法をとる．

また，記号化された状態遷移を扱う研究例ではいずれの方法も単一の観察結果の解析に基づき作業モデルを生成しているという問題点がある．単一観察の場合，事前の知識無しに作業に必須の動作を確定することは困難であり，そのため接触状態遷移のように微視的には厳密に状態遷移を抽出できる場合でも，検出された遷移のうちのどれが作業にとって本質的に必要な遷移であるのかを確定できないため冗長な作業表現になる．接触を伴う単純な作業に関しては，例えば初期状態から終了状態までの接触状態遷移図上での最適パスを計算することで不必要な遷移を取り除くことが可能だが [40]，これは遷移の経過は結果に影響しないとの前提でのみ可能であり，また直接的な接触を伴わない場合には適用できない．そのため本研究では，本質的には同一の作業を表す複数の実演教示の観察結果を統合し，全てに共通する相互作用を抽出することで必須の相互作用を推定する手法を提案する．

以上に紹介した研究は，主に物体同士の接触状態遷移を再現するためのモデル化を行っているため，把持物体は一般にロボットアームに固定されている．しかし人間型ロボットが作業を再現するときには必ず物体を把握する把持動作を伴うため，この実現のためには日常における不定形な物体を把持する戦略を事前に獲得する必要がある．そのためには人間の把持の形態をお手本にロボットの把持の形態を決定することが効率的である．指の複雑な動きを伴う操りを考慮しない場合，ロボットハンドと人間の手指とで機構が異なる場合には何らかのマッピングを行い，把持の最終形態 [48, 49, 50, 51] とそこに至るまでの把持戦略を作業モデル中に記述する必要がある．

把持形態は把持物体の形状・機能や操りの性質によって異なるが，把持期間中にハンドと把持物体との相対関係が変化しない，つまり指による操りが無視できると仮定できる場合には，一般に把持の形態を有限数に分類分けしこれを把持プリミティブとして設計し，観察した把持形態と最も類似度の高い把持プリミティブによって作業モデルを記述する研究例が多い．

古くは、Napier の圧力把握と精密把握の分類 [48] があり、組立作業を対象に Napier の分類を細分化した Cutkosky の分類 [49] が古典的な分類として有名である。最近では Kang の組立作業における把持形態の認識に関する研究 [50] があり、この研究では掌と把持物体との接触状態を Contact web の表現形式で抽象化し、把持の形態を指先の接触圧ベクトルの分散に基づき Virtual Finger[51] の表現形式で抽象化することによって、人間の把持を機構の異なる任意のロボットハンドにマッピングする手法を提案した。

しかし、これらの把持分類は機械加工等の組立作業に即した分類分けがなされており、具体的な認識のために指先と掌の接触にのみ着目しているが、例えば指の腹を積極的に使う把持が考慮されないなどより多様な日常動作に現れる把持を分類するためにはそぐわない面がある。日常動作に現れる把持を分類分けした例として、作業療法士の立場から把持を 14 種類に分類した鎌倉の分類例がある [52]。本研究では、把持の分類規範として鎌倉の分類を使用し、この 14 種類を把持プリミティブとして設定し把持の認識を行う。

また、我々は作業モデルを生成する過程を 2 つに分けて研究を進めている。一つは、作業レベル、つまり「何をやるのか (what to do)」のレベルでのモデル化であり、もう一つはスキルレベル、つまり「どうやるのか (How to do)」レベルでのモデル化である。本論文では、前者にあたる教示動作の実演から動作の概略を獲得し模倣するための手法を提案する。後者のスキルレベルについては本研究では扱わないが、[53, 54] で述べている。

## 1.2 注視点に基づく手作業モデルの獲得法

### 1.2.1 注視点

本研究は、事前の知識は普遍性のある最小限のプリミティブ集合に限定してそれをもとに作業の概略を抽象化し、次にその情報からでは一意に解釈できない作業については繰り返し観察を行い情報量を増やすことによってあいまい性を解消するとともに、作業に固有のプリミティブを自動的に獲得することで認識システム自体が対象とする作業ドメインに適応していく点が特徴である。

このときセンサ入力を一様に解析することは非効率的であり、少ない情報から段階的に作業モデルを構築するために、教示動作・もしくはロボットの再現動作のどの個所に着目して解析を行うべきかを段階的に変更する戦略が必要となる。本研究では、観察データの中で注目する空間・時刻・センサを”注視点”という言葉で表し、手作業のモデルを生成するためにどこに注視点を設定しどのように注視点解析するべきかを決定する注視戦略に基づいた段階的な作業モデルの生成法を提案する。

### 1.2.2 注視戦略に基づく作業の段階的な獲得

本研究では、図 1.1 に示すように、次の 3 つの段階に分けて作業モデルの獲得を行う。

図 1.1: 注視点解析に基づく作業モデル生成の概要

1.2.2.1 基本プリミティブに基づく作業の概略の認識

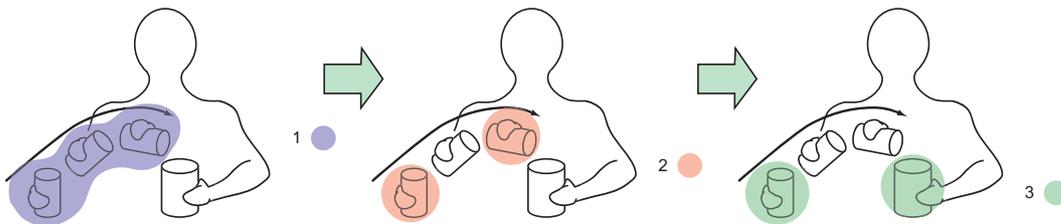


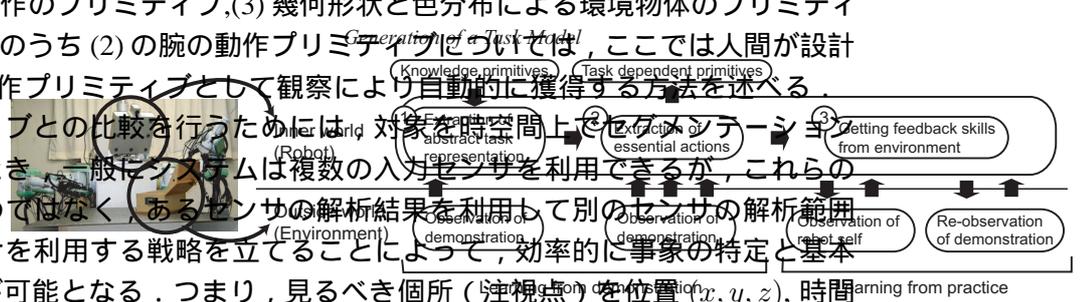
図 1.2: 作業の概略の認識

まず，図 1.1 の 1 番に示すように，人間の実演教示動作から作業の概略 (Abstract task representation) を獲得する．この時，あらかじめ埋め込んである要素知識である基本プリミティブ (Knowledge primitives) と観察によって得られた事象とを比較し，各事象がどの基本プリミティブの組み合わせで表現できるのかを解析する．

普遍性のある基本プリミティブとして，(1) 掌の圧力分布に基づく把持のプリミティブ，(2) 作業によく現れる腕の動作のプリミティブ，(3) 幾何形状と色分布による環境物体のプリミティブの 3 種類を用いる．このうち (2) の腕の動作プリミティブについては，ここでは人間が設計しているが，3 章では動作プリミティブとして観察により自動的に獲得する方法を述べる．

ここで基本プリミティブとの比較を行うためには，対象を時空間上でセグメンテーション (Segmentation) する必要がある．このとき，一般にシステムは複数の入力センサを利用できるが，これらのセンサ群を同列に扱うのではなく，あるセンサの解析結果を利用して別のセンサの解析範囲を拘束し段階的にセンサを利用する戦略を立てることによって，効率的に事象の特定と基本プリミティブとの比較が可能となる．つまり，見るべき箇所 (注視点) を位置  $(x, y, z)$ ，時間  $t$ ，センサ  $sensor_i$  の 5 次元空間の中でどのような遷移させたらよいのかが問題となる．

この戦略は入力センサに依存するため定式化することは困難であるが，解析対象の見当が



ついているセンサを先に用い、その結果を利用して残りのセンサの解析範囲に拘束をかけることによって、段階的に注視対象を限定していく。本研究では動きを伴った把持物体と環境物体との相互作用を認識の対象とするため、(1) 把持を行う手の把持形態、(2) 把持物体、(3) 相互作用の対象となる物体の3つの情報の時系列での遷移が作業の概略を知るうえで必要になる。そのため本研究では、手の位置・姿勢・指の形状及び掌の圧力分布が計測可能なデータグローブと、空間の3次元距離データと色画像を計測可能なステレオ視覚装置をセンサとして使用し、次の手順で作業の概略の認識を行う。

図1.2は、人が右手で把持した容器の中身を左手で把持した容器の中に注ぐ動作を示している。初期の段階では解析対象を絞る情報がないため、図1.2の1に示すようにデータグローブの情報を用いて手の動きのある領域を注視対象とする。次に、データグローブの位置・姿勢・圧力分布等のデータを把持プリミティブおよび動作プリミティブを用いて解析することにより、図1.2の2に示すように有意な動作を検出することができる。次にこの動作が行われた場所及びその近辺を解析することによって、図1.2の3に示すように把持物体及び相互作用の対象となる物体を認識することができる。物体の認識は、ステレオ視覚装置の距離データ及び色画像を物体プリミティブによって解析することで行われる。

この結果より、基本プリミティブの組み合わせによって記述された作業の概略、つまり作業モデルが生成される。

#### 1.2.2.2 複数回観察に基づく作業に固有のプリミティブの推定

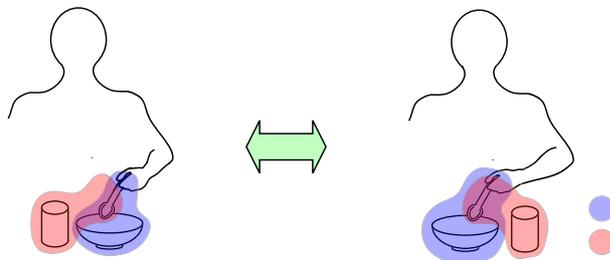


図 1.3: 複数回観察に基づく動作プリミティブの推定

前節の手法では、注視点を段階的に移動することによって相互作用が行われている個所を推定し基本プリミティブとの比較によって作業のモデルを生成したが、次の2つの問題点がある。

1つは、推定された動作から真の相互作用を推定することが困難であるという問題である。日常動作においては、注ぐ・かき回すといった直接的な接触を伴わない動作や、同時に多数の物体との偶発的な接触を伴う動作が多く存在するため、対象物体を認識するときには手の動作の近傍を漠然と探索する方法や接触が生じる方向にある物体を対象と判断する方法では、複

数もしくは不適切な候補がある中から真の相互作用の対象物体を確定することは困難である。

2つ目は、推定された動作がその作業を達成するために必須の動作であるか否かを判断することが困難であるという問題である。ある相互作用が基本プリミティブに照らし合わせて検出されたとき、それが偶発基本プリミティブと一致したのか、それとも意味を持ち作業を遂行する上で必須の相互作用であるから一致したのかを前節の手法から判断することは困難である。

これらは単一の観察結果を解析することに起因する問題であり、本研究では図 1.1 の 2 に示すように本質的には同一の作業を表す複数の教示動作を観察し、各々に検出された相互作用候補を注視個所とし、複数の観察結果を統合し相互に比較することによって、相互作用を行う対象物体と必須相互作用の正否の双方を同時に推定する手法を提案する。例えば、図 1.3 の例は手で把持しているスプーンでお椀の中身をすくう動作であるが、すくう動作は直接的な接触を伴わないため、すくう動作に関して事前の知識がない場合にはスプーンとお椀が相互作用をしているのか、もしくはスプーンととなりのコップが相互作用をしているのかを確定することは困難である。そこで、図 1.3 の左右に示すように、例えば教示動作によって物体の配置を変えてみる。すると、把持物体と対象物体の総体的な関係は変化しないため、図の 2 つの相互作用候補のうちどちらが真の相互作用であるのかを推定することが可能になる。つまり、教示動作の空間軸方向に変動を与えることで 1 つ目の問題点を解決することが可能になる。

また、教示動作中に必須ではないノイズのような相互作用を挟み時間軸方向に変動を与えることによって 2 つ目の問題点を解決することが可能になる。この場合は、必須ではない相互作用は各教示動作で出現の仕方が異なるものの、必須相互作用については全ての教示動作で同じ形態・順序で現れることが期待できるので、全ての教示動作に共通する相互作用を検出しそれを必須の相互作用として獲得する方法である。

これにより、相互作用を行っている把持物体と対象物体を特定することができ、把持物体の 3 次元追跡を行うことによって対象物体座標系における把持物体の相対軌跡を求めることができる。この相対軌跡と把持物体・対象物体を組み合わせた情報は、この作業ドメインに固有の動作プリミティブと考えることができる。これは、前節で基本プリミティブの 1 つとして設定した動作プリミティブと置換できるものであり、前節では手動で動作プリミティブを設計したためその妥当性に疑問があったが、本節の方法ではより作業に本質的な動作を実演教示から自動的に獲得することができるため妥当なプリミティブであるといえる。この動作プリミティブは、これ自体が作業モデルを構成するための記号としての役割を持ち、同時にロボットが作業を模倣する際に動作軌跡を生成するモデルとしても、また人間の動作を認識するための認識器としても用いることが可能である。

### 1.2.2.3 再観察に基づく失敗回避動作の生成

上述の手法に従って構築された作業モデルに基づき、ロボットは教示作業の模倣を行うことが可能になる。しかし実際に再現する際には、いくつかの要因から模倣に失敗することがある。本研究では失敗を回避する方法として、ロボットが再現動作を行う際失敗する個所に

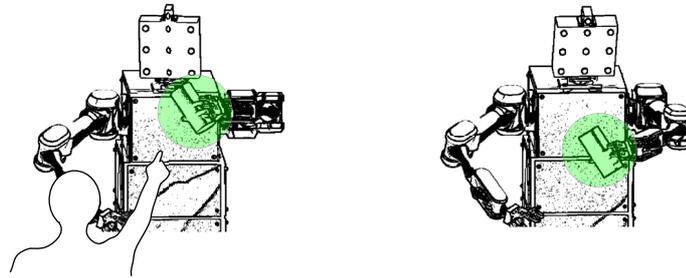


図 1.4: 再観察に基づく失敗の回避

ついて図 1.1 の 3 に示すように、(1) 人間が明示的に失敗箇所を指示し、その部分を再教示することで作業モデルを修正する方法 (図 1.4 左)、(2) ロボットが自身の動作を観察することで自動的に失敗を回避する方法 (図 1.4 右) の 2 つを提案する。

(1) の方法では、人間が明示的に注視箇所を指定しその動作の再教示を行う。ここでは、失敗の要因が観察データの誤差にあるとし、センサのパラメータを変更することで補償する方法を提案する。一般にセンサの測定範囲と精度にはトレードオフの関係があり、作業モデル獲得の段階では教示動作が未知であるため測定範囲を拡大しておく必要がある。しかし、再観察時には教示動作が予測できるため、測定範囲を狭めセンサの精度を向上させることで観測データの質を向上させることが可能である。本研究では、入力センサであるステレオ視覚のズーム比率を変更することで、再観察時の把持物体の軌跡の推定精度を向上させる。

(2) の方法では、失敗の要因が作業実行時の外乱にあるとし、作業再現時にロボットが自身の動作を注視することによって作業モデルから予想される動作と実際の動作との差を検出し、その差を動作指令にフィードバックすることにより失敗の回避を行う。外乱としては予期せぬ接触などによって把持が崩れることが考えられ、具体的には次の手順で補償を行う。まず、ロボットの腕の 3 次元幾何モデルを視覚データ中に予想位置に投影し、視覚中で腕を同定することによりキャリブレーション誤差を推定する。次に把持物体の 3 次元幾何モデルを、上記の誤差を補正した上で視覚データ中の予想位置に投影し同定を行うことにより、把持の崩れのもとづく把持物体の姿勢の変化量を推定する。最後に、この変化量が解消されるようにロボットハンドの位置・姿勢に負のフィードバックをかけることによって、握り直すこと無く把持の崩れの補償を行うことが可能になる。

### 1.3 本論文の構成

2 章では、本研究で用いる基本プリミティブの定義と表現方法について説明し、注視戦略により複数のセンサの依存関係を効率よく利用して段階的に解析範囲を拘束し、基本プリミティブとの比較にもとづいた解析を行うことで作業の概略である作業モデルを生成する手法につ

いて述べる．

3章では，1回の実演教示の観察結果に基づく解析には本質的なあいまい性があることを論じ，本質的には同じ作業を表す複数の教示動作を観察し，作業に必須の相互作用が複数の観察データ間で普遍性を持つことからこれらを相互比較することによって作業に必須の相互作用を推定する手法について述べる．

また，推定された必須相互作用が作業ドメインに固有の妥当な動作プリミティブであることを論じ，作業モデルの構成要素として使用できることを述べる．また，この動作プリミティブから再現動作のためのロボットの動作指令を生成することができ，かつ人の動作を認識するためのロバストな認識器としても利用できることを示す．

4章では，作業モデルに従ってロボットが作業を再現する場合に作業が失敗する可能性について論じ，失敗の要因を(1)観察データの誤差,(2)作業実行時の外乱の2つに限定して，それぞれについて動作の失敗を回避する方法を述べる．

5章では，最終的に生成された作業モデルについて説明し，開発した人間型ロボットプラットフォームによる提案手法の検証結果について述べる．

最後に6章において結論を述べる．

## 第2章 基本プリミティブに基づく作業の概略の認識

本研究では、対象とする作業ドメインに現れる普遍性を持った作業の構成要素を基本プリミティブとして定義し、これを実演教示の解析に用いる認識器として利用するとともに、作業の抽象表現である作業モデルの記述にも用いる。普遍性を持った作業の構成要素として、(1) 把持の形態、(2) 腕の動作、(3) 環境物体の幾何形状と色形状を選択し、それぞれについてその作業ドメインでの表出を網羅するように有限個のプリミティブ集合を設計する。

人間による実演教示は入力センサによって記録され、注視戦略にしたがってセグメンテーションされた後に基本プリミティブとのパターンマッチングに基づく照合が行われ、プリミティブが同定される。3種類の基本プリミティブは段階的に同定され、これによって作業の概略が認識される。

プリミティブが同定される順番は、センサ間の依存関係と注視戦略によって現在どのセンサの情報の解析範囲が絞られておりどのプリミティブとの照合が一番ふさわしいかによって決定される。

本章では、まず基本プリミティブの定義とその設計方法について述べ、本研究で対象とする手作業を効率よく解析するための入力センサの構成とそれを用いた注視戦略について述べる。さらに、それぞれのセンサの具体的な処理の手法、生成された作業モデル、および予備的な検証実験を行った結果について述べる。

### 2.1 基本プリミティブの定義

本節では、以下の3種類の基本プリミティブを定義し、その意味・表現方法および認識のための手法について述べる。

- 掌の圧力分布に基づく把持プリミティブ
- 作業によく現れる腕の動作プリミティブ
- 幾何形状と色分布による物体プリミティブ

### 2.1.1 把持プリミティブ

手の把持形態を表すプリミティブとして、これまで手の静的な形状の分類分けを利用する方法が提案されている。

静的な把持の分類に関しては、古典的には作業の対象物に応じて (1) 釣握り (hook grasp), (2) 筒握り (cylindrical grasp), (3) こぶし握り (fist grasp), (4) 球握り (spherical grasp), (5) 指尖掴み (tip prehension), (6) 掌側面掴み (palmar prehension), (7) 側面掴み (lateral prehension) の 7 種類に把持を分類する試みがなされた [55]。

後になって、Napier は把持の種類は作業の対象物ではなく作業の目的によって決まると主張し、多くの把持動作は対象物の固定を目的とする (1) 圧力把握 (power grip) と対象物の操作を目的とする (2) 精密把握 (precision grip) の 2 つに分けられることを示し、作業目的に即した分類分けを提案した [48]。これは以降の分類分けの基礎となっている。Cutkosky は Napier の分類を拡張し、一般的な機械部品の組立作業において生じる把持を 14 種類に細かく分類し、樹形図の形で表した。またこれを用いて、人間がどの把持形態をとっているのかを判別するエキスパートシステムを開発した [49]。

一方、ロボットに把持を行わせることを考えた場合、一般にロボットハンドの機構と人間の手の機構は異なるため、人間の把持形態からロボットハンドに適した把持形態へのマッピング問題を解決する必要がある。Arbib らが提案した Virtual Finger の概念がよく知られている [51]。Virtual finger とは、ある操作において似た動作をする 1 本以上の指をまとめた仮想的な指であり、一般的な把持は 2 本から 3 本の virtual finger によって記述することが可能である。また、機構や指の本数の異なるロボットハンドについても、動作の似ている指をまとめることで virtual finger と対応させることができ、特定の構造のロボットハンドに依存しない把持の中間表現として利用される。

Kang は、人間の手と把持物体との接触状態を接触点とその力によってトポロジカルに表現する Contact Web を提案した [56]。そして、ステレオ視覚による観察から接触点を推定して Contact Web を構築し、同時に推定された接触力の方向から Virtual Finger を生成することで、人間の把持のロボットハンドの把持へのマッピングを実現した。

しかし、Cutkosky の分類 [49] や Kang の方法 [56] は組立作業における把持を対象としており、例えば (1) 手のひらの接触を一点で近似する、(2) 指の先端以外の側面や腹を柔軟に使った把持を考慮していないといった制限がある、そのため、日常生活においてよく現れる掌全体を柔軟に使った把持を表現する目的にはそぐわない。

また、プリミティブに分類するのではなく手の形状を直接獲得する試みとして、島田らの時系列上で手形状が緩やかに変化すると拘束から単眼画像より手形状を推定する手法 [57] や、上田らの多視点シルエット画像から体積交差法により手のボリューム表現を求め 3 次元モデルをフィッティングする手法 [58] がある。これら手法では非常に高速に手形状を連続認識可能であるが、手が隠蔽されず完全に見えることが前提となっており、本研究のように物体の操作を前提としている場合には直接利用することができない。

表 2.1: 日常動作における把持の分類

圧力把握系
握力把握-標準型 (Power Grip-Standard Type)
握力把握-釣型 (Power Grip-Hook Type)
握力把握-示指伸展型 (Power Grip-Index Extension Type)
握力把握-伸展型 (Power Grip-Extension Type)
握力把握-遠位型 (Power Grip-Distal Type)
中間把握系
側面把握 (Lateral Grip)
三面把握-標準型 (Tripod Grip-Standard Type)
三面把握-亜型 I (Tripod Grip-Variation I)
三面把握-亜型 II (Tripod Grip-Variation II)
精密把握系
並列軽屈曲把握 (Parallel Mild Flexion Grip)
包囲軽屈曲把握 (Circular Mild Flexion Grip)
指尖把握 (Tip Grip)
並列伸展把握 (Parallel Extension Grip)
母指不関与系
内転把握 (Adduction Grip)

鎌倉は、作業療法士の立場から日常生活で現れる種々の把持を 14 種類に分類した [52]。この分類方法と Cutkosky の分類方法との大きな違いは、(1) 手の骨格ではなく掌の接触分布で分類分けをしている点、(2) 大分類として圧力把握系・精密把握系の他に指の側面をよく使う中間把握系を導入している点にある (表 2.1)。この中間把持は組立作業には現れないが日常動作には頻出するため、本研究では把持の分類規範として鎌倉の方法を使用する。

また、把持の認識を行う際に Kang らは純粋に視覚によって把持形態を認識することを試みた [56]。しかし、ステレオ視覚を用いることによって指先と把持物体との接触は精度よく推定できるものの、手のひらや指の腹・側面の接触は直接観察できないため推定することは困難であり考慮されていない。

人の動作獲得過程においては教示者の手の接触情報が直接利用できないことから入力情報は視覚と言語の 2 つに限られる。このうち動作獲得の初期の段階では視覚情報の重みが大いため、純粋に視覚のみを用いるアプローチは人の動作獲得過程の実装の観点からは妥当である。しかし現状では、人間の高性能な視覚機能を工学的に実現できないため、Kang らは視覚の補助手段としてデータグローブの情報を使用している。

本研究の場合は、鎌倉の分類が図 2.1 に示すように掌の接触分布で規定できるため、手形状

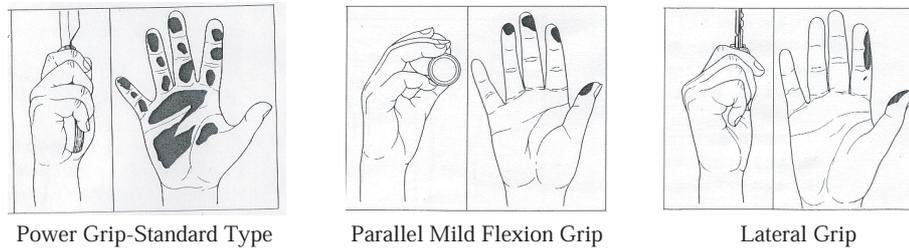


図 2.1: 鎌倉の把持分類における掌の接触分布例

認識の補助手段としてデータグローブに圧力センサを分散配置しその情報を用いる．分布するセンサの数を  $N$ ，各センサ入力を  $s_i$  とし，鎌倉の  $j$  ( $1 \leq j \leq 14$ ) 番目の分類における接触圧分布を  $C_{j,i}$  ( $1 \leq i \leq N$ ) とすると，認識結果は式 (2.1) によって計算され把持プリミティブとなる．

$$\text{把持プリミティブ} = \operatorname{argmin}_j \left\{ \sum_{i=1}^N (C_{j,i} - s_i)^2 \mid 1 \leq j \leq 14 \right\} \quad (2.1)$$

### 2.1.2 動作プリミティブ

本節では，作業ドメインに頻出する腕もしくは指の動きのパターンを動作プリミティブとしてモデル化し，これを用いて動作認識を行う手法について述べる．このような動作は，基本となる動きのパターンから時空間上で確率的に変動するため，不確定な時系列のデータをモデル化するための有効な統計的手法である隠れマルコフモデル [23] を用いて動作のモデル化と認識を行う．

手作業の抽象化自体に隠れマルコフモデルを利用する研究例は多くあり，例えば Xu と Yang は人間の持つ 2 種類のスキルをモデル化するために隠れマルコフモデルを使用した．1 つはセンサフィードバックの必要のないスキルで，モデルの状態が人間のある時点での思考状態に，状態の出力が把持物体の位置と抗力に対応する一方向型の隠れマルコフモデルで記述された．もう 1 つはセンサフィードバックの必要なスキルで，センサ入力を出力指令に変換する一方向型の隠れマルコフモデルとして記述された [45]．しかし，思考状態としている個々の状態が実際に作業の何を表しているのかが明確になっておらず，より複雑な作業を記述するためにモデルをいかに拡張したらよいのかが不明である．

作業の内容を明示的に表現する方法として，Hovland と McCarragher らは単純な 2 次元空間での組立作業において，可能な接触状態を 5 つに分類しそれぞれを状態として全結合型の隠れマルコフモデルを構築した．環境からのセンサ入力を時間方向に離散化したものをトレーニングに用い，作業レベルでの動作のモデル化を行った [46]．

これらの方法は、いずれも手と操作物体を含めた作業の全容を隠れマルコフモデルによってモデル化する試みであるが、モデルの状態の切り替えが把持物体の接触状態や抗力の変化に依存しているため、本研究の目的にはそぐわない。そのため、本節では [59] のように手の動作のみを隠れマルコフモデルによってモデル化する手法を説明する。また第 3 章では、この拡張として把持物体の動きを隠れマルコフモデルによってモデル化する手法を述べる。

以降では、まず隠れマルコフモデルの概要を説明し、離散的に現れるパターンを推定するためスポットニング認識への拡張方法、およびこれを用いて実際にモデル化した 2 種類の動作プリミティブについて述べ、それぞれの認識性能を示す。

### 2.1.2.1 隠れマルコフモデル

隠れマルコフモデル (Hidden Markov Model: 以下 HMM) は、不確定な時系列のデータをモデル化するために有効な統計的手法であり [23]、音声認識における重要な基礎技術の一つとなっている。HMM の特徴は、時系列遷移のマルコフ性を仮定し、また単純マルコフモデルの状態間の遷移と状態における出力がどちらも確率的であり内部の状態遷移が出力系列から一意に決まらないところにある。これが「隠れ」マルコフモデルと呼ばれる所以である。マルコフ性とは、式 (2.2) に示すようにある状態 ( $s_{i(t-1)}$ ) から次の状態 ( $s_{i(t)}$ ) に遷移する確率はそれ以前の状態に依存しないことを指す。出力系列に含まれるノイズを確率的に処理出来る上、モデルのシンボルと時系列データを結びつける各状態の理論的展開が容易な事から、音声のみならずジェスチャー認識にも使われる事が多い [59]。本研究では、このように時間軸方向の遷移が確率的であるという性質が不定長の手の動作のモデル化に適している上、後述するように事前のセグメンテーションを行うこと無く連続動作認識が可能であるという利点があるため、HMM を利用して動作プリミティブのモデル化と認識を行う。

$$\begin{aligned} P(S_t = s_{i(t)} | S_1 = s_{i(1)} \cap S_2 = s_{i(2)} \cap \dots \cap S_{t-1} = s_{i(t-1)}) \\ = P(S_t = s_{i(t)} | S_{t-1} = s_{i(t-1)}) \end{aligned} \quad (2.2)$$

一般的に HMM は、図 2.2 に示すように有効グラフの形で表され、記述上は  $\{A, B, \pi\}$  と表すことができる。  $A = \{a_{i,j} | 1 \leq i \leq N, 1 \leq j \leq N\}$  はマルコフ過程において状態  $S_i$  から状態  $S_j$  への遷移確率を表す行列を指し、  $\pi = \{\pi_i | 1 \leq i \leq N\}$  は初期位置の確率分布を、  $B = \{b_i(O_k) | 1 \leq i \leq N, 1 \leq k \leq M\}$  は状態  $S_i$  における出力シンボル  $O_k$  の生起確率を表す。HMM を時系列パターンの認識に使う方法は、以下の手順となる [23]。

1. 識別対象を決定し、いくつかのモデルに分類するのかを決定する。
2. 分類毎に、HMM の状態数・状態遷移のトポロジー・出力シンボル  $O_k$  などを決定する。

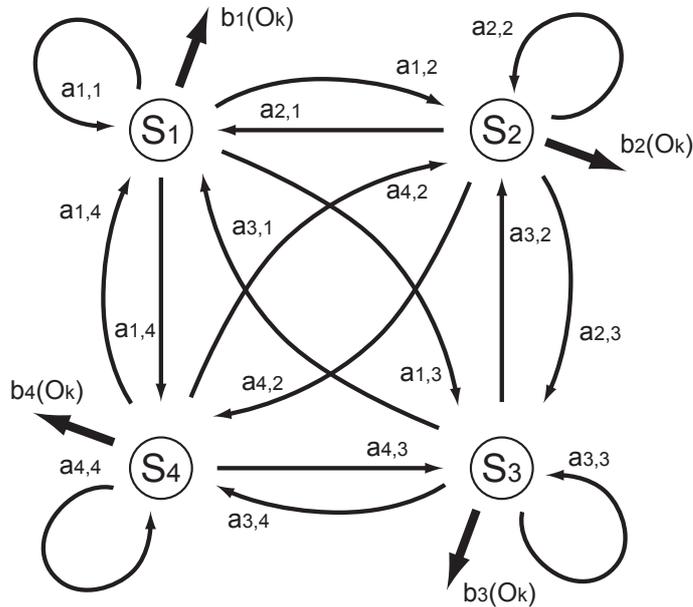


図 2.2: 隠れマルコフモデル：状態遷移図

3. 分類毎に学習パターンを用意し, Forward-Backward アルゴリズムを利用した Baum-Welch アルゴリズムを用いてパラメータ  $\{A, B, \pi\}$  を学習する.
4. 未知パターン  $O = (O_{i(1)}, O_{i(2)}, \dots, O_{i(T)})$  に対しては, Forward-Backward アルゴリズムによって HMM 毎に  $O$  を生成する出力確率  $p(O|\text{HMM}_j)$  を推定し, ベイズ推定により事後確率  $p(\text{HMM}_j|O)$  を最大にする HMM が表す分類を認識結果とする. また, その時の状態遷移系列  $(S_{i(1)}, S_{i(2)}, \dots, S_{i(T)})$  は Viterbi アルゴリズムを用いて推定される.

#### 2.1.2.2 スポットティング認識

ジェスチャーのスポットティング認識とは, 連続した動作の中から時間的位置が未知のジェスチャーの判別と, 時系列上のセグメンテーションを同時に行うものである. これにより, ジェスチャーを動作の開始と終了を意識することなく認識する事が可能となる.

スポットティング認識には連続 Dynamic Programming (DP) を用いたもの, HMM を用いたもの, ニューラルネットを用いたもの等様々な手法が提案されている. 連続 DP は始点固定で終点フリーの DP マッチングを連続して行う方法で, 計算量が HMM と比べて極めて大きくなるためさまざまな工夫が提案されている [60]. 標準的な HMM によるスポットティング認識は, キーワードとなる HMM と Garbage (Filler) HMM を並列に繋げ, 対象外の動きを Garbage HMM 内の状態に落とし込む方法がとられる [61]. 音声の場合, Garbage HMM を全音素の HMM が

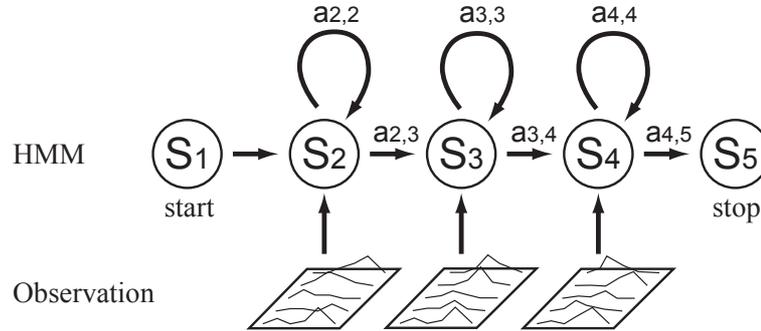


図 2.3: 動作プリミティブを表現するための隠れマルコフモデル

ら用意する事が可能だが，ジェスチャーの場合，明確な要素となる動作の定義は無い．その為，アドホックに作成する [62] か，閾値を出す為の閾値モデルを作るなどの工夫 [63] が必要となる．本研究では，スポッティング対象の語彙数が少ない為，Garbage HMM を独自に作成した．

### 2.1.2.3 モデルのトポロジー

対象とする動作は確率的な幅を持ちながらも開始状態から終了状態まで一方向に遷移するため，動作プリミティブを学習するための HMM のトポロジーとして図 2.3 に示すように一方向 (left-to-right) HMM を使用した．状態数は 5 とし，後戻りのない一方向の遷移のみが可能である．

各状態はある時点の動作の状態を確率的な幅を持つ表現 (図 2.3 Observation) で表しており，ガウス混合分布で表現することができる．すると入力ベクトルの次元数を  $N$  とした時，状態  $S_i$  は，平均と共分散の組  $\{(\mu_{ijs}, \Sigma_{ijs}) | 1 \leq j \leq N, 1 \leq s \leq M_i\}$  と記述することができる．ただし  $M_i$  はガウス混合分布に含まれる正規分布の数とする．すると，時刻  $t$  において観察量  $O(t)$  を状態  $S_i$  が生起する確率  $b_i(O(t))$  は式 (2.3) のように求まる．

$$b_i(O(t)) = \sum_{j=1}^{M_i} c_{ij} \mathcal{N}(O(t); \mu_{ij}, \Sigma_{ij}) \quad (2.3)$$

ただし， $\mathcal{N}$  は式 (2.4) に示す正規分布， $c_{ij}$  は各正規分布の重みを表す．

$$\mathcal{N}(\mathbf{o}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{\sqrt{(2\pi)^N |\boldsymbol{\Sigma}|}} e^{-\frac{1}{2}(\mathbf{o}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{o}-\boldsymbol{\mu})} \quad (2.4)$$

ここでは，各動作はプリミティブ動作であり変動は少ないとの前提からガウス混合分布を

単一の正規分布で近似し ( $M_i = 1$ ) , また入力ベクトルの要素間には相関がないとして共分散行列の対角以外を 0 とする簡略化を行う .

実際の学習と認識は , 音声認識の分野で広く使用されている Hidden Markov Model Toolkit (HTK) [64] を用い , データグローブから得られるの手形状 , 3次元位置・姿勢 , 触覚センサのデータをオンラインもしくはオフラインで取り扱えるように独自に拡張した上で前記の条件の下で使用した .

#### 2.1.2.4 動作プリミティブのモデル化例 1

##### 動作プリミティブの設計

まず対象とする作業を単純な注ぎ動作に限定し , この作業で出現し得る動作を動作プリミティブとして設計して , 手法の妥当性の予備的な評価を行った .

表 2.2: 注ぐ動作における動作プリミティブ

Primitives	Description
cls	Power grip
prc	Precision grip
opn	Release
roll	Rotation (twist) of the wrist
forw	Translation (forward) of the hand
gb	Garbage (noise absorber)
sil	Silent (start or end of the motion)
sp	Short pose (no motion)

この作業では , (1) 容器を掴んで別の容器に注ぐ , (2) 容器を掴んで前に差し出すの 2 種類の動作しか発生しない . そのため , 表 2.2 の上段に示す 5 つの動作プリミティブによって全ての動作が記述可能である . cls と prc はそれぞれ圧力把握・精密把握に対応し , opn は離す動作に , roll は手首の軸回りの回転 , forw は手を前に押し出す動作を表す .

表 2.2 の下段に示すのは認識の際に補助的に必要となる HMM であり , gb は動作間の不定状態を他の HMM よりも高い確率で吸収する garbage collector , sil は一連の動作 (後述) の先頭と末尾に挿入される識別用の HMM , sp は各動作シンボルの後に入る動作の中断点を指す連結用の HMM を示す . sil と sp は , HTK を使用する上で必要となる補助 HMM である .

またこのとき , 表 2.3 に示すようにこれらの 5 つの動作プリミティブを組み合わせることで高次の意味を持った行為を表現することが可能になる . 例えば , 注ぐ (Pour) という行為は , 圧力把握動作を行い (cls) , 次いで手首の軸回りの回転を行う動作 (roll) を連続的に行うことで表

表 2.3: 動作プリミティブの結合による行為の記述

Gesture	Primitives	Action
GRIP	cls+sp	Power-grasp from open position
PICK	prc+sp	Precision-grasp from open position
POUR	cls+roll+sp	Power-grasp, and roll the wrist
EXTEND	prc+forw+sp	Precision-grasp, move forward, and back
RELEASE	opn+sp	Open a grasp hand
GARBAGE	gb	A filler model for spotting
START,END	sil	Silence at the start and end

現される．HMM を共有し，行為のレベルで学習を行うことで，学習用データの不足を補い学習効率を向上させることが可能になる．

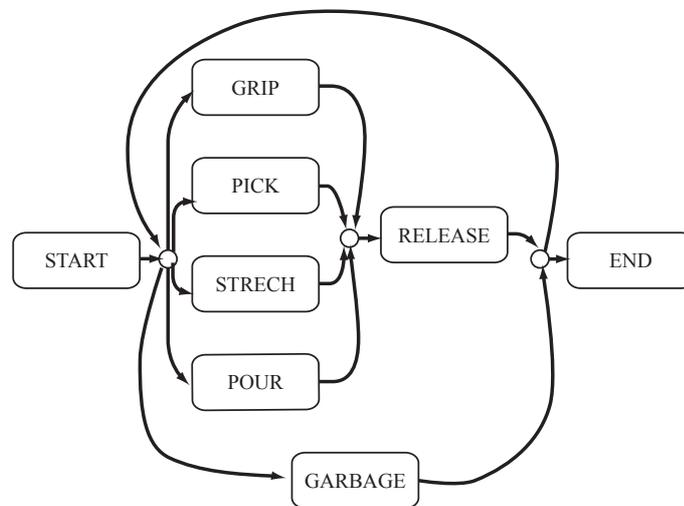


図 2.4: HMM ネットワークの文法

さらに図 2.4 に示すように連続する行為の間には一定の順序関係が存在する．例えば，摘む (Pick) という行為の後には必ず離す (Release) という行為が伴う．この順序関係を文法として認識システムの中に組み込みことで認識誤りを低減することができる．

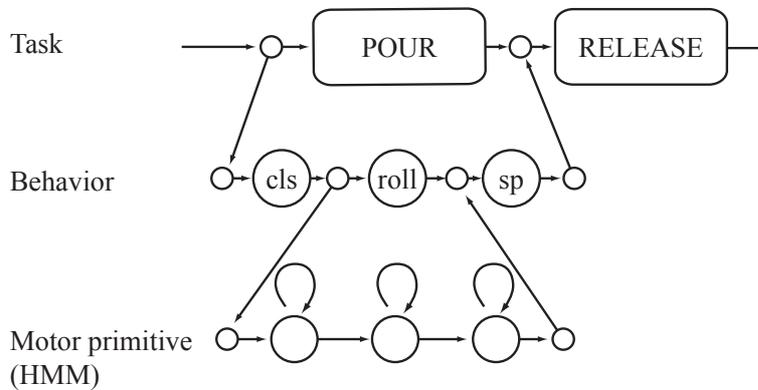


図 2.5: 手の動作認識のための階層的な HMM 表現

これらをまとめると，図 2.5 に示すように全体の認識系が階層構造になっていることが分かる．このように，有限個の動作プリミティブを規定し (Motion primitive)，動作プリミティブを組み合わせることによって行為 (Behavior) を表現し，行為の順序関係を規定することで対象とする作業を記述する枠組みを構成する．

#### 認識系の設計

前述の 5 つの動作プリミティブを認識するための入力として，データグローブ (CyberGlove) と 3 次元位置・姿勢センサ (Polhemus) を使用した．ただし，図 2.6 に示すようにデータグローブの甲に装着されている Polhemus 3D tracker 受信機の位置と姿勢は  $4 \times 4$  の同次変換行列  ${}^{P_t}T_W$  で記述できるが，世界座標系  ${}^W\Sigma$  を基準として獲得されるため，HMM が絶対位置・姿勢に依存しないためには式 (2.5) に示すように一つ前の時刻  $t-1$  の座標における受信機座標系における位置・姿勢  ${}^{P_t}T_{P_{t-1}}$  に変換する必要がある．

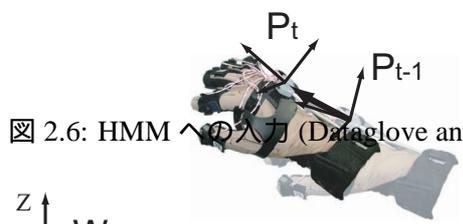
$${}^{P_t}T_{P_{t-1}} = {}^{P_t}T_W \cdot {}^{P_{t-1}}T_W^{-1} \quad (2.5)$$

するとセンサ入力の次元は，指や手首の曲がり具合を表す 18 自由度と，Polhemus より得られる前フレーム座標系での位置と姿勢 (速度) を表す 6 自由度の計 24 自由度となり，さらにそれぞれの時間微分である変化量を加えた合計 48 自由度を HMM への入力ベクトルとする．

左右の手を同時に使う場合には，HMM は手左右独立して学習・生成され，認識段階においては両手の動作は並列かつ同時に処理される．両手を使って一つの物体に作用する動作については，左右の認識結果を統合した後同じ対象物体に作用しているか否かを調べることによって判断され，この作業においては両手で同時に Extend 動作を行う，つまり両手で同じ物を把持し前に差し出すといった動作に表れる．

図 2.6: HMM への入力 (Dataglove and Polhemus)

認識系の学習と評価



HMM の学習には時間情報付きラベルデータを用いるのが最も望ましい。しかし、本研究が対象とする手の動作には、音声と異なりデータベースが存在しない。そのため、初期モデルの平均ベクトルと分散を学習データ全体から求め、フラットスタート処理を行った。初期化された HMM は各々の連続学習 24 DOF 最適化 24 DOF (連続学習では DOF が上げられた複数の HMM が学習データ全体で同時に最適化される。時間情報付きラベルデータは必要無く、学習データに対応したジェスチャーの出現順序を記したラベルデータがあればよい。

本システムは認識に Viterbi アルゴリズムを連続信号認識向けに最適化した Token Passing model を採用している。Viterbi アルゴリズムは、HMM において与えられた時系列データに沿った最適な状態系列と系列上での確率を求めるアルゴリズムである。Token Passing では、データの更新と同時に、遷移情報と確率を含んだ各 Token を更新をしながら最尤 Token を遷移先にコピーしていくことで、Viterbi アルゴリズムと同じ問題を高速に解く。更に、Token にジェスチャーの最終状態や遷移時間を含むことで、時系列セグメンテーションも可能である。実験では 30Hz で入力される両手の特徴ベクトルに対し、遅延無しでジェスチャーのスポットティング認識を左右同時に行うことができることを確認している。

HMM の学習は片手ずつ行われ、各腕は文法にそったトランスクリプト付き学習データを 5 パターン各 5 回分と Garbage HMM 用データを 10 回分、計 184 秒 (5520 フレーム、内 Garbage 用は 1670 フレーム) 分を使用した。各トレーニングパターンは、平均 6 個の”行為”を文法に合うように並べたものを手動で生成した。ジェスチャーの単語認識は学習データとは別パターンのテストセットで実験を行った。テストセットは 5 パターンのジェスチャー配列を各 1 回ずつ計 109 秒分使用した。認識結果を表 2.4 に示す。

表 2.4: ジェスチャの認識

	Left hand	Light Hand
Accuracy	98.89%	95.56%
N,D,S,I	90,0,0,1	90,0,4,0

$$\% \text{ Accuracy} = \frac{N-D-S-I}{N} \times 100\%$$

(N)number of gestures, (D)eleleion error,  
(S)ubstitution error, (I)nsertion error

### 2.1.2.5 動作プリミティブのモデル化例 2

前節では非常に限定された作業ドメインを設定し、いわば恣意的に動作プリミティブを設計してアルゴリズムの評価を行った。本節では実際の日常生活に頻出する動作を広範囲にわたって記述可能な汎用性のある動作プリミティブの設計を試みる。ただし、任意の動作の認識を対象とした場合、多くの例外処理を設け、かつ得られた動作プリミティブの妥当性の検証が困難になるため、本研究ではある閉じた作業ドメインを一つ選択し、その枠組みの中で妥当性を持つ動作プリミティブを設計する。その後、その動作プリミティブが他の作業ドメインに対しても有効であるのか否かを評価することにより、日常生活全般を網羅することが可能な動作プリミティブについて考察を行う。

ここでは、比較的閉じた作業領域でありかつ様式（文法）が決まっておりモデル化のしやすい作業として、裏千家茶道 [65] を選択した。茶道の特徴は、何種類もの点前の方法がある中で、各点前については茶道具を展開してから茶を点て終わるまでの一連の点茶の手順が動作の進行・茶器の空間的な位置の移り変わりを含めて厳密に決まっていることにある。これは、システムティックに解析を行う立場がから見ると、教示者の動作の逸脱が非常に少ないことを意味する。つまり、学習時と認識時で教示者が異なる場合でも、入力としてほぼ同一のものが獲得できることを意味する。また、行為の種類が限定されており、かつ時系列上での順序関係が厳密に規定されているため、モデルを設計することが比較的容易である。

#### 動作プリミティブの設計

表 2.5 に示すのは、点前の 1 種である風炉薄茶点前から代表的な動作を抜き出し、現れる手の動作を手動で解析したものである。表 2.5 の概要にあるように、(1) 抹茶を茶碗に入れ、(2) お湯を注ぎ、(3) 茶筌で茶を点てる代表的な 3 動作が入っている。

これを見ると、主な動作は“指先把持（上下）”、“指先把持（左右）”、“つまむ”、“離す”、“注ぐ”、“攪拌”、“手のひらで支える”、“回す”の 8 種類であることが分かった。このうち、“手のひらで支える”はもう片方の手を補助するための受け身動作であるためここでは考慮から外す。また“回す”は茶碗の縁を指先で把持し茶碗の中心軸回りに茶碗を旋回させる動作だが、これは茶を点てた後に客に茶を差し出す前に行われる動作であり点茶自体に必須ではない上、他の動作と比べて日常的に用いられる頻度が少ないため、これも考慮から外す。

表 2.5: 風炉薄茶点前の動作順序

写真	概要	動作	把持アプローチ
	右手で茶碗を取る	把持(右)	横から上下
	左手に持ち替え(中身を捨て)	離す(右) 把持(左) 注ぐ(左)	横から上下
	右手で茶巾を取り, 茶碗を拭く	NULL	
	右手で茶杓を取る	NULL	
	左手で棗を取って移動	把持(左)	横から左右
	右手で茶杓を握りこむ なつめの蓋をはずす 茶碗に茶を入れる	NULL 把持(右) 蓋開け(右) 離す(右) 注ぐ(左) 離す(左)	上から
	水差しの蓋を(右・左・右)と持ち替えて取る	NULL	
	柄杓で湯を汲む 右手で茶笥を取る 左手で茶碗を支える	把持(右) 注ぐ(右) 離す(右) つまむ(右) 把持(左)	横から左右 上から 横から上下
	茶を立てる 右手で茶碗を取る	攪拌(右) 離す(右) 離す(左) 把持(右)	横から上下
	左手で下から支える	手のひらで支える	
	右手で茶碗を回す	把持(右) 回す(右) 離す(右)	横から上下
	右手で茶碗を取り置く	把持(右) 離す(右)	横から上下

表 2.6: 動作プリミティブ

Primitive	Description
pick	つまむ (親指を含む 3 本の指先でつまむ)
grsp	把持 (親指を含む 4 本以上の指先で把持)
rls	離す (つまんだ or 把持状態から手を離す)
grt_r	把持右回り (親指を含む 3 本以上で把持した状態で上腕の軸回りに右回転)
grt_l	把持左回り (親指を含む 3 本以上で把持した状態で上腕の軸回りに左回転)
gtwst_r	把持右ひねり (親指を含む 3 本以上で把持した状態で指をひねって右回転)
gtwst_l	把持左ひねり (親指を含む 3 本以上で把持した状態で指をひねって左回転)
twst_r	右ひねり (離れた状態で指をひねって右回転)
twst_l	左ひねり (離れた状態で指をひねって左回転)
crcl_r	攪拌右 (親指を含む 3 本以上で把持した状態で上腕の軸回りに 1 回右回りに旋回)
crcl_l	攪拌左 (親指を含む 3 本以上で把持した状態で上腕の軸回りに 1 回右回りに旋回)
gb	Garbage (noise absorber)
sil	Silent (start or end of the motion)
sp	Short pose (no motion)

すると、表 2.6 に示すように動作プリミティブを設計し、その組み合わせとして表 2.7 に示すように行為を設計すると、茶道の代表的な動作を網羅した手の動作プリミティブを記述できることが分かる。ただし、表 2.7 の“OPEN”、“CLOSE” は瓶の蓋をねじって開け閉めを行う動作を指し、茶道には現れないものの日常生活ではよく見かける動作であり、かつ表 2.6 の動作プリミティブから簡単に構成できるため追加する。このとき、行為の順序関係を規定する文法は図 2.7 に示す通りになる。

#### 認識系の設計と評価

2.1.2.4 節の認識系では、指の形状と手の 3 次元空間内の動きベクトルを入力として動作プリミティブの学習を行った。しかし、指の形状は把持物体の大きさや形状に依存して変化するため、同じ動作プリミティブであっても対象物に応じて入力値が変化し、HMM の場合は各状態がある時点での入力の平均と分散によって確率的に表現されるため、必然的に分散が大きくなりそのパラメータが認識に貢献しなくなるという現象が生じる。このとき、例えば Kang の Volume Sweep Rate のプロファイルを調べる手法 [56] によって把持自体は頑健に検出されるものの、動作の種別の認識は難しい。そのため、それを補う意味で対象物の形状変化に対して変動の少ない掌の圧力分布の情報もモデルの入力に組み込む。

また 3 次元位置・姿勢の変化分のうち位置に変化分については、環境物体の大きさや相対関

表 2.7: 動作プリミティブの結合による行為の記述

Behavior	Primitives	Action
PICK	pick + sp	つまむ
GRASP	grsp + sp	把持
RELEASE	rls + sp	離す
POURR	grt_r + grt_l + sp	右に注ぐ
POURL	grt_l + grt_r + sp	左に注ぐ
OPEN	gtwst_l + twst_r + sp	蓋を開ける
CLOSE	gtwst_r + twst_l + sp	蓋を閉める
STIRR	crcl_r + sp	右に攪拌
STIRL	crcl_l + sp	左に攪拌
GARBAGE	gb	A filler model for spotting
START,END	sil	Silence at the start and end

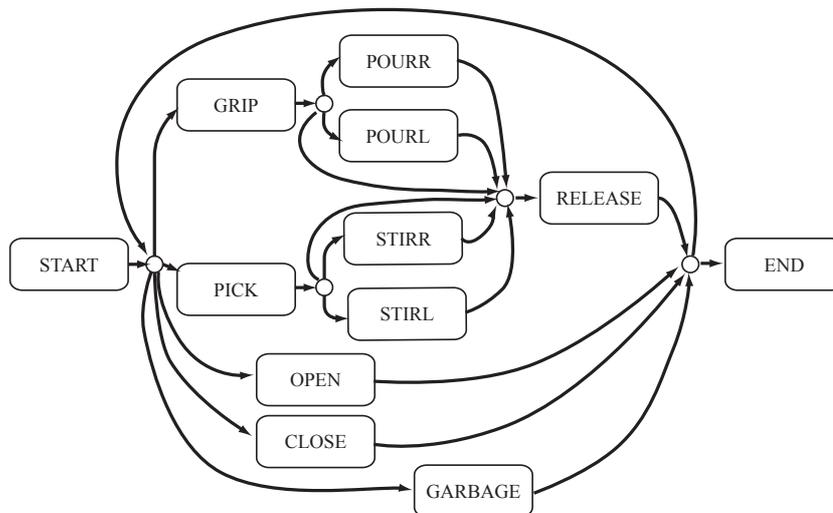


図 2.7: HMM ネットワークの文法

係に依存する項であるため，ここでは姿勢の変化分のみを取り扱うとした．

さらに，前節では指の形状・手の姿勢の変化分それぞれの時間差分をも HMM への入力ベクトルとして扱っていたが，動作プリミティブの種類やトレーニングセットの数と比較して次元が不必要に高くなり過学習の傾向が見られたため，ここでは時間差分を取り入れないこと

表 2.8: 認識結果:(指形状 + 姿勢変化 + 触覚)

Input	指形状 + 姿勢変化 + 触覚
SENT	Correct=28.57 % [H=2, S=5, N=7]
WORD	Corr=89.47 %, Acc=84.21 % [H=34, D=3, S=1, I=2, N=38]

$$\% \text{ Accuracy} = \frac{N-D-S-I}{N} \times 100\%$$

(N)number of gestures, (D)eleation error,  
(S)ubstitution error, (I)nsertion error

表 2.9: 認識結果:(指形状 + 姿勢変化 + 触覚 with Garbage)

Input	指形状 + 姿勢変化 + 触覚
SENT	Correct=12.50 % [H=1, S=7, N=8]
WORD	Corr=89.74 %, Acc=66.67 % [H=35, D=1, S=3, I=9, N=39]

$$\% \text{ Accuracy} = \frac{N-D-S-I}{N} \times 100\%$$

(N)number of gestures, (D)eleation error,  
(S)ubstitution error, (I)nsertion error

にする。

最終的な HMM への入力は、指の形状変化 18 自由度・手の姿勢の変化 4 自由度 (quaternion 表現)・触覚センサ 11 自由度) の計 33 自由度となる。

指の形状変化については、静的な把持自体は把持プリミティブの情報から認識できるため、把持と非把持状態を結ぶ動作の記述に主に用いられる。この時、認識結果が把持物体の形状に依存しないためには指の形状変化の時間差分を用いた方が良い可能性がある。そのため、指の形状変化をそのまま扱う場合と時間差分を扱う場合、さらに Garbage HMM を使用する場合と使用しない場合についてそれぞれ HMM を構築し評価を行った。

表 2.8 は入力を指形状 + 姿勢変化 + 触覚とし Garbage を含まない場合の認識結果、表 2.9 は入力を指形状 + 姿勢変化 + 触覚とし Garbage を含めた場合の認識結果、表 2.10 は入力を指形状差分 + 姿勢変化 + 触覚とし Garbage を含まない場合の認識結果、表 2.11 は入力を指形状 + 姿勢変化 + 触覚とし Garbage を含めた場合の認識結果である。

最も結果がよいのは、表 2.11 の入力を指形状 + 姿勢変化 + 触覚とし Garbage を含めた場合の認識結果である。これにより、把持対象物体の形状に依存しない入力ベクトルを選ぶことが重要であり、また Garbage HMM が有効であることが確認できる。

動作プリミティブのうち”つまむ”と”把持”と”離す”は、把持プリミティブと重複する動作プリミティブであり異なる認識方法によって評価されるため、それぞれの結果をお互いにフィードバックすることにより信頼性を高めることが可能である。

表 2.10: 認識結果:(指形状差分 + 姿勢変化 + 触覚)

Input	指形状差分 + 姿勢変化 + 触覚
SENT	Correct=14.29 % [H=1, S=6, N=7]
WORD	Corr=92.11 % , Acc=73.68 % [H=35, D=1, S=2, I=7, N=38]

$$\% \text{ Accuracy} = \frac{N-D-S-I}{N} \times 100\%$$

(N)number of gestures, (D)eleation error,  
(S)ubstitution error, (I)nsertion error

表 2.11: 認識結果:(指形状 + 姿勢変化 + 触覚 with Garbage)

Input	指形状 + 姿勢変化 + 触覚 with Garbage
SENT	Correct=50.00 % [H=4, S=4, N=8]
WORD	Corr=92.31 % , Acc=84.62 % [H=36, D=3, S=0, I=3, N=39]

$$\% \text{ Accuracy} = \frac{N-D-S-I}{N} \times 100\%$$

(N)number of gestures, (D)eleation error,  
(S)ubstitution error, (I)nsertion error

この動作プリミティブは茶道に即して構成したものであるが、表 2.6 を見ると分かるように、動作プリミティブ自体は手の指の局所的な動きをモデル化しており特に茶道に依存しているわけではない。ただし、人間が必要に応じて設計しており、また日常動作の範囲が明確でないため、日常動作全般にわたってどの程度の動作を表現できるのかを定量的に評価することは難しい。そのため、基本となる動作プリミティブをさらに拡張する方法としては、第 3 章で説明するようにシステムが動作を適応的に獲得する方法がふさわしいといえる。

### 2.1.3 物体の幾何形状と色分布による分類

#### 2.1.3.1 物体の幾何形状と色分布の構成

[14] の知見によれば、サルや猫は網膜に映った物体のエッジや角もしくは単純な形状プリミティブ（円筒や球）、模様、色などの低レベルの要素知識の組み合わせとして対象物を認識している。本研究でも、物体の幾何形状を表すメッシュモデルと代表的な色分布の組み合わせによって対象物の認識を行う。

図 2.8 に、本研究で定義した物体プリミティブの例を示す。上段が物体の画像・中段が生成した幾何モデル・下段が代表色の分布である。幾何モデルは実物体を基に CAD で作成し、3 角メッシュにより構成されている。3 次元スキャナーを用いて幾何形状のモデルを観察から自動獲得する方法もあるが、本研究では対象物の形状が単純であり、かつセンサの精度から考え

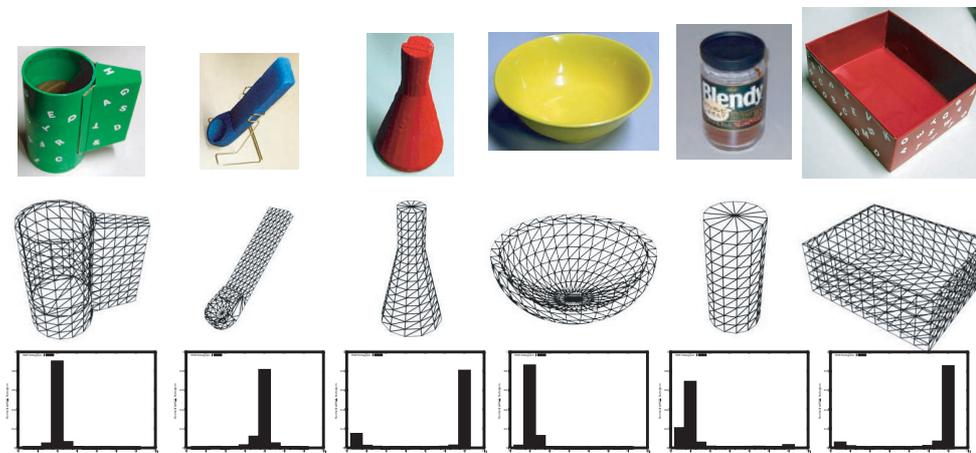


図 2.8: 物体プリミティブ例（上段：画像・中段：幾何モデル・下段：色相分布）

て CAD 上で要素物体の加減算により生成する方法で十分な精度が得られることから，手動で作成した．代表色の分布は，上段の画像で物体に対応する領域について，色相を 12 段階に分けてそのヒストグラムをとったものである．

### 2.1.3.2 視覚による認識システム

ここでは，ステレオ視覚装置から得られるカラー画像・距離データを利用して，物体認識に関する次の 2 通りの問題を解決する方法について述べる．

1. 既知の対象物体のおおよその位置が既知の場合に，物体の正確な位置と姿勢を認識
2. おおよその位置が既知の時に，未知の物体の種別を判定する

また条件として，(1) 環境に存在し得る全ての物体候補についてその 3 次元幾何モデル及び色モデルが既知であり，(2) 対象は既知のテーブルの上に置かれているとする．

認識の手順の概要は下記の通りとなり，以降の節ではその詳細について述べる．

- 視覚装置から得られる距離データ中で，個々の物体に対応する領域を切り出す
- 既知のおおよその位置と姿勢をもとに，対象物体が切り出された領域の中のどの位置にあるのかを推定する
- 対象物の種別が未知の場合には，その領域について全ての幾何モデルとの形状比較を行い類似度を評価することで種別を推定し，その後位置と姿勢の推定を行う

### 2.1.3.3 物体領域の切り出し

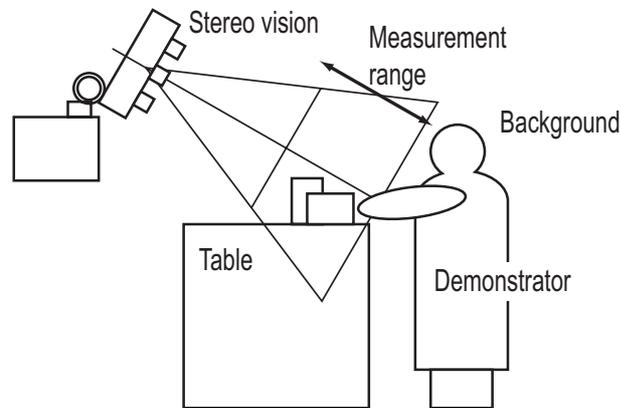


図 2.9: 教示環境

複数の環境物体が図 2.9 に示すようにシステムの前に置かれた既知のテーブルの上に存在するとき、ステレオ視覚によって得られたカラー画像・距離データの中から各環境物体に対応する領域を抽出する手順は以下ようになる(図 2.10 参照)。

1. 図 2.9 に示すように、本ステレオ視覚装置はカメラ配置の物理的な制約から有効な測定

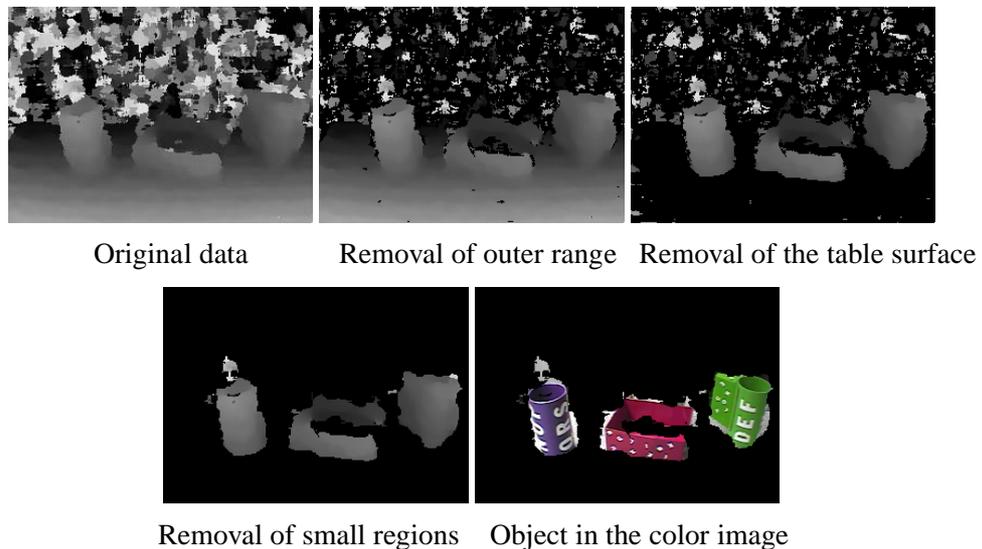


図 2.10: 物体の抽出

範囲が決まっているが、範囲外の領域であっても何らかの値が格納されるためこの部分を取り除く必要がある。

そのため、最小及び2番目に小さな SSAD (Sum of Sum of Absolute Difference) の差を評価する手法 [66] を用い、距離データ中の測定範囲外のデータを除去する。

2. テーブル表面にあたる領域を推定しその部分をマスクする。

視覚装置のパン・チルト角及びテーブルの既知の幾何情報から、カメラ座標系においてテーブル面を表す平面がどの位置に投影されるかが分かる。これを初期値とし距離データ中で平面のフィッティングを行うことで、距離データ中でのテーブル面の位置を推定し、テーブル面より奥側のデータを除去する。

3. 残った領域に対して、収縮・微少領域の除去・膨張の画像演算をかけ、微少領域を除去する。
4. 残った領域を物体に対応する領域とし、その重心を初期推定位置とする。また、対応するカラー画像上の領域の色相ヒストグラムを取る。

物体の姿勢に関しては、テーブル上での姿勢の自由度が鉛直上向の  $z$  軸回転のみであるとし、物体の幾何形状の対称性に応じて1つから4つの姿勢候補を生成する。物体が完全な軸対象であれば候補は1つ、面对称であれば候補は  $\pi$  だけずれた2つ、対称性が無い場合は  $\frac{\pi}{2}$  ずつずれた4つとなる。これは、2.1.3.4 節で述べる推定法が概ね  $\pm\frac{\pi}{4}$  までの姿勢のずれを補正することができるからである。それぞれの候補について次の2.1.3.4 節で述べる推定法を用いて位置と姿勢の推定値を計算し、結果の最もよいものを採用する。

#### 2.1.3.4 位置と姿勢のロバスト推定法

この章では、統合テンプレートマッチング法により、対象物の幾何形状と大まかな位置が既知の時に、対象物の正確な位置と姿勢を同定するための手法について述べる。この手法は、環境中の対象物体の認識及び3次元空間を移動する対象物体の3次元追跡に使用される。

統合テンプレートマッチング法は、3次元情報から推定される3次元誤差 [67] と2次元情報から推定される3次元誤差 [67] を同時に取り扱い、物体のメッシュモデルの初期位置・姿勢が与えられた時に、共役勾配法を用いた反復法によって漸近的に真の位置・姿勢を推定する手法である。

モデルの3次元位置を  $mp_i$  とし、距離データ中の対応する3次元点を  $rp_i$  とすると、両者の関係は変換式  $\langle p, q \rangle$  によって誤差を含んだ式 (2.6) の形で表される。演算  $q \cdot mp_i$  は、 $mp_i$  を quaternion  $q$  に従って回転させることを意味する。

一方、 $\langle p, q \rangle$  に従ってモデルがカラー画像上に投影された時、投影されたモデルのエッジとその再近傍にある画像エッジとは対応することが期待される。これより、 $re_i$  (視線ベクト

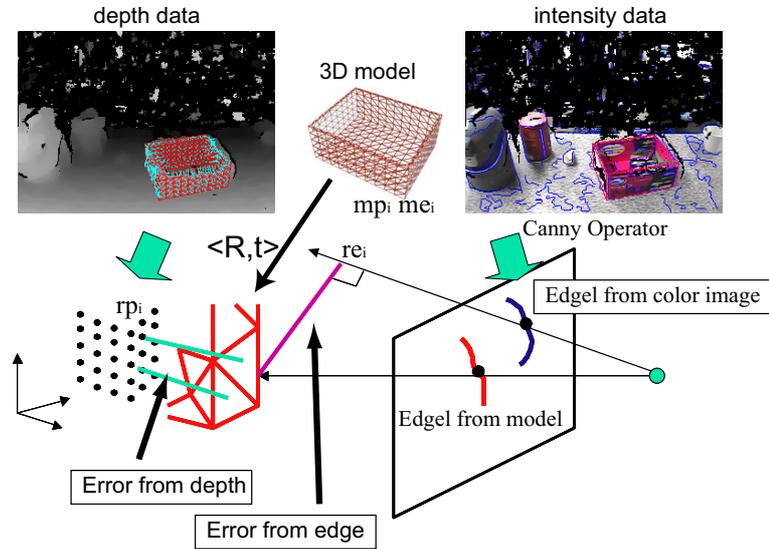


図 2.11: 統合テンプレートマッチング法に基づく物体の位置と姿勢の同定法

ル) と  $(q \cdot me_i + p - re_i)$  との内積が 0 になるとの拘束条件の下で、画像エッジ点を 3 次元空間に逆投影することで、モデルエッジとの 3 次元誤差を推定することができる。  $re_i$  と  $\langle p, q \rangle$  によって変換されたモデルエッジ  $me_i$  との関係は、式 (2.7) で表される。

$$rp_i = q \cdot mp_i + p + \beta_1 \quad (2.6)$$

$$re_i = q \cdot me_i + p + \beta_2 \quad (2.7)$$

ただし、 $\beta_1$  と  $\beta_2$  はランダムな 3 次元ノイズであり、 $\beta$  がガウス分布に従うならば、 $\langle p, q \rangle$  は最小二乗法により式 (2.8) を最小化することによって解くことができる。

$$f(q, p) = \Sigma \| q \cdot mp_i + p - rp_i \|^2 + w \cdot \Sigma \| q \cdot me_i + p - re_i \|^2 \quad (2.8)$$

ただし、 $w$  は重みを表す定数である。

しかし、実際の誤差分布は通常ガウス分布に従わないため、最小二乗法の場合外れ値の影響により同定処理が不安定になる。そのため、Wheeler は M 推定法を誤差分布の評価に用いた物体の同定手法を提案した [67]。M 推定法は最小二乗法の一般形であり、 $E(z) = \sum_i \rho(z_i)$  と定式化される。ただし、 $\rho(z)$  は誤差  $z_i$  の任意の関数である。式 (2.9) で表される Lorentzian 関数の 2 乗を  $\rho(z)$  として用いることで、外れ値の影響を低減し同定性能を向上させることが

できる．これにより，対象物体の一部が隠蔽され不可視の場合にも，メッシュモデル上で正しく対応する距離データが無い個所は外れ値として共役勾配法への寄与が低減されるため，正確な同定が可能となる．

$$\psi(z) = \frac{z}{1 + \frac{1}{2}z^2} \cdots \text{Lorentzian weight function} \quad (2.9)$$

エッジの対応から得られる推定誤差は，視線方向に対して誤差の精度が期待できないため，推定の前半ではまず式 (2.8) の  $w$  の値を小さくし，3次元情報からの推定誤差のみによって大まかな姿勢の推定を行う．推定の後半においては， $w$  を増加させた後再び減少させることによって，2次元情報からの推定誤差を用いて局所解からの脱出を図り，その後再び3次元情報からの推定誤差を利用して真の値への収束を図る．物体近辺にテクスチャが多い場合には，モデルエッジに対応しないエッジが多数検出されるため2次元情報からの誤差が正しく推定されない場合がでてくるが，2次元情報からの誤差は局所解から真の解へのバイアスとして用いられるため，この場合は  $w$  を減少させた時に元の局所解に戻ってくることが期待され，同定性能の劣化の要因にはならない．

### 2.1.3.5 環境物体の位置と姿勢の推定

2.1.3.3 節の手法により環境物体に対応する領域と物体の推定位置が分かる．ついで，図 2.12 に示すように保持している物体モデルそれぞれについて，モデルを初期位置に投影し 2.1.3.4 章に示す手法で位置と・姿勢の推定を行う．この時，2.1.3.3 章で述べたようにモデルの対称性に応じて 1 から 4 つの姿勢候補があるので，それぞれについて推定を行う．

この時，モデルとの一致性を評価するための指標として，2.1.3.4 章の手法で M 推定法の代わりに平均二乗誤差を使った場合の計算値を使用した．これは，外れ点つまりフィッティング誤差の影響を 2 乗のオーダで受けるため，モデルと距離データの差が大きい個所の影響が支配的になり，不一致性を表すよい指標になる．

表 2.12: 検出された形状差

Objects (in Depth Data)	Models		
	Pack	Dish	Bottle
Pack Histogram	<u>0.25</u>	1.30	0.55
Dish Histogram	2.08	<u>0.65</u>	1.43
Bottle Histogram	0.92	1.20	<u>0.37</u>

表 2.12 に示すのが，図 2.1.3.3 の 3 種類の環境物体について，上記の方法で物体領域の識別を行った結果である．この例ではうまく判別ができているが，一般には形状のみでの判別は

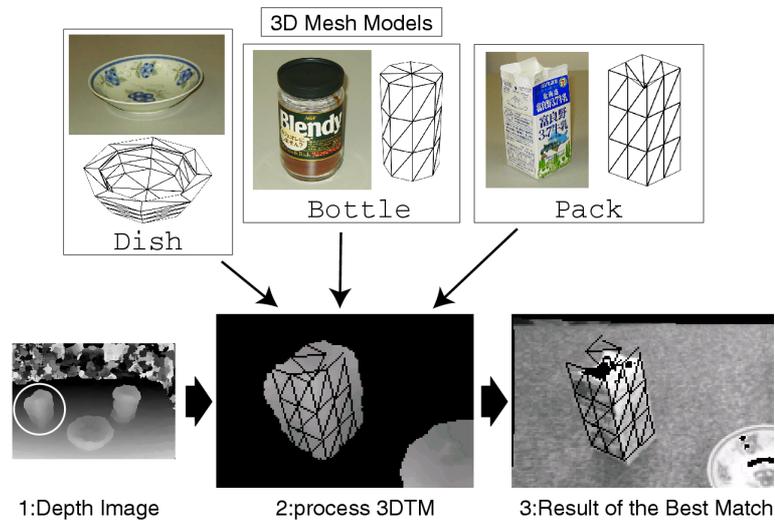


図 2.12: 幾何モデルの一致度に基づく物体認識

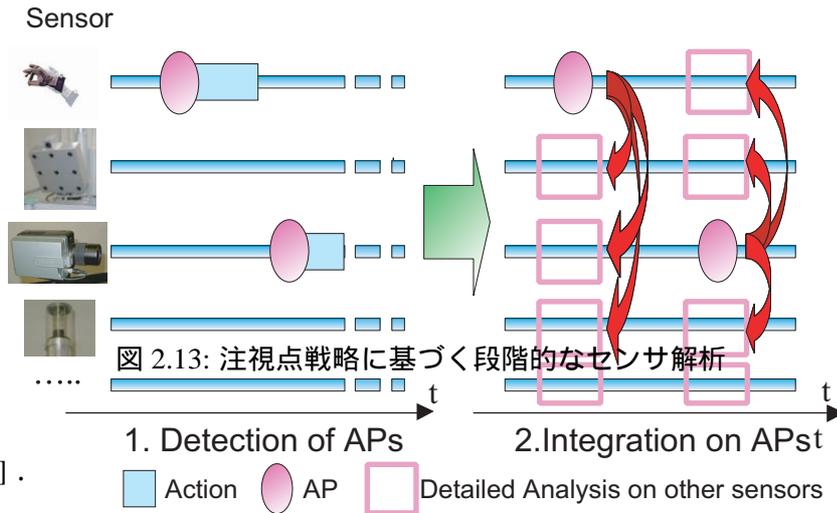
困難である．そこで，形状評価の指標をヒストグラムで表し，同時に色相ヒストグラム同士の一貫性も評価することで，ロバストな推定を試みた．

$ObjG_i$  を  $i$  番目のモデルに対する形状の一貫性指標とする． $ModelH_i[j]$  を  $i$  番目のモデルの  $j$  ( $1 \leq j \leq 12$ ) 番目の色相値， $ObjH[j]$  を対象領域の  $j$  番目の色相値とする．すると，最終的な指標  $eval_i$  は両者の重み付き和である式 (2.10) で記述される．

$$eval_i = ObjG_i - w \cdot \left( \sum_{j=1}^{12} ModelH_i[j] \cdot ObjH_i[j] \right) \quad (2.10)$$

## 2.2 注視点戦略に基づく段階的なセンサ解析

注視点戦略は入力センサに依存するため定式化することは困難であるが，一般的には図 2.13 に示すように低コストで概略を認識可能なセンサを先に用い，その結果を用いて高コストで詳細な解析が可能なセンサの解析範囲を拘束するのがよい．本研究では，手の位置・姿勢・指の形状及び掌の圧力分布が計測可能なデータグローブと，空間の 3 次元距離データと色画像を計測可能なステレオ視覚装置をセンサとして使用し，まずデータグローブが取る時空間上の軌跡を注視個所に設定する．次にそのデータを用いて把持区間を特定し，同時に把持プリミティブ及び動作プリミティブの推定を行う．次いで把持を行った位置及び動作が行われた位置の近傍を注視個所とし，その情報からステレオ視覚装置のデータの解析範囲を拘束して，距離データ及び色画像上でその場所を探索することにより把持物体と相互作用対象物体の推



定を行う [68] .

### 2.2.1 データグローブの解析

前節で定義された把持プリミティブ及び動作プリミティブをデータグローブから得られるデータに適用し、動作が行われている区間と動作を構成する基本プリミティブの同時推定を試みる。

手の動作解析の結果から、表 2.13 に示すように、検出された”行為（動作プリミティブの組み合わせ）”・把持プリミティブ・使用された手・発生および終了時間・位置および姿勢の情報が時系列に沿って得られる。Priority の低い項は、ロボットが作業を再現する際にモデルの全ての条件を満たすことができなかつた場合に無視される項を表す。一連の動作から 2.13 の情報が  $N$  個検出されたとし、 $i$  番目に検出された情報を  $State_i$  と表すと、この時点での作業モデルは  $\{State_i | 1 \leq i \leq N\}$  と表される。

### 2.2.2 ステレオ視覚装置の解析

前節の手の動作の解析により、作業は  $\{State_i | 1 \leq i \leq N\}$  と記述された（ただし、 $State_i$  は表 2.13 の情報で構成される）。しかし、この情報からは手のシンボリックな動作は分かるものの操作対象となる物体に関する情報は分からない。そのため次に、環境中の物体の中のどの物体が操作されたのかを認識する。

表 2.13: データグループのデータより検出された作業の情報

Attribute	Priority	Description
Behavior	3(high)	Combination of the action primitives
Grasp primitive	1	One of the grasp primitiveives
Hand	2	Right, Left or Both
$t_s$	1	Absolute start time
$t_e$	1	Absolute end time
p	1(low)	Position at the start time in the world coordinate
R		Rotation matrix at the start time in the world coordinate

操作対象の情報を知るためには視覚より得られる画像を解析する必要があるが、動作期間中の全ての視覚画像それぞれに対して画像全体を一様に解析することはたいへん非効率的である。前節の手の動作解析の場合は、入力装置から解析のために必要十分な量のデータを直接獲得できたため、効率のよい解析が可能であった。

ここで、現在注目しているのが操作対象の物体の種別であることを考えると、前節で検出された各行為  $State_i$  が操作そのものであるため、その時に操作している物体に着目すれば良いことが分かる。この時、各行為  $State_i$  が発生した時間  $State_i.t_s$  及び手の空間上の位置  $State_i.p$ ・姿勢  $State_i.R$  は既知であるため、この情報から、どの時刻の画像のどの範囲に対象物体が存在するのかを知ることができる。この時空間上の場所が注視点  $AP_i = State_i$  となる。また、把持期間中は把持物体は同一のままであるため、行為の中でも把持を表す行為にのみ着目すればよい。

具体的には、図 2.14 の上段に示すように手の動作解析中はステレオ視覚装置によってカラー画像・距離データ  $image(t)$  を連続的に記録しておく（段階 1）。その後、手の動作の解析結果から作業モデルが生成され注視個所  $AP_i$  が決定されると、まずその注視個所が把持動作を表すか否かを判定し、把持動作の場合には記憶装置から把持開始時点より  $t_{offset}$  時間前の画像  $image(AP_i.t_s - t_{offset})$  を取り出す。 $t_{offset}$  時間前の動作を見るのは、把持の瞬間の直前の画像を見ることにより手によって隠蔽されていない物体の画像を得るためである。

次に、把持を行う手の位置と姿勢は  $AP_i.p$ ,  $AP_i.R$  より既知であるため、把持物体は手固有の座標系において手の腹側の  $grasp_{offset}$  の位置にあるとして、把持物体の位置  $P_{obj}$  を推定する。これを変換行列  ${}^C T$  によってカメラ座標系に変換し ( ${}^C P_{obj}$ )。画像上の  ${}^C P_{obj}$  を中心として把持物体の認識を行う。下にこのアルゴリズムを示す。

$i = 1$

**repeat**

if  $AP_i.behavior == grasping$  then

$$P_{obj} = AP_i.R grasp_{offset} + AP_i.p$$

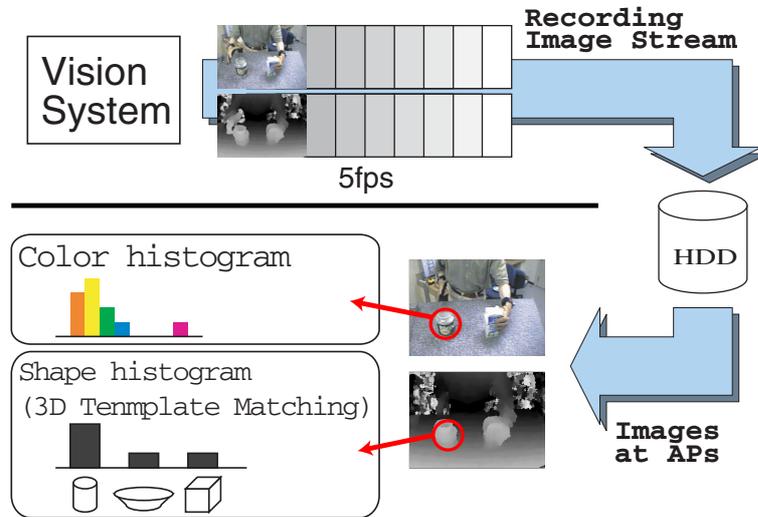


図 2.14: ステレオ視覚を用いた注視点解析

```

 $C_{P_{obj}} = C_{TP_{obj}}$ 
analyze image( $AP_i.ts - t_{offest}$ ) at  $C_{P_{obj}}$ 
endif
until  $i \leq N$ 

```

### 2.2.3 動作再現例

最後に、本章で述べた手法の妥当性を示すために、2.1.2.4 節の動作プリミティブを段階 1 における手の動作認識に適用し、段階 2 の物体プリミティブに基づく把持物体の認識結果と組み合わせて、実ロボットによる人間作業の認識・モデル化および再現を行った実験例を示す。この実験において、人間は以下の手順で教示を行った。

1. 容器 A を左手でつかむ
2. 容器 B を右手でつかむ
3. 容器 B の中身を容器 A の中に注ぐ
4. 容器 B を離す
5. 容器 A を離す

ロボットはその作業を観察し，前述の方法にしたがって作業モデルを構築する．次に，その作業モデルにしたがってロボットが同じ動作の再現を行が，モデルの優先度の効果を確認するために，人間の実演教示時とは若干異なる環境で再現動作を行い作業モデルの有効性を検証した．

### 2.2.3.1 教示動作の認識

解析の1段階目では，システムは両手の動作を同時に解析し統合することで，(1)左手把持 (GRIP),(2)右手把持 (GRIP),(3)右手注ぎ (POUR), (4)右手離し (RELEASE), (5)左手離し (RELEASE) の順に動作を認識することができた．GARBAGE モデルが適切に有意動作間の不定動作を吸収したため，図 2.15 の上段に示すように，時間軸に沿った離散的な行為列として作業モデルを構築できた．また，このときステレオ視覚装置によってカラー画像と距離データが 5[frame/s] の周期で連続的に記録されている．

解析の2段階目では，把持に対応する行為の開始時点を注視点とし，図 2.15 の中段に示すように記録済のカラー画像・距離データの中から注視点に該当するデータを読み込み，2.2.2 章で述べた方法によって把持物体の推定を行った．

最後に手の動作の情報と把持物体の情報を統合し，シンボリックな手の作業モデルを構築した．

### 2.2.3.2 ロボットによる人間行動の再現

次に，作業モデルの有効性を検証するために，ロボットによる作業の再現実験を行った．

ここで，作業モデルの異なる環境における適用性を検証するために，教示時には存在しなかった新しい物体（皿）をテーブル上に追加し，また物体の配置が教示の時とは異なるように物体の再配置を行った．再現時にテーブル上の物体を認識する方法として，2.2.2 節で説明した手法を用いた．

実験の結果は，ロボットが正しい物体を選択し作業を遂行できたことを示している（図 2.15 の下段）．ロボットの再現した動作を検証すると，次の2点において優先度の効果が現れていることが分かった．

- 対象物体がモデルで記述されている位置に無い場合には，ロボットは優先度の低い“Position” 項を省略し，視界全体から対象物体を探している．これは，特に似た形状の物体が複数ある場合には正しい物体を効率よく探すために有効である．
- 物体の配置が変更されたため扱うべき物体が本来扱うべき腕の操作範囲の外にきてしまう場合には，ロボットは優先度の低い“Hand” 項を省略し他方の腕を使って把持動作を行った．

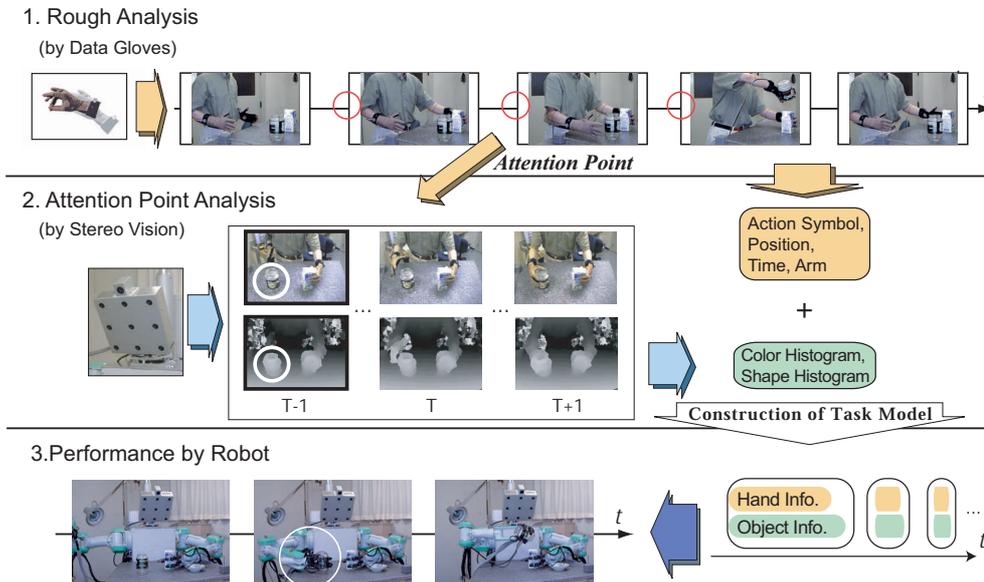


図 2.15: 教示動作の認識と再現

優先度項により「手の動作モデル(表 2.13)」毎に抽象度を変更することで、作業の達成と教示動作の再現のトレードオフを調整し作業を再現することが可能になる。

また本研究では、想定する環境が比較的単純であったため一方方向の決まった注視戦略によって基本プリミティブが同定されたが、より複雑な動作・環境の場合には、逆に後半で推定された基本プリミティブによって前半の基本プリミティブの取り得る値を拘束するなど基本プリミティブ間の拘束を利用したフィードバックによって最適な基本プリミティブの組を漸進的に求める方法が必要になると思われる。

## 第3章 複数回観察に基づく作業に固有のプリミティブの推定

本章では、獲得対象とする作業を把持物体と環境物体との相互作用の連続形として表現可能な手作業とし、(1) 把持を行う手・(2) 把持物体・(3) 対象となる環境物体・(4) 把持物体の環境物体座標系における相対軌跡の4つの属性によって動作プリミティブを表現する。すると、手作業は時間軸上に動作プリミティブが不連続に並んだ形で表現される。

動作プリミティブを獲得するためには、実演された教示動作の観察結果から作業の遂行に本質的な相互作用を推定する必要があるが、従来の多くの解析手法には一回の観察結果のみを利用して解析を行うという問題点があった。これは、相互作用のない全身運動の獲得の場合 [24, 22] や、プリミティブ自体はあらかじめ設計され相互作用も明らかである場合 [40, 42, 36] には問題にならないが、一般に手作業の動作プリミティブを獲得する場合には (1) どの相互作用が作業の遂行に必須であるのか、(2) 把持物体とどの環境物体が相互作用を行っているのかの2点についてあいまい性があり、一回の観察結果からでは事前の知識無しにプリミティブを確定することはできない。

例えば図 3.1 の例を考えた場合、手で把持されている物体 A が環境物体 (B or C) と何らかの相互作用を行っていることは分かったとしても、どちらの物体と相互作用を行っているのかを確定することはできない。

そのため本章では、本質的には同一の作業を示す  $N$  個の異なる教示動作の観察結果を統合し、全ての教示動作に共通する相互作用を抽出することで作業に必須の動作と相互作用を行う物体ペアを同時に推定する手法を提案する。複数の教示動作の観察結果を統合する研究例としては、Dufay と Latombe らのロボットコマンドレベルでの組立作業プログラムをマルチパスグラフを使って統合する研究 [69] や、それを接触状態遷移で表された作業に適用した津田らの研究例 [42] があるが、これらは作業モデルに冗長性を持たせることが目的であり、必須相互作用を推定する本研究の目的とは異なる。

推定された各必須相互作用は  $N$  個の教示動作全てに共通する相互作用の集合であるため、 $N$  個の相互作用を保持している。本稿では、まず各相互作用毎に把持物体を3次元空間中で追跡することにより把持物体の対象物体座標系における相対軌跡を計算し、次に  $N$  個の相対軌跡を統合し汎化する手法を提案する。複数の軌跡の汎化は、Delson と West の手法 [32] を拡張し時間軸方向に正規化された  $N$  個の軌跡の平均軌跡とその分散を計算することによってなされる。平均軌跡がロボットの動作軌跡となり、分散の大きい個所は逸脱が許容される動作、

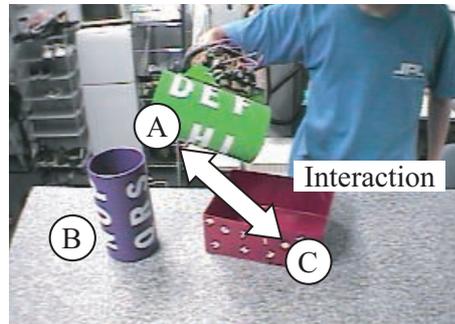


図 3.1: 相互作用の不確定性

分散の小さな個所は視覚等によるフィードバックを必要とする精度が要求される動作として模倣が可能である。また、教示後に一般的な状況において動作認識を行う場合には、教示時と比較して動作の確率的な変動が大きくなることが予想されるため、 $N$  個の相対軌跡から隠れマルコフモデルを生成しこれを認識に用いることで、確率的な変動に強い動作の認識器を生成する。

作業モデル構築の手順は以下の通りになる。

1. 多次元 DP matching により複数の実演教示の観察結果を統合することで作業に必須の相互作用を自動獲得する  
 必須相互作用区間以外は、必須相互作用区間同士を結ぶための過渡的な区間とみなす  
 また、この必須相互作用は作業に固有の動作プリミティブと見ることができ、作業モデルを構築するための構成要素となる。
2. 各必須相互作用区間について、統合テンプレートマッチング法に基づき環境物体座標系における把持物体の運動軌跡を 3 次元追跡により獲得する
3. ロボットによる動作の模倣を実現するために、各必須相互作用区間に対応する複数の相対軌跡を統合し、平均軌跡とその分散によってモデル化する
4. 時空間上の確率変動に強い隠れマルコフモデルを用いて必須相互作用区間の相対軌跡をモデル化することにより、動作の認識器として用いることを可能にする

以降の節では、まず動作プリミティブ表現とそれによって構成される作業モデルについて説明し、次いで単一の観察結果を利用することの問題点を指摘して複数の観察結果を統合することで作業を遂行する上で必須の相互作用を自動抽出する方法について述べる。さらに、相対軌跡を求めロボットによる動作再現と動作認識のための汎化を行う方法について述べる。

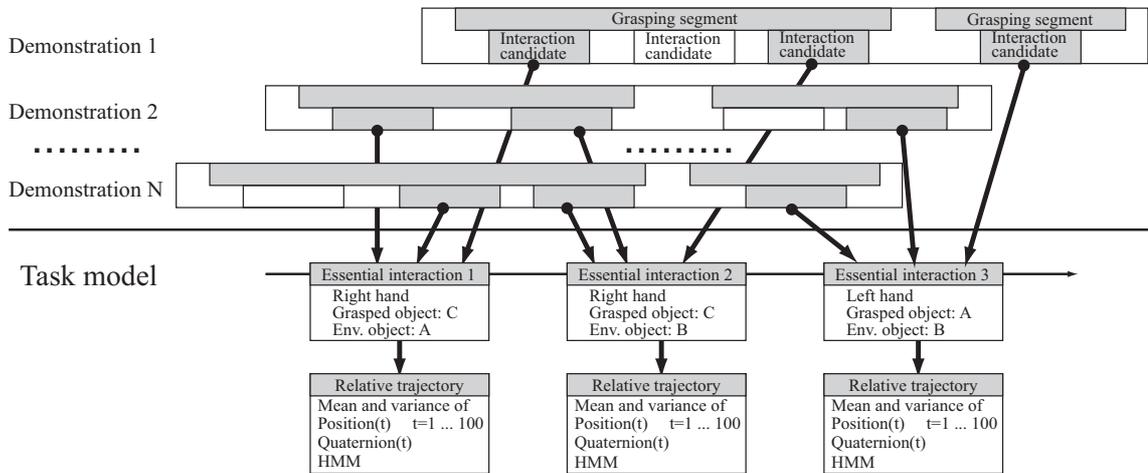


図 3.2: 必須相互作用 (プリミティブ) と作業モデル

### 3.1 プリミティブと作業モデルの表現

本稿では、静的な把持のみを扱い把持物体と環境物体との相互作用のみを対象とする。この仮定より作業モデルは図 3.2 のように表される。

$N$  回の実演動作はデータグローブとステレオ視覚装置を用いて解析され、把持区間中に分布する動作のまとめり (後述) が相互作用区間の候補群 (Interaction candidate) として抽出される。各相互作用候補は、(1) 把持を行う手・(2) 把持物体・(3) 対象物体 3 つの属性を保持している。

把持物体は、把持を行った瞬間に手の位置と最も近い場所にある環境物体とし、環境中の物体は、把持区間の直前に環境全体を探索し 3 次元プレートマッチング (3DTM) 法 [67] をもとにした同定手法 [70] をステレオ視覚装置の出力に適用することで同定される。同定に必要な環境物体の形状・色モデルは、実物体を元に CAD を使用して生成した。

次に、全教示動作 (Demonstration 1 - Demonstration  $N$ ) にわたって同じ属性を持ち同じ順序で現れる相互作用候補を探索する。この相互作用候補は、表現の異なる教示動作全てにわたって共通して出現するため、作業を達成する上で必要な動作である可能性が高い。そのため、このような相互作用を必須相互作用と定義し全ての必須相互作用を抽出する。

そして、図 3.2 下段に示すように各必須相互作用毎に対応する把持物体の  $N$  個の相対軌跡を計算し、各軌跡を時間方向に正規化し平均軌跡及び分散軌跡を計算することにより  $N$  個の軌跡を汎化する。この平均軌跡がロボットによる再現動作の目標軌道に変換される。また同時に、 $N$  個の軌跡から隠れマルコフモデルを生成し、把持物体・対象物体・隠れマルコフモデルの 3 つの要素によって認識器を構成する。

## 3.2 複数観察結果の統合

### 3.2.1 複数観察の必要性

従来の組み立て作業の獲得を扱った研究 [40, 42, 36] では、作業の達成に必須の動作を抽出する方法を手と把持物体もしくは把持物体と環境物体との接触を検出することに頼っていた。しかし、作業の過程において作業の目的とは直接関係のない接触が偶発的もしくは付随的に生じる場合や、直接的な接触を伴わない作業の場合には、検出された接触状態から作業に本質的な動作を確定することはできない。

また日常動作のように必ずしも接触を伴わない作業を対象とし、手の動作の情報と操作対象物体の情報を段階的に統合することで作業モデルを生成する手法が提案されている [70]。この手法では作業ドメインに現れ得る手の基本動作をあらかじめ隠れマルコフモデルを用いて学習しておき、データグローブを用いたジェスチャー認識によって教示者の手の動きのセグメンテーションと基本動作の認識を同時に行っている。この時、学習外の動作を吸収する garbage モデルを組み込むことで、有意な動作が行われている個所のみを選択的に抽出するスポットィング認識を可能にしているが、有意な動作間の遷移過程を表す動きが必ずしも garbage モデルにおいて最大事後確率を取る保証が無く、また基本動作を表すモデルの事後確率が対象動作が必須であるか否かの直接の指標にはならないことから、必須相互作用のみを検出することはできない。

この問題は単一の観察結果に内在するあいまい性に起因しており、このあいまい性を事前の知識無しに解消する目的で、複数の観察結果を相互比較し統合する方法を提案する。

### 3.2.2 複数観察結果の統合方法

まず、本質的には同一の作業を表す教示動作を  $N$  回実行しそれを記録する。ここで本質的に同一とは、作業の目的を達成するために必須の把持物体・環境物体間の相互作用が決まった形態・順序で現れるものと定義する。この時、必須ではない相互作用が任意の順番で現れることは許す。すると、各教示動作は必須相互作用を内包した相互作用の連続形として表現することができる。

前述の理由から単一の観察結果には解析する上であいまい性が存在するため、そこから必須相互作用のみを抽出することは困難である。そこで、教示動作を複数回行う際に、必須相互作用に影響を与えずに環境もしくは教示動作自体を毎回若干変化させる。すると、必須相互作用は同じであるが、それ以外の相互作用については教示動作によって異なる観察結果を得ることができる。

次に、複数の観察結果を相互比較し、全ての観察結果に共通する相互作用を抽出することで必須の相互作用を推定する。相互比較を行う方法として、多次元 DP (Dynamic Programming) Matching [71] を用いる。

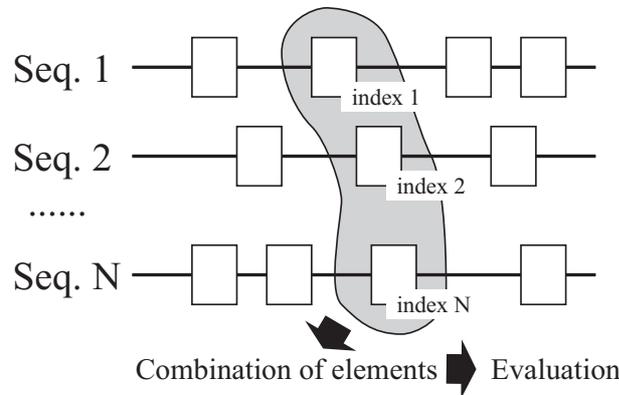


図 3.3: 要素に分割された観察結果

複数の要素配列を統合し共通因子の抽出を行う多次元 DP Matching は、DNA 解析など生物学の分野で積極的に研究されてきた [71]。規模の小さな問題に対しては、2次元 DP Matching を単純に  $N$  次元に拡張した手法が適用できるが、計算コストのオーダーが  $O(2^k N^k)$ <sup>1</sup> であるため、多数の長い配列の統合に用いるのは実用的ではない。規模の大きい問題に対しては、準最適解を求める近似方法として、2次元 DP Matching の可能な組み合わせによる拘束から探索範囲の最小化を図る方法、一致度を表す木を使用し漸進的に 2次元 DP Matching を用いる手法が存在する。

本研究の場合は、把持区間毎に複数の観察結果を統合するため、比較的小規模な要素配列の統合問題に帰着できる。そのため、2次元 DP Matching を単純に  $N$  次元に拡張した手法を用いる。

### 3.2.3 多次元 DP Matching を用いた必須相互作用の推定

図 3.3 に示すように各観測結果を要素配列  $Seq_i (1 \leq i \leq N)$  の形で表現した時に、DP Matching を適用するには任意の要素の組み合わせ  $(Seq_1[index_1], \dots, Seq_N[index_N])$  の一致度を評価する関数  $E(index_1, \dots, index_N)$  を作成する必要がある。ここで、要素は検出された相互作用候補を指す。

$G(index_1, \dots, index_N)$  を、その要素の組み合わせに至るまでの評価値の重み付き和とすると、以下の漸化式によって最適パスつまり最適な対応を計算することができる。すなわち、計算された最適パスが経由する要素の組み合わせが推定された必須相互作用である。

$$G(index_1, \dots, index_N) = E(index_1, \dots, index_N) \cdot \text{path}(ii, \text{index})/2 +$$

<sup>1</sup> $N$  は配列数,  $k$  は配列内の要素数

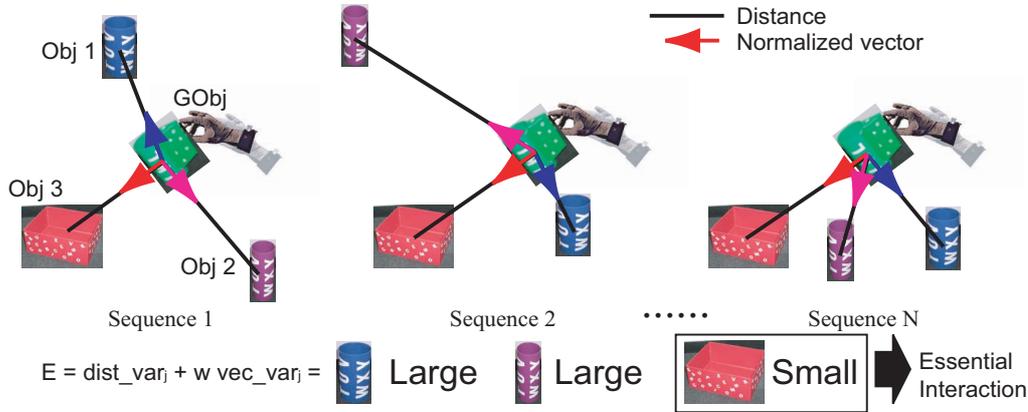


図 3.4: 必須相互作用の評価

$$\min\{\cup[G(ii_1, \dots, ii_N) + E(ii_1, \dots, ii_N) \cdot \text{path}(ii, \text{index})/2] \mid \text{index}_1 - S \leq ii_1 < \text{index}_1, \dots, \text{index}_N - S \leq ii_N < \text{index}_N\}$$

ただし、 $\text{path}(ii, \text{index})$  は現在の格子点  $\text{index}$  から探索対象の格子点  $ii$  までの距離 ( $\sqrt{\sum_{k=1}^N (\text{index}_k - ii_k)^2}$ ) を表し、探索範囲内の連続した必須相互作用が縮退することを防ぐ役割を持つ。また、(1) ある要素が 2 回以上他の配列の要素と一致することを許さない、(2) 探索範囲を  $N^S$  の格子とする、との 2 つの拘束条件を設定する。前者は、必須相互作用が他の必須相互作用と重なって検出されないための条件である。後者の  $S$  は、必須相互作用間に入り得る必須ではない相互作用の数を規定するものである。 $S - 2$  が連続する必須ではない相互作用の数よりも少ないと、必須ではない相互作用が必須であると誤検出され、逆に  $S$  を大きくした場合には計算コストが増大する。各教示動作を見た時に最大の相互作用候補数に合わせるのが最も安全である。

### 3.2.4 DP Matching における評価関数

本稿では、把持物体と環境物体との相互作用の検出を目的としており、ある要素の組み合わせにおいて把持物体とある環境物体との相対関係が全ての要素に渡って一致している時に、その環境物体と把持物体が必須の相互作用をしている（評価関数  $E(\text{index}_1, \dots, \text{index}_N)$  が低い値を返す）とする。

ここで相対関係とは、図 3.4 に示すように把持物体  $GObj$  からある環境物体  $Obj_j$  までの距離  $\text{dist}_i(GObj, Obj_j)$  及び、把持物体からその環境物体へ向けた正規化ベクトル  $\text{vec}_i(GObj, Obj_j)$  によって規定され、両者の標準偏差 (式 (3.1), (3.2)) の重み付和の最小値をもって評価値とする。

$$\begin{aligned} dist\_mean_j &= \frac{\sum_{i=1}^N dist_i(GObj, Obj_j)}{N} \\ dist\_dev_j &= \sqrt{\frac{\sum_{i=1}^N [dist_i(GObj, Obj_j) - dist\_mean_j]^2}{N}} \end{aligned} \quad (3.1)$$

$$\begin{aligned} vec\_mean_j &= \text{normalize} \left( \sum_{i=1}^N vec_i(GObj, Obj_j) \right) \\ vec\_dev_j &= \sum_{i=1}^N [1.0 - vec_i(GObj, Obj_j) \cdot vec\_mean_j] \end{aligned} \quad (3.2)$$

評価関数  $E$  のアルゴリズムは下記のように表される .

```

function evaluationFunction: real;
var dev1, dev2, ..., devnumber_of_objects: real;
var i,k: integer;
begin
  k := 1;
  repeat
    devk := dist_devj + w · vec_devj;
  until k ≤ number_of_objects;
  evaluationFunction := mink{devk | 1 ≤ k ≤ number_of_objects};
end;

```

ただし  $w$  は重みを示す定数であり, 本研究では両者のバランスがとれるように経験的に定めた .

図 3.4 の例では, 把持物体と  $Obj_3$  との関係 ( $GObj, Obj_3$ ) は全ての教示動作を通してほぼ同一である . そのため, 評価関数  $E$  ではこの関係 ( $GObj, Obj_3$ ) を表す重み付き分散和  $dev_3$  が他の関係のものとは比べて最小となるため, この値を評価値として返す . この関係 ( $GObj, Obj_3$ ) が相互作用候補となり, この評価値が小さい程これが必須動作である確率が高くなるが, 最終的には DP マッチングの結果によってどの相互作用候補が必須であるのかが決定される . 逆に, もし評価関数  $E$  が小さい値を返さない場合には, ( $GObj, Obj_i$ ) ( $1 \leq i \leq 3$ ) はいずれも必須相互作用では無いと予想することができる .

### 3.2.5 必須相互作用区間の推定実験

#### 3.2.5.1 相互作用区間候補推定に関する実験条件

本実験では、データグローブの掌に分布した触覚センサの平均圧力がある閾値以上である区間を把持区間とし、時間軸上で連続する把持物体位置の分散がある閾値以下の区間を相互作用候補区間とした。後者の仮定は、環境物体は通常静止しているためそれと相互作用を行う把持物体の動きは環境物体の直近の空間に限定されることと、これは教示動作であるため教示の核となる相互作用区間では観察者（ロボット）が理解しやすいように教示動作の速度を落とすことが期待されることから設定された。ただし、手を大きく動かすことが本質的に重要である作業、例えばハンマーで叩くといった予備動作を要する動作・雑巾でテーブル面を拭くといった広範囲の移動を要する動作は対象外であり、対象となるのは、容器の中身を注ぐ・蓋を開ける・攪拌する・すくうといった動作である。

この制限は、例えば周期性のある連続動作や直角に曲るなど不自然な軌跡を通る動作を検出する機構を追加することで緩和できるが、本実験の目的は相互作用候補中から必須相互作用を推定することにあるため、実装上の容易さから前述の検出方法を採用した。

また、獲得対象とする作業として「注ぐ」「すくう」「攪拌」動作を選択した。

#### 3.2.5.2 必須相互作用候補の決定

本研究では把持物体と環境物体との相互作用を対象としており、相互作用を推定するためにはまず全作業区間  $1 \leq t \leq T$  の中から把持を行っている区間を抽出する必要がある。

把持区間の推定については、データグローブの掌に分布している  $N$  個の触覚センサの時系列情報  $tactile[T][N]$  を用い、接触面積の推定値が閾値  $GRASPING\_THRESHOLD$  以上の時に物体を把持していると見なす。このことから、下記のアルゴリズムによって把持の開始時点・終了時点が分かる。

```

function segmentGrasping: real;
input tactile[T][N]: real;
output grasping_segment[]: real;
var ave[T]: real;
begin
  t := 0;
  repeat
    ave[t] :=  $(\sum_{i=1}^N tactile[t][i]) / N$ ;
    t := t + 1;
  until t ≤ T;
  grasping_segment[] = labelling tactile[] where ave[] > GRASP.THRESHOLD;

```

**end;**

そこで、相互作用区間において把持物体の平均移動速さは有意に小さいとし、隣接する  $N_s$  点の分散がある閾値よりも小さい区間をヒステリシス閾値法によって抽出し相互作用の候補区間とする。時刻  $t$  での位置を 3 次元ベクトル  $p[t]$  とすると、その時刻を中心とした隣接する  $N_s$  点の分散  $var[t]$  を計算する。分散が大きいということは移動量が大きいということを意味するため、相互作用ではなく過渡的な状態であると見なす。

次に、全体で各分散  $var[t]$  が閾値 `MOVE_LOW_THRESHOLD` より小さい個所 *moving\_segment* をセグメンテーションし、不連続領域を結合するために  $N_a$  フレーム分の拡大・縮小処理を行う。最後に、セグメントの境界が `MOVE_HIGH_THRESHOLD` 以下の区間を除外する。

アルゴリズムは下記の通りになる。 $N_s$  と  $N_a$  は経験的に決定し、それぞれ 3 と 3 とした。

```

function segmentMoving: real;
input p[T]: real[3];
output moving_segment[]: bool;
var ave, var: real[3];
begin
  t := 0;
  repeat
    ave[t] := ( $\sum_{i=1}^{N_s} p[t-N_s/2+i]$ ) /  $N_s$ ;
    var[t] := ( $\sum_{i=1}^{N_s} (p[t-N_s/2+i] - ave) \cdot (p[t-N_s/2+i] - ave)$ ) /  $N_s$ ;
    t := t + 1;
  until t ≤ T;
  moving_segment[] = labelling p[] where var[] > MOVE_LOW_THRESHOLD;
  expand moving_segment[] by  $N_a$ 
  shrink moving_segment[] by  $N_a$ 
  trim moving_segment[] under MOVE_HIGH_THRESHOLD
end;

```

### 3.2.5.3 必須相互作用区間の推定例

まず、人間の教示者が若干異なった表現で 5 回の教示を行う。この作業の本質は、図 3.5 に示すように容器 A の中身を容器 B に注ぎ、次に容器 A の中身を容器 C に注ぐことである。個々の教示動作の違いは、物体の配置や必須動作と関係のない手の動きにある。

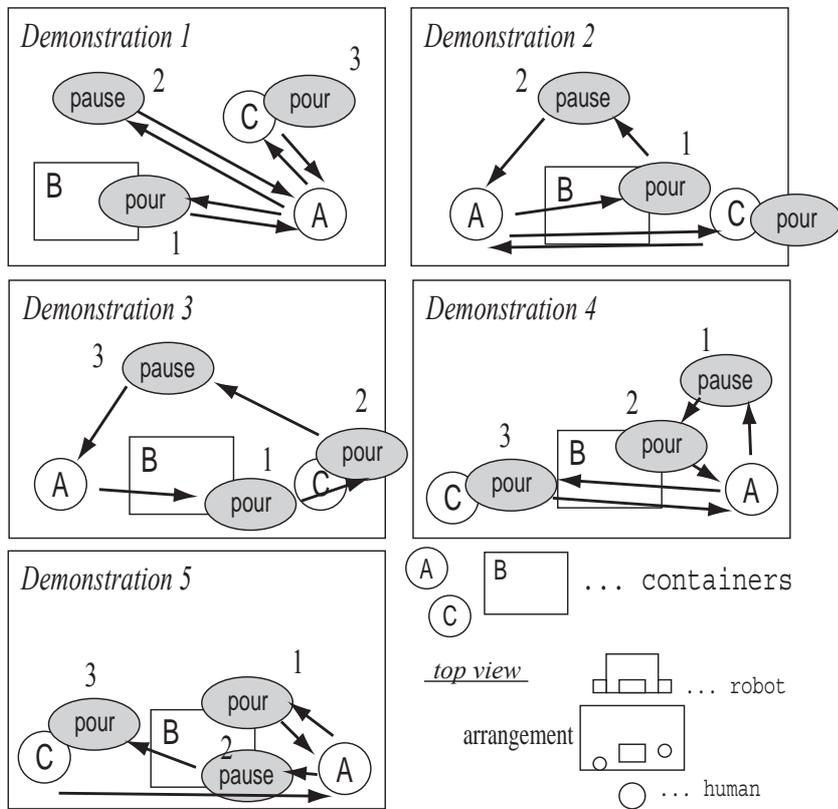


図 3.5: 複数の教示動作

図 3.5 で pause とあるのは、作業の過程において結果的に手の移動速度が閾値を下回ったため相互作用として誤検出されたことを表す。

表 3.1 と表 3.2 に示すのが、5つの教示動作の内1番目と4番目のものについて、把持物体(図 3.5 の A) とその他の2つの環境物体(図 3.5 の B と C) との相対関係を解析し、相互作用の候補区間を検出した結果である。ただし、ベクトルは長さが1に正規化されている。

図 3.6 は、4番目の教示動作について把持を行う手の静的な状態を検出することで相互作用候補を推定した結果を示す。図中の小さな球は非把持区間を、白球は相互作用候補区間を、灰色球はそれ以外の区間を示す。この初期のセグメンテーションから、相互作用候補が推定される(図 3.7 中の細い線の四角)。この中から必須ではない候補を取り除くため、本章で述べた手法を用いて必須相互作用を獲得する(図 3.7 中の太い線で囲まれた四角)。本実験では、結果的に必須相互作用間に連続して含まれる必須ではない相互作用の数は最大で3つであった。従って  $S$  は5以上である必要があり、本実験では  $S = 5, 6, 7$  の3通りについて検証を行った結果、いずれの場合でも次に示す同じ結果が得られたことを確認した。検出されたのは計4つの必

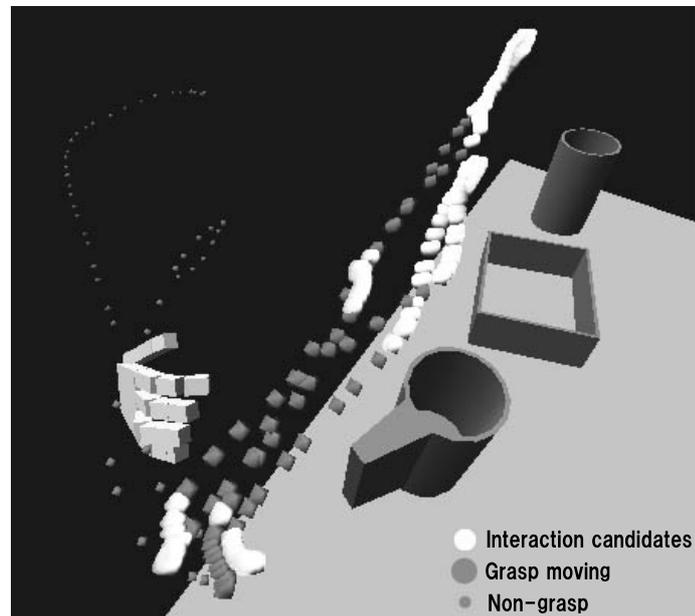


図 3.6: 相互作用候補の抽出

表 3.1: 把持物体と環境物体との相対関係 (教示動作 1)

Objects		1	2	3	4	5	6	7
B	Normalized vector	0.991	0.779	0.988	0.365	0.984	0.883	0.981
		-0.088	0.194	-0.057	0.539	-0.033	0.277	-0.038
	Distance [mm]	604	231	691	336	683	548	680
C	Normalized vector	0.845	-0.872	0.913	-0.736	0.917	0.646	0.908
		-0.533	-0.287	-0.393	0.253	-0.360	0.243	-0.371
	Distance [mm]	291	197	362	311	348	204	347

須相互作用であり，最初と最後は把持動作及び離す動作に対応するため，真の必須相互作用は 2 番目と 3 番目の動作である．これは 2 回の注ぐ動作に対応する．この 4 つの相互作用は適切なパラメータを伴い作業モデルに格納される．

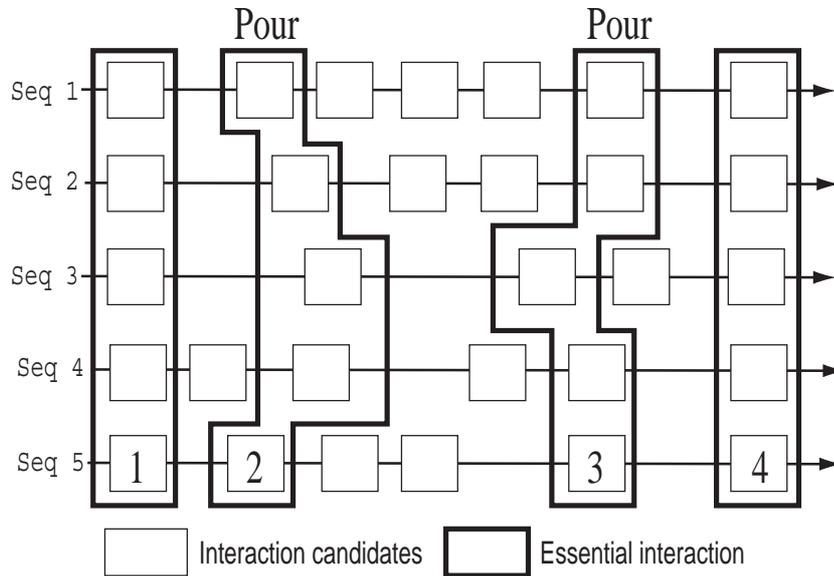


図 3.7: 多次元 DP matching による統合結果

表 3.2: 把持物体と環境物体との相対関係 (教示動作 4)

Objects		1	2	3	4	5	6
B	Normalized	0.999	0.958	0.999	0.967	0.652	0.997
	vector	0.015	0.229	0.015	0.064	0.307	0.042
		0.010	-0.168	-0.020	-0.245	-0.692	-0.055
	Distance [mm]	655	470	718	463	212	673
C	Normalized	0.988	0.680	0.984	0.663	-0.583	0.966
	vector	-0.008	0.408	-0.004	0.069	0.195	0.038
		-0.149	-0.607	-0.176	-0.745	-0.788	-0.252
	Distance [mm]	367	233	432	235	264	393

### 3.3 必須相互作用の汎化

#### 3.3.1 相対軌跡

動作プリミティブで模倣を表現するために、把持物体の軌跡の情報を導入する。軌跡の情報は、教示環境とは異なる環境においても使用可能なように対象物体の座標系 ( $T$  で表す) における把持物体の相対軌跡として表され、時間軸方向に並んだ位置と姿勢のペア ( ${}^T p_G(t), {}^T q_G(t)$ )

で表現される． ${}^T p_G(t)$  は  $1 \times 3$  の位置ベクトルであり， ${}^T q_G(t)$  は式 (3.3) に示すように  $1 \times 4$  の 4 元数 (quaternion) ベクトルである．

$${}^T q_G(t) = \left( \sin \left( \frac{\theta(t)}{2} \right) {}^T n(t), \cos \left( \frac{\theta(t)}{2} \right) \right)^t \quad (3.3)$$

quaternion は，単位方向ベクトル  ${}^T n(t)$  回りに角度  $\theta(t)$  だけ回転することを表す．通常の 3 次元の表現と比較して値域に不連続面が無いことが特徴である．

### 3.3.2 3次元追跡による軌跡の推定

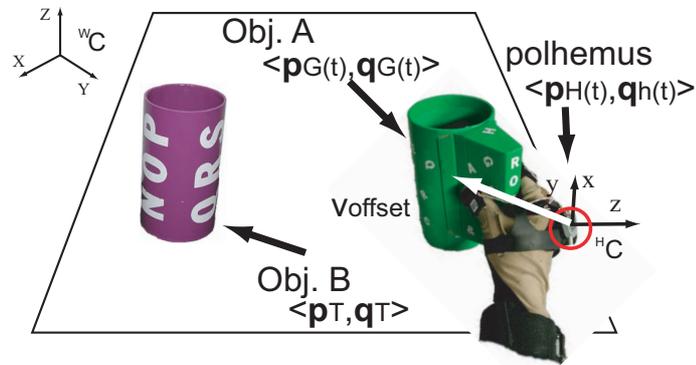


図 3.8: データグローブからの運動軌跡の推定

把持を行う手の大まかな位置と姿勢 ( $p_H(t), q_H(t)$ ) は，図 3.8 に示すようにデータグローブより既知である．静的な把持を仮定しているため，グローブ座標系で定数オフセットベクトルを加算することにより把持物体の大まかな位置と姿勢 ( $p_G(t), q_G(t)$ ) を推定することができる．そこで，前節で推定された各必須相互作用区間について，各フレーム毎に ( $p_G(t), q_G(t)$ ) を初期姿勢とし，観察時にデータグローブからのデータ取得と同期してステレオ視覚装置より獲得された色画像と距離データに対して 2.1.3.4 章で述べた統合テンプレートマッチング法 (CTM) を適用することで，把持物体の真の位置と姿勢 ( $p_{G'}(t), q_{G'}(t)$ ) の連続推定を行う．推定された軌跡は対象物体の座標系で表された相対軌跡に変換され，動作プリミティブに格納される．相互作用の対象となる物体の姿勢 ( $p_T, q_T$ ) は既に求めてあるため，相対軌跡は式 (3.4) に従って求められる．

$$\begin{aligned} {}^T p_{G'}(t) &= q_T^{-1} \cdot (p_{G'}(t) - p_T) \\ {}^T q_{G'}(t) &= q_T^{-1} \cdot q_{G'}(t) \end{aligned} \quad (3.4)$$

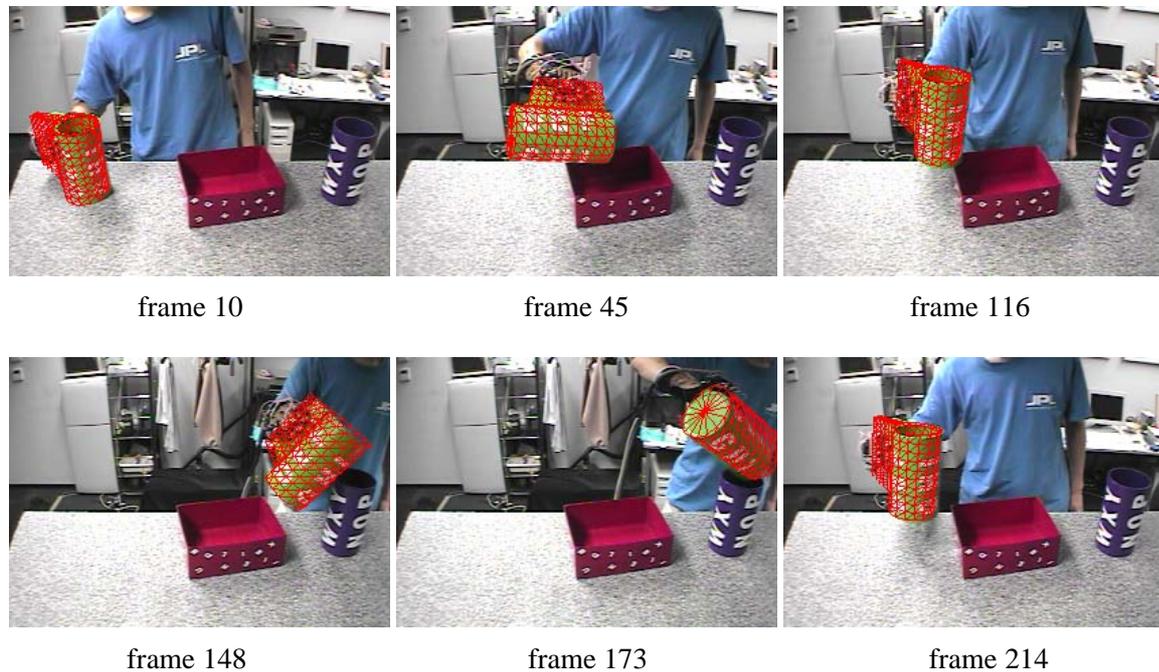


図 3.9: 把持物体の 3 次元追跡 (カラー画像上)

視覚データが十分短い時間間隔で記録されている場合、隣接するフレームの画像間での把持物体の移動量は、本推定手法の収束範囲に入ることが期待されるため、上記のループを把持期間が終わるまでの間繰り返すことによって把持物体の位置と姿勢の 3 次元軌跡を推定することが可能になる。

本実験では、サンプル周期を約 30 [frame/sec] として視覚データの記録を行った。図 3.9 と図 3.10 に示すのは、図 3.5 の Demonstration 5 の把持期間全般にわたって 3 次元追跡を行った結果である。図 3.9 がカラー画像上に把持物体のメッシュモデルを投影したもので、図 3.10 が同じ時刻で距離データ (視差画像) 像上に把持物体のメッシュモデルを投影したものである。位置・姿勢を含めて精度良く追従できていることが分かる。

なお図 3.10 において背景の画像が無いのは、時刻  $t$  において処理対象領域を  $t-1$  時の位置の周辺に限定することで、精度を落とさず処理速度を向上させるためである。本実験での 3 次元追跡はオフラインで行われるため処理速度向上のメリットはないが、4 節で必要となる視覚系を駆動しながらの実時間 3 次元追跡の場合には重要になる。

画像の下の数字は、その相互作用の開始時点からの経過フレーム数を表す。獲得された軌跡は対象物体の座標系で表された相対軌跡に変換され、動作プリミティブに格納される。

動作プリミティブ自体は教示動作から自動的に獲得される作業ドメインに固有のプリミティブであるため、人間が手動で設計した 2 章での動作プリミティブと比較して、無駄なく作業

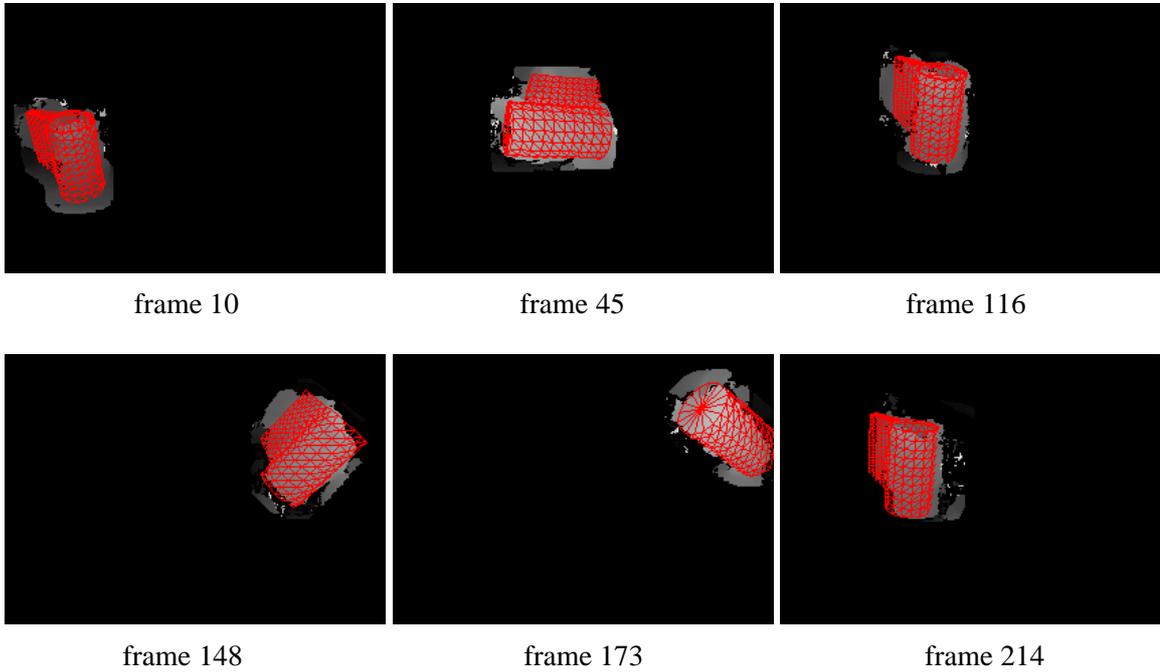


図 3.10: 把持物体の 3 次元追跡 (距離データ上)

に本質的な動作をモデル化しているという特徴がある。

### 3.3.3 模倣のための相対軌跡の汎化

3次元追跡処理の結果, 各必須相互作用について対応する  $N$  個の軌跡  $\langle {}^T \mathbf{p}_{G'n}(t), {}^T \mathbf{q}_{G'n}(t) \rangle$  ( $1 \leq n \leq N$ ) が獲得された。これらの軌跡を汎化するために, 全ての軌跡の平均軌跡とその分散軌跡を計算する。軌跡の長さは各々異なるため, まず全体が一定長 (ここでは 100 単位) となるように元の軌跡を補間して時間方向に正規化する。

平均  $\langle {}^T \mathbf{p}_{G'm}(t), {}^T \mathbf{q}_{G'm}(t) \rangle$  と分散  $\langle {}^T \mathbf{p}_{G'v}(t), {}^T \mathbf{q}_{G'v}(t) \rangle$  は, 式 (3.5) に従って計算される。

$$\begin{aligned} {}^T \mathbf{p}_{G'm}(t) &= \left( \sum_{n=1}^N {}^T \mathbf{p}_{G'n}(t) \right) / N \\ {}^T \mathbf{q}_{G'm}(t) &= \text{meanQuaternion}() \end{aligned} \quad (3.5)$$

**function** meanQuaternion: real[4];

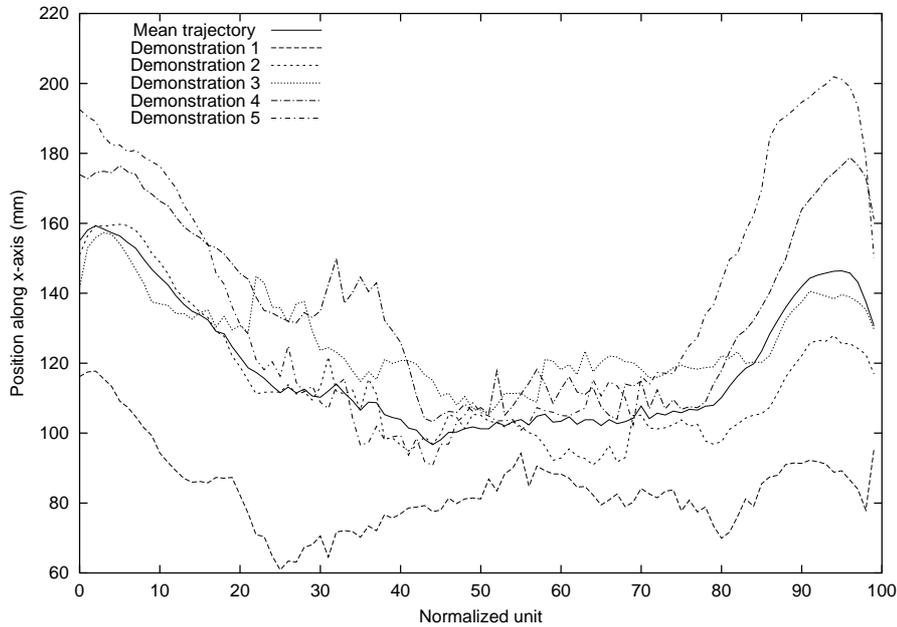


図 3.11: 平均軌跡の x 軸成分

```

var i: integer;
var quat: real[4];
begin
  quat :=  $^T q_{G'1}(t)$ ;
  i := 2;
  repeat
    quat := interiorDivision( 1.0 / (i+1), quat,  $^T q_{G'i}(t)$  );
  until i ≤ number_of_demonstrations;
  meanQuaternion := quat;
end;

```

2つの quaternion の内分を計算する関数 `interiorDivision` は, *ratio* と 2つの quaternion  $q_1$  と  $q_2$  の合計 3つの引数を取り, 相対姿勢  $q_{rel} = q_2 \cdot q_1^{-1}$  を計算して,  $q_{rel}$  を 2つの quaternion の積  $q_{rot} \cdot q_{trans}$  に分解する. この時,  $q_{trans}$  が 2つの quaternion の任意の軸 (ここでは x 軸とした) を最小の角度で一致させる回転を表し,  $q_{rot}$  は  $q_{trans} \cdot q_1$  座標系でのその軸回りの回転を表す. すると,  $q_{trans}$  の回転軸と  $q_{rot}$  の回転軸は直交するため, 内分は  $q_{rot'} \cdot q_{trans'}$  と計算される. ただし,  $q_{rot'}$  は  $q_{rot}$  の回転角度を *ratio* 倍したものであり,  $q_{trans'}$  は  $q_{trans}$  の回転角

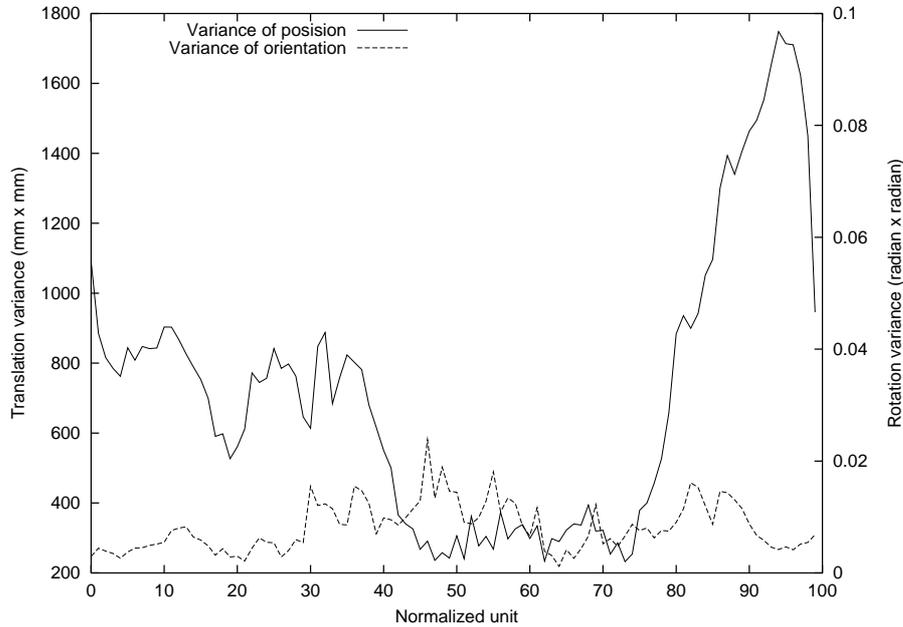


図 3.12: 汎化された軌跡の分散

度を *ratio* 倍したものである。

分散軌跡は式 (3.6) のように表される。

$$\begin{aligned}
 {}^T p_{G'v}(t) &= \left( \sum_{n=1}^N \| {}^T \mathbf{p}_{G'n}(t) - {}^T \mathbf{p}_{G'm}(t) \|^2 \right) / N \\
 {}^T q_{G'v}(t) &= \left( \sum_{n=1}^N \text{get\_angle}({}^T \mathbf{q}_{G'n}(t) \cdot {}^T \mathbf{q}_{G'm}(t)^{-1})^2 \right) / N
 \end{aligned} \tag{3.6}$$

ただし, `get_angle` は指定された quaternion の回転角度を返す関数である。

ロボットによる動作再現時には, 生成された把持物体の平均相対軌跡を再現するようにロボットアームの姿勢が決定される。また, 再現動作は教示動作の所要時間の平均になるようにサンプリングし直される。

図 3.11 は, 容器 A から容器 B への注ぐ動作に対応する 5 つの相対軌跡の平均を求めることで汎化を行った結果である。図 3.12 は, 平均軌跡の分散を表す。グラフより, 平均軌跡の分散は時間軸方向に見て中間の区間が両端区間と比較して有意に小さいことが分かる。これは, 中間区間 (45 から 75 正規化フレーム) の軌跡が複数の教示動作においてほぼ同一の軌跡を取ったことを意味し, 精密な動作の必要性を暗示している。平均と分散軌跡の情報は, スケーリングパラメータと共に作業モデルに格納される。

### 3.3.4 重複する動作プリミティブのクラスタリング

また実際には、ある作業ドメイン中の様々な作業について前述の手法を繰り返すことにより、その作業ドメインに固有の動作プリミティブが多数生成されるが、このとき動作プリミティブには重複するものが出てくるため、同じ把持物体・対象物体ペアを持つ動作プリミティブが独立となるように平均軌跡の差異を指標にクラスタリングを行い統合処理を行う。

ここでは、各集合毎に分割数未知のクラスタリングを行う。各相対軌跡のサンプル数は正規化されており等しいため、ある集合に属するプリミティブ同士で相対軌跡の差をサンプル数分積分した値を指標とし、この値がある閾値以下の動作プリミティブは統合して新たな動作プリミティブとするという処理を新たな動作プリミティブが生成されなくなるまで繰り返すことによって、重複する動作プリミティブを統合することが可能になる。

このとき閾値の決め方が問題となるが、教示においては同一の動作を示す動作プリミティブの軌跡はほぼ同一であるため、本研究ではある時点で差の積分値の最小値が、2番目に小さな差の積分値の1/10以下の場合にクラスタリングを継続するように動的に閾値を決定する。



図 3.13: 動作プリミティブの統合

図 3.13 に示す 3 通りの動作プリミティブの相対軌跡を比較した結果が、図 3.14 左と図 3.14 右である。

上記のクラスタリングにより 2 番目と 3 番目の動作プリミティブが統合され、その時点で終了条件を満たすためクラスタリングは終了する。

### 3.3.5 認識器の生成

この時点で、各独立な動作プリミティブはクラスタリングの結果に応じて複数の相対軌跡の集合として構成される。この時、ロボットに動作の模倣を行わせる目的で前節では平均軌跡とその分散軌跡を計算したが、この情報をそのまま動作の認識に使用することは適当ではない。なぜなら、教示を目的としない一般の動作を認識する場合、(1) 動作プリミティブの平均軌跡と比較して動作が時空間上で変動しやすい、(2) 各動作が明確に分離されず複数の動作

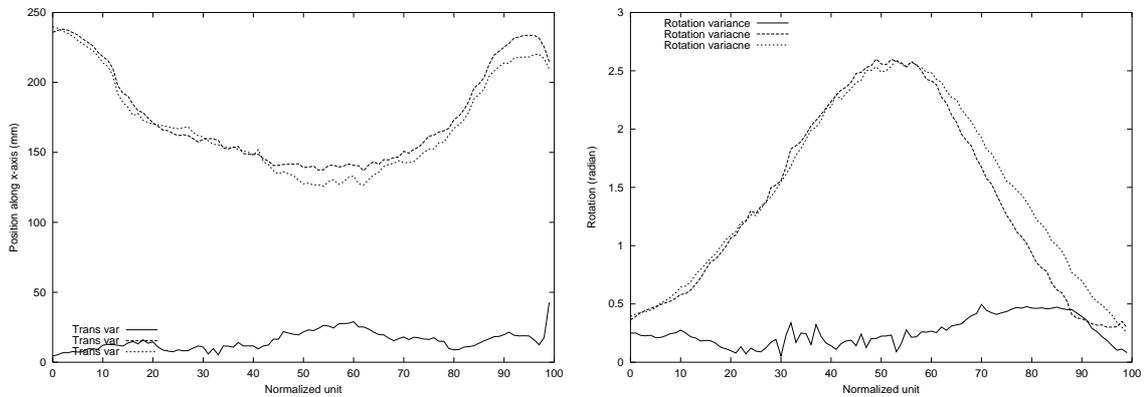


図 3.14: (左)動作プリミティブの軌跡の差の併進成分, (右)動作プリミティブの軌跡の差の回転成分

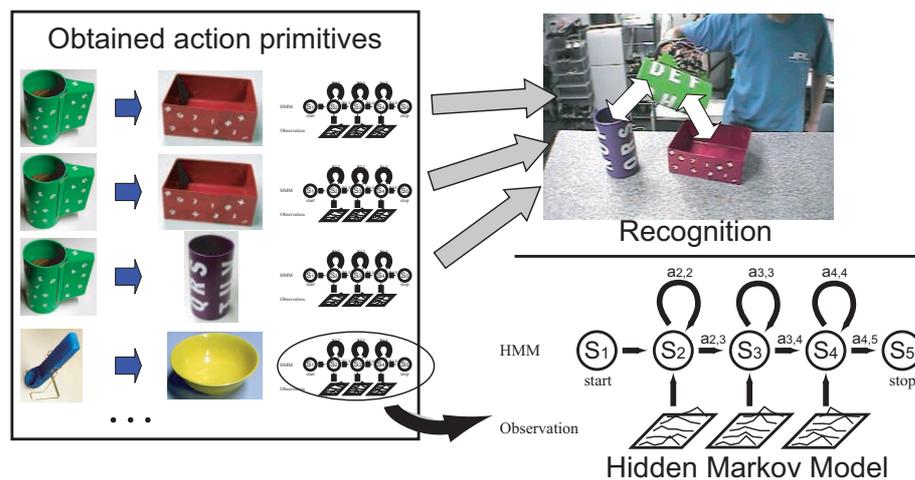


図 3.15: 隠れマルコフモデルによる動作認識

プリミティブが連続する場合があるといった2点に対処する必要があるからである。

本研究では、不確定な時系列のデータをモデル化するために有効な統計的手法であり、セグメンテーションされていない連続データの認識に使用することのできる隠れマルコフモデル [23] を用いて各動作プリミティブの相対軌跡をモデル化することにより、上の2つの問題を同時に解決し認識器を構成する方法を提案する。

ここでは、図 3.15 右下のような単純5状態隠れマルコフモデルを設定し、相対軌跡（位置3自由度と姿勢4自由度）の7自由度を入力として各動作プリミティブ毎に学習を行った。この結果、図 3.15 左のように把持物体・対象物体・隠れマルコフモデルの3つの要素で構成さ

れる動作プリミティブが生成される。

学習後に図 3.15 右上に示す動作を認識するときには，図 3.15 右上における把持物体と全ての環境物体のペアの相対軌跡  $\text{trajectory}_i$  について，同じ物体ペアを持つ動作プリミティブの隠れマルコフモデル  $\text{HMM}_j$  を適用し，最も事後確率  $p(\text{HMM}_j|\text{trajectory}_i)$  の高いものを対応する動作プリミティブとして採用する．図の場合は，把持物体と右側の環境物体について 2 つ該当する動作プリミティブがあり，把持物体と左側の環境物体について 1 つ該当する動作プリミティブがあるため，計 3 つの動作プリミティブについて事後確率を計算する．

ただし，対象動作が未獲得の場合にも既存のいずれかの動作プリミティブが選択されてしまうため，対象動作のモデルの有無を判定する必要がある．一般的には事後確率を何らかの閾値で判定する方法が用いられ，本研究では次の手順で閾値を定める．

各動作プリミティブの隠れマルコフモデル  $\text{HMM}_j$  に対して，その学習に用いた相対軌跡  $\text{trajectory}_i$  の対数事後確率  $\log(p(\text{HMM}_j|\text{trajectory}_i))$  を計算する．各相対軌跡は同じ動作を表現しているため，得られる対数事後確率も大体同じ場所に分布することが期待される．ここで知りたいのはこの分布の幅であるので，分布をガウス分布で近似し，動作プリミティブ毎に平均と分散  $(\mu_i, \sigma_i)$  を計算し分布を推定する．この分布を同じグラフの上に重ね合わせたものを図 3.16 に示す．認識時の最大対数事後確率が，該当する分布の外にある場合は，対応する動作プリミティブがないと判定する．分布の幅の判定基準として，本研究では  $\mu_i \pm 3\sigma_i$  を用いた．

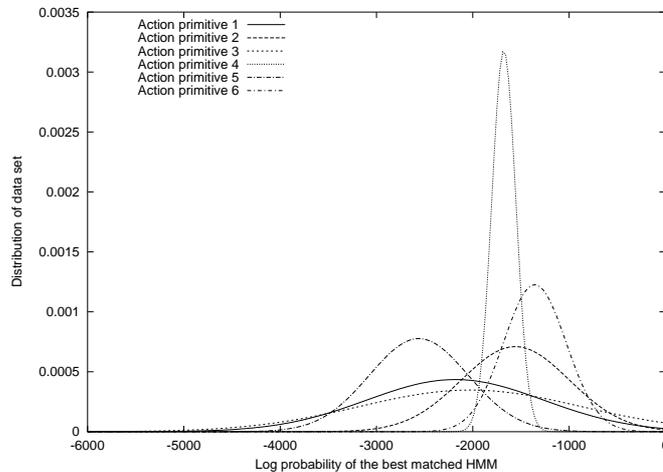


図 3.16: 学習に用いたサンプルの隠れマルコフによる対数事後確率の分布

## 第4章 再観察に基づく失敗回避動作の生成

前章までは、複数の観察結果を統合して、あいまい性を低減しつつ作業モデルをどう構築していけばよいのかについて述べた。この作業モデル中では、把持物体と環境物体との相互作用が重要となる個所について、ロボットが把持物体を操作するための参照用に、実演教示の際の環境物体座標系での把持物体の軌跡を記述した。

この作業モデルに従ってロボットが作業を再現する場合、特に参照軌跡に従って把持物体のマニピュレーションを行う区間において、次に示すいくつかの要因によって作業に失敗する可能性がある。

1. 観察データの誤差
2. 作業実行時の外乱
3. 本質的にセンサフィードバックが必要

本研究では1と2の要因に着目し、これらをそれぞれ独立に補償する仕組みを提案し、作業の獲得・再現の枠組みの系を補間する方法について述べる [72]。

3に関しては、作業モデルにスキル [38] 等を導入する必要があるが、本論文ではスキルレベルの話は扱わず詳細は [54] にゆずる。

### 4.1 観察データの誤差の補償

センサによるデータ取得時において、何らかの誤差によってデータが正しく教示動作を反映してない場合について考える。誤差の要因としては、(1) センサの精度が必要精度に足りていない、(2) センサ情報の解釈時の誤差、(3) センサ座標系から内部座標系への変換（キャリブレーション）誤差等が考えられる。

本研究では、観測データとして環境物体座標系で表現した把持物体の運動軌跡を扱う。データ取得の手順は、まずステレオ視覚によって対象物のカラー画像・距離データを獲得し、初期状態では物体はテーブル上に置かれているとの条件から初期位置・姿勢を算出し、次に対象物の3次元追跡を行う。対象物の3次元追跡は、 $t-1$  フレームでの対象物の位置・姿勢が分かっていると、 $t-1$  フレームでの位置・姿勢を初期値として、 $t$  フレームでの位置・姿勢を

2.1.3.4 節で紹介した位置と姿勢のロバスト推定法を用いた収束計算によって推定する．連続的にカラー画像及び距離データを獲得し処理することで3次元追跡を可能にする．

この軌跡を獲得する時点では，人間の教示動作がどのように行われるのかが未知であるため，両手動作を対象とする場合は少なくとも両手がどのような挙動を示すのかを同時に観察する必要があり，そのため視覚センサの計測範囲が可変である場合には計測範囲を人間が動作を行う領域全体に広げる必要がある．しかし，一般に視覚の計測範囲と解像度にはトレードオフの関係があり，従来の一回の観察に基づいて教示動作を理解する研究においては，視覚系において特定のトレードオフを選択する必要があった．

本章では，センサのパラメータを変更して動作の再観察を行うことによって，うまくトレードオフを回避し精度のよい教示データを獲得する方法について述べる．

#### 4.1.1 センサのパラメータの変更に基づく教示動作の再観察

滝沢らは，移動ロボットのゴール到達可能性を評価する方法として，経路上の通過可能性が不確かな領域のうちロボットの経路計画上重要と考えられる領域を注視・ズームして再観測することによって，重要な領域を選択的に精密化する手法を提案した [73]．彼らの環境では観察対象が変化しないため，一回目の観察結果と2回目の観察結果を直接比較・統合することにより，大域的なデータと局所的なデータの対応を正確に評価することが可能であり，大域的データの欠落部分を局所観察によって補うことが可能であった．

本研究では，同様にステレオ視覚のズーム比率を2倍に変更することで対象の選択的な精緻化を行うが，対象が動作であるため，1回目と2回目の観察において観察結果は一致しない．また，2回目においては計測範囲が狭くなるため，空間を移動する一連の動作を固定された視覚装置で計測することは不可能である．動作全体を追跡するためには，視覚装置自体を同時に駆動し対象が常に計測範囲内に収まるようにする必要があり，視覚系が非定常的に駆動されている時に，センサ座標系とロボット座標系との対応を厳密に取ることは困難である．

そのため本研究では，(1) 測定精度のよい2回目の観測結果にのみ着目する．また作業モデル構築時において，把持物体と対象物体との相互作用が行われる区間は空間の局所的な個所で生じる，言い換えると環境物体が静止している場合相互作用中は把持物体が比較的静止した状態にあると見做せるため，(2) 精度が要求される相互作用区間において視覚系はサンプリング周期と比較して十分低速に駆動していると仮定する．

#### 4.1.2 再観察の手順

前述の条件の下に以下の手順で再観察を行う．

##### 1. 作業モデルを生成

前章までに説明した通り，ズーム比率を1倍として観察に基づき作業モデルを生成する．

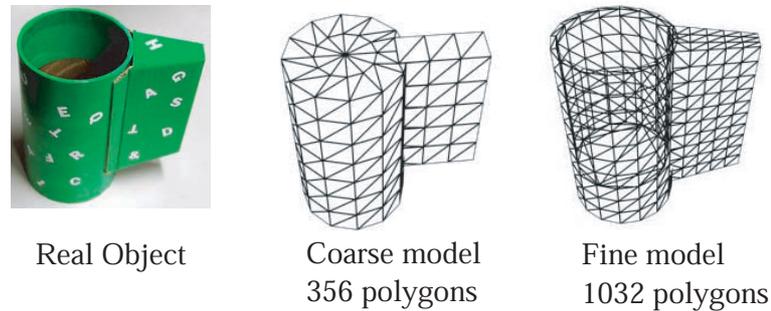


図 4.1: 把持物体のカラー画像と 3 次元幾何モデル

この時、図 4.1 に示すように、粗いモデル（図 4.1 中）と精緻なモデル（図 4.1 右）を生成しておく。この時点では、軌道の推定はオフラインで行うため、2.1.3.4 節で述べた統合テンプレートマッチング法を精緻なモデルを使用して適用する。

## 2. 再観察個所の決定

ロボットによる再現動作を人間が観察し、動作が不安定な個所を明示的に指定する。

## 3. 再観察

ズーム比率を 2 倍にして、指定された動作の再観察を行う。この時は、対象が追跡中常に測定範囲内にあるように視覚装置のパン・チルト角を実時間で駆動する必要がある。そのためは、動作速度と比較して対象物の大まかな位置と姿勢を十分早く推定する必要がある。以下では、(1) 視覚データの実時間処理による追跡と (2) データグローブの 3 次元位置センサの情報をそのまま利用した追跡の 2 通りの方法の結果を述べる。

視覚データの実時間処理による追跡では、この時点では厳密な推定を行う必要はないため、粗いモデル（図 4.1 中）を統合テンプレートマッチング法で用いる。

3 次元位置センサの情報をを用いる場合は、画像取得タイミングにほぼ同期して手の位置と姿勢が推定できるため、そこから把持物体の大まかな位置を推定することができる。ただし、把持物体の姿勢に関しての情報が無いため、次で述べるオフラインでの追跡処理が必須となる。

またこの時、次のオフライン処理のために、パン・チルト角度及び得られたカラー画像・距離データを記憶装置上に連続的に記録しておく。

## 4. 再観察結果の評価

一連の動作が終了すると、記録されたカラー画像・距離データを読み込みオフラインで運動軌跡の推定を行う。この時には、実時間で処理を行う必要がないため、精緻なモデ

ル（図 4.1 右）を使用して統合テンプレートマッチング法を適用し 3 次元追跡を行う。

表 4.1: 再観察の手順

	Zoom	Model	Time	Description
1	x1	Fine	0.6s	Extraction of APs
2	x2	Coarse	1.4s	Tracking the object online
3	x2	Fine	2.0s	Tracking the object off-line

### 4.1.3 再観察の結果

図 4.2, 図 4.3, 図 4.4 に、注ぎ動作に対して 3 次元追跡を試みた結果を示す。



図 4.2: 3 次元追跡 (x1 zoom, 精緻なモデル)

図 4.2 は、ズーム比率を 1 倍とし精緻なモデルで追跡を行った結果である。

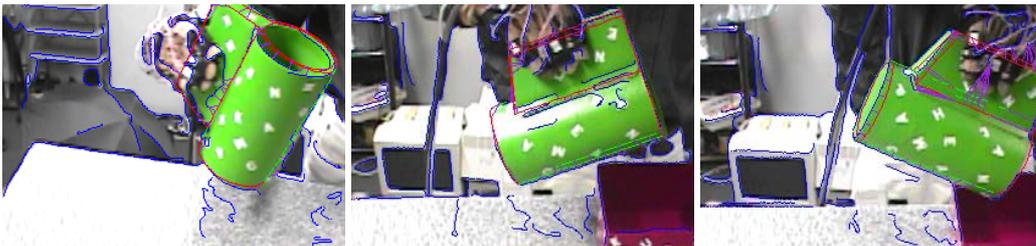


図 4.3: 3 次元追跡 (x2 zoom, 粗いモデル)

図 4.3 は、ズーム比率を 2 倍とし粗いモデルで追跡を行った結果である。この場合、ズーム比率を 1 倍の時と比べて図に示すように測定範囲の面積が 1/4 となっている。そのため、視覚

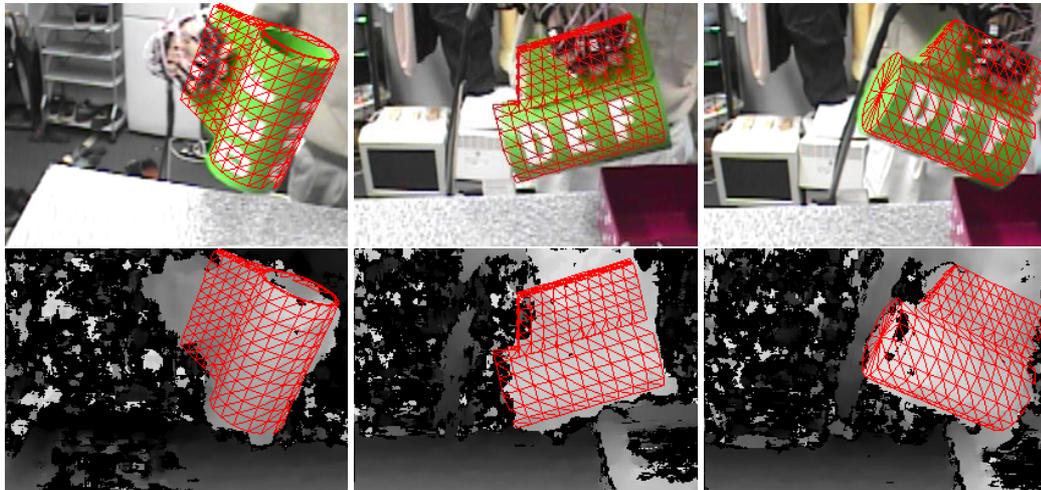


図 4.4: 3次元追跡 (x2 zoom, 精緻なモデル)

装置を固定した場合にこの動作例では容易に把持物体が測定範囲の外に出てしまう．そのため追跡処理を行うのと同時に，推定された把持物体の位置が常に画面の中央に来るように視覚装置のパン/チルト駆動系にフィードバックをかけ，動作全区間について追跡を可能にした．

図 4.4 は，図 4.3 で得られたカラー画像・距離データに対して，オフラインで精緻なモデル

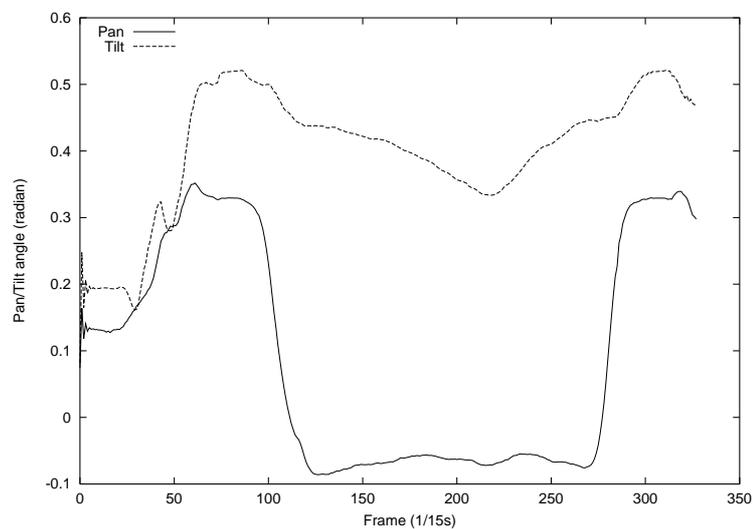


図 4.5: 視覚系のパン・チルト角速度の局所性

を使用し把持物体の運動軌跡の精密な推定を行った結果である。

しかし、サンプリング周期が  $1/15$  [frame/sec] であるため、この周期に対して駆動系十分高速に動いている場合には、駆動系と視覚系の同期誤差・サンプリング系でのループ遅延などの誤差が累積し、カメラ座標系を正確に世界座標系に変換できない。

しかし、ここで正確な値が欲しいのは相互作用区間であり、図 4.5 に示すパン角度とチルト角度のプロファイルを見ると分かるように、相互作用区間 ( $120 \leq frame \leq 270$ ) ではどちらの角速度も十分小さいと言える。そのため、把持物体の位置と姿勢の評価はこの区間内のみにおいて行うとする。

#### 4.1.4 評価

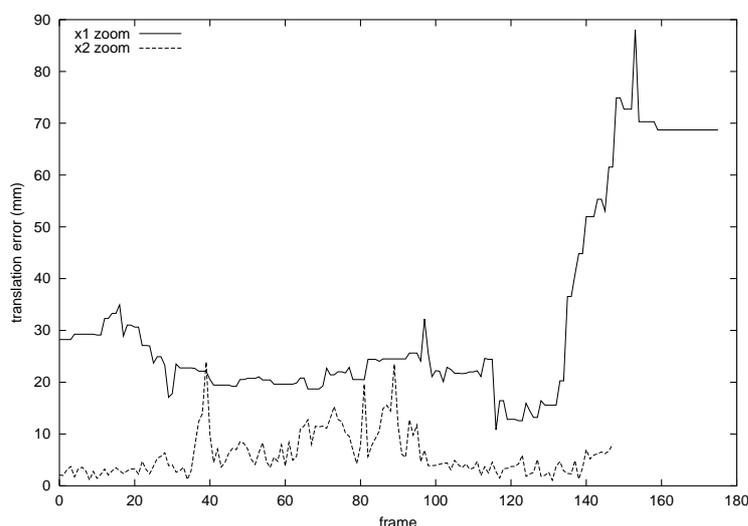


図 4.6: 軌跡の並進成分の誤差

図 4.6 と図 4.7 に、ズーム比率  $x1$  の場合とズーム比率  $x2$  の場合それぞれについて、推定運動軌跡の真の値からの誤差をグラフにしたものを示す。ここで真の軌跡は、獲得画像に対して手作業で初期値を設定したものに 2.1.3.4 節の手法を適用して算出した。グラフに描かれている軌跡はほぼ図 4.5 の相互作用区間に該当する。なお、ズーム比率  $x1$  の時とズーム比率  $x2$  の時のデータは、軌跡がそもそも一致しないうえ長さも異なるので、グラフには便宜上並べて描いたが時間軸方向の対応はとれていない。

図 4.2 と図 4.3 に、ズーム比率  $x1$  及びズーム比率  $x2$  の時に誤差の統計を示す。これを見ると並進誤差についてはズーム比率  $x2$  の方が区間一様にわたって有意に小さいことが分かる。しかし回転誤差についてはほぼ同じであり、ズームの精度とは別の項が支配的であることが

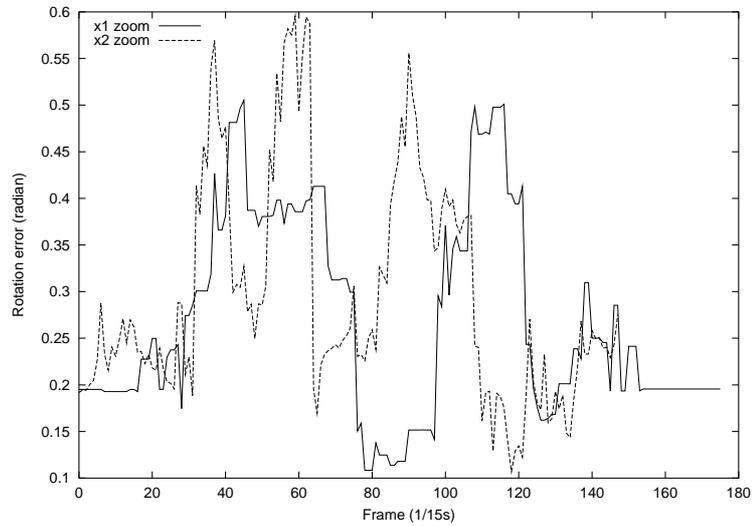


図 4.7: 軌跡の回転成分の誤差

表 4.2: ズーム比率 x1 の時の誤差

	x	y	z	dist	angle
Mean	-1.7	-25.5	18.3	32.1	0.27
Std. deviation	4.1	17.1	9.2	18.9	0.11

表 4.3: ズーム比率 x2 の時の誤差

	x	y	z	dist	angle
Mean	2.1	-0.1	4.4	6.0	0.30
Std. deviation	4.4	1.3	2.9	4.2	0.12

分かる。これはステレオ処理の精度の問題であり、一般にステレオ処理の結果は物体の境界部が膨らむ傾向にあるため、幾何形状の特徴がステレオの精度と比較して小さい場合には必ず一定の誤差が乗る。

## 4.2 作業実行時の外乱の補償

ロボットが物体を把持し操作をしている最中には、移動中に他の環境物体にぶつけるなどの環境との予期せぬ接触や、把持物体をテーブルの上に置く際に環境の認識誤差から予想以上の力をかけてしまうなど予期せぬ外乱が恒常的に発生し得る。把持物体の位置や姿勢は、このような予期しない外乱がハンドや把持物体に加わるとに崩れる可能性がある。特に、把持が精密把握が行われている時に外乱があると崩れやすい。このような外乱は、結果的に把持物体をハンドの中で滑らせたり、コンプライアントな指の制御をしている場合には指の把持形状を変化させる。

前章までに述べたように、本作業モデルでは相互作用を把持物体と環境物体との相対軌跡によって記述している。そのため作業を遂行するためには、各相互作用区間について把持物体の位置・姿勢が、モデルに記述されている通りの軌跡を移動しているのかどうかをチェックし、逸脱がある場合にはその場で補償を行う必要がある。

以下では、把持物体の位置・姿勢の誤差を推定する方法と、推定された誤差を使ってどのように補償動作を行うのかについて説明する。

### 4.2.1 把持物体の位置・姿勢誤差の推定

まずシステムは、視覚におけるロボットアーム投影誤差を推定する。この誤差は、ロボットアームの各関節角と視覚上でのアームの見え（位置・姿勢）との間のキャリブレーションが不正確であることが原因だが、重力によるアームのたわみや視覚駆動系の静摩擦による位置決め誤差などの要因から、厳密なキャリブレーションが難しい。

しかしここで問題となるのは、同一カメラ座標系において把持物体と環境物体との相対関係を一致させることであるため、ロボットアームのカメラ座標系における位置・姿勢が分かれば、厳密なキャリブレーションを必要とせず必要な相対関係を計算することができる。



図 4.8: カメラ座標系における腕の位置・姿勢の推定

そのためシステムは、現時点の関節角を考慮してのロボットアームの3次元幾何モデルを動的に生成し、図4.8に示すように視覚画像に投影する。これは、システムが予想する見えに対応する。しかし、前述の要因によって一般的に投影されたモデルと視覚画像上のアームの見えとの間には差がある。そこで投影されたモデルを初期位置  $\langle \mathbf{R}_A, t_A \rangle$  として2.1.3.4節の手法を使った localization によって、図4.8に示すように視覚座標系における真の位置・姿勢  $\langle \mathbf{R}_{A'}, t_{A'} \rangle$  を推定し、位置と姿勢の誤差を式(4.1)によって推定する。

$$\begin{aligned} {}^A\mathbf{R}_{A'} &= \mathbf{R}_A^{-1}\mathbf{R}_{A'} \\ {}^A t_{A'} &= \mathbf{R}_A^{-1}(t_{A'} - t_A) \end{aligned} \quad (4.1)$$

次に、システムは把持物体を視覚画像に投影する。この時、把持物体のカメラ座標系での期待位置・姿勢を  $\langle \mathbf{R}_G, t_G \rangle$  で表すと、カメラ座標系でのアームの誤差を考慮した投影点  $\langle \mathbf{R}_{G'}, t_{G'} \rangle$  は式(4.2)のように求まる。

$$\begin{aligned} {}^G\mathbf{R}_{G'} &= \mathbf{R}_G^{-1}\mathbf{R}_{G'} \\ {}^G t_{G'} &= \mathbf{R}_G^{-1}(t_{G'} - t_G) \\ \mathbf{R}_{G'} &= \mathbf{R}_G\mathbf{R}_A^{-1}\mathbf{R}_{A'} \\ t_{G'} &= \mathbf{R}_G\mathbf{R}_A^{-1}(t_{A'} - t_A) + t_G \end{aligned} \quad (4.2)$$

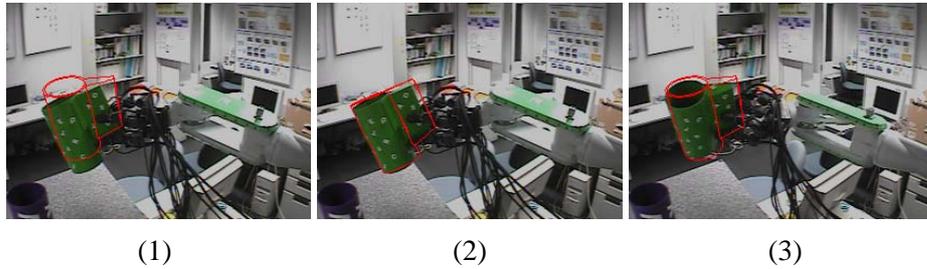


図 4.9: 把持物体の微調整:1

図4.9(1)に、 $\langle \mathbf{R}_{G'}, t_{G'} \rangle$  の位置に把持物体を投影した結果を示す。次に、先程と同様に localization によって真の位置の推定を行う。結果は、図4.9(2)に示すようになる。この差が把持の崩れを表す。



図 4.10: 把持物体の微調整:2



図 4.11: 把持物体の微調整:3

#### 4.2.2 誤差の補償動作

ここまでの過程で把持の崩れ具合を評価できたので、次にこの崩れを補償することを考える。ここではこの誤差が0になるように、ハンドの位置・姿勢に対して誤差を表す変換行列の逆行列をかけることを行う。これによってアームの姿勢が変化し、把持物体の位置と姿勢が補正される。これを行った結果が、図 4.9(3) である。

この手順を誤差の絶対値が閾値以下になるまで繰り返すことで、把持の崩れを補償することができる。図 4.10 が 2 回目の繰り返し、図 4.11 が 3 回目の繰り返しを示し、3 回目の最後において収束していることが分かる。

この処理は、各相互作用区間の最初のフレームに対して行い、作業モデルに記述されている元々のロボットハンドの位置・姿勢から、把持物体補償後のロボットハンドの位置・姿勢への変換行列を  $\langle R_e, t_e \rangle$  とすると、残りの軌跡については、各フレームにおいて軌跡にこの変換行列をかけることによって、補償済の運動軌跡を描くことが可能になる。

## 第5章 人間型ロボットプラットフォームを用いた実験例

本章では、生成された作業モデルについて説明し、新規に開発した人間型実験プラットフォームの構成を述べ、このプラットフォームを用いてこれまで述べた手法の検証を行った結果について述べる。

### 5.1 生成された作業モデル

本研究では、把持物体と対象物体との動きを伴う相互作用の連続形で表される作業の獲得・再現・認識が可能な作業モデルの枠組みを提案する。作業全体の概要を表す作業モデルは、実際には個々の相互作用を表す記述から構成され、相互作用を表す記述は、先天的に与える基本プリミティブと教示の過程で動的に獲得される動作プリミティブとの組み合わせによって構築され、これが作業の再現と認識の双方に用いられる。

相互作用を表す記述は、最終的には表 5.1 の属性によって構成される。

表 5.1: 相互作用を表す属性

Property	Description
Hand	Left or right
Grasp	Grasp primitive
Grasped object	Object primitive
Target object	Object primitive
Mean and variance of trajectory	Relative trajectory in the garget object's coordinate frame
HMM	Hidden Markkov Model

図で、Grasp, Grasped object, Target object の3つが先天的に与えられる基本プリミティブに該当し、Mean and variance of trajectory と HMM は動的に獲得される動作プリミティブに該当する。Mean and variance of trajectory はロボットによる動作再現時に使用され、HMM は動作の認識に使用される。

本研究では、「観察に基づく学習」[40]の枠組みの中で、なるべく少ない事前知識（基本プ

リミティブ)を基にして観察によって得られる教示データから作業の概略を自動的に推定する。さらに基本プリミティブのみでは推定することの困難な事象については、事象が作業に必須の場合普遍性を持つことから複数の教示データを統合し相互に比較を行うことによって推定を行う。このとき、自動検出された事象を作業に固有の動作プリミティブとして獲得することによって、認識システムが該当作業に特化したものになる。

また、軌跡の表現とシンボリックな表現の両者を取り入れた作業モデルを提案する。ここでは対象とする作業を、手によって操作される物体(把持物体)と環境物体間の相互作用の連続形で表されるとする。この時、まず全作業を把持物体と環境物体との相互作用が生じているか否かの2種類の区間にシンボリックに分解し、次に相互作用が生じている各区間について環境物体の座標系における把持物体の相対軌跡を記述する。シンボリックな表現と軌跡の表現を両方取り入れることで、異なる環境における再利用性の確保と、正確な動作の再現・動作の認識の両立を図った。

## 5.2 人間型実験プラットフォーム

ドレイファスらに批判された[74]人工知能の研究分野における”積み木の世界”の失敗例から、ロボット研究者の間でも、手と視覚が密接に関連する作業の獲得には本質的に身体性が必要であるとの観点から、人間と同構造の実証プラットフォームを系に組み込む必要性が議論されている[14, 28]。

人間型ロボットに関していうと、これまでは主に二足歩行に代表される全身のダイナミックな運動制御を実現するための研究が行われてきた。しかし、二足歩行を含めダイナミクスの技術が確立されてきた[6]。今、人間型ロボットの役割は認知モデルの検証プラットフォーム[1, 2]、もしくはより具体的なアプリケーション開発のためのプラットフォーム[10]に移りつつある。そして、近年の著しいハードウェアの進歩・新しいセンサの登場・基本的なアルゴリズムの熟成等の要因により、ツールとして使える人間型ロボットプラットフォームを容易に開発することが可能になってきた。

我々は「観察に基づく学習」の枠組みの下で、作業の実演を観察によって理解し、作業を記述した再利用性のある中間表現を獲得して対応するロボット行動を自動生成するための統一的方法を模索している。この対象の観察から認知・再現へと続く一連の過程を検証するためには、感覚系と行動系が統合された実験プラットフォームが必要となる[27]。本研究では上半身を使った手作業を対象作業としているため、システムの行動系として人間の上半身と同等の機能を持つものが望ましい。そのため、図5.1に示すような視覚・双腕を搭載した人間型ロボットプラットフォームを開発した[75]。

このロボットの主な特徴は下記の通りである。

- 視覚として、対象物の3次元認識のために9眼マルチベースライン実時間ステレオ装置及・対象物の2次元の特徴を精度よく得るためのズームカメラ・ロボットの周り全周を

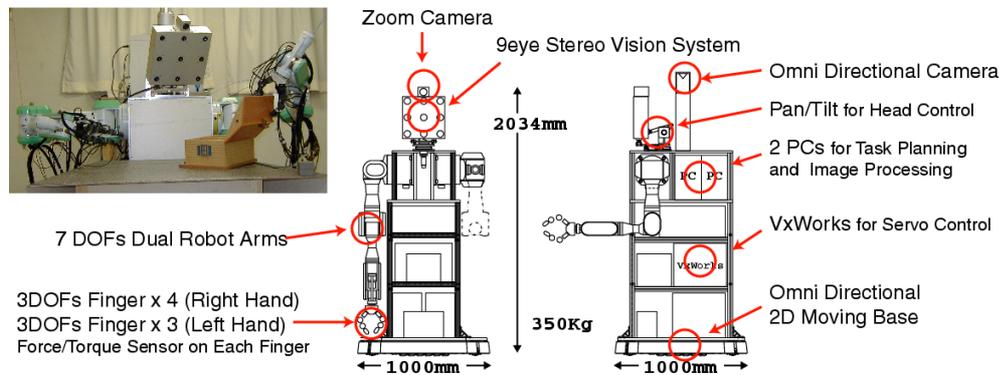


図 5.1: 実験プラットフォーム

観察するための全方位カメラを備えている。

- 腕として7自由度の多関節ロボットアームを2つ備えている。右のアームには4本指のハンドを、左のアームには3本指のハンドを装着している。一つの指は3自由度で構成され、先端に Force/Torque センサがついている。
- 視点や腕を空間内で自由に移動できるように、ロボットは全方向に移動が可能な自律台車の上に搭載されている。
- 種々の制御装置・センサをを制御するためにロボットには複数のコンピュータが搭載されているが、これらはLANで結合されCORBA[76]による通信バスによってソフトウェアの透過性が図られている。CORBAにより、分散マシン・分散OS環境で容易にソフトウェアを開発することが可能になり、データグローブといった新しい外部機器を既存のシステムの組み込むことが容易になった。

### 5.2.1 視覚系

視覚システムは人間の視覚機能を実装する。本ロボットには3種類の視覚装置が搭載されている。一つは9眼マルチベースラインステレオ視覚装置であり3次元の認識に使用される。2つめはEVI-400ズームカメラであり、様々な解像度で2次元的な認識を行う目的で搭載されている。この2つの視覚システムはロボットの頭部に装着されており、ロボットが任意の対象物を注視できるようにパン/チルトの回転駆動系によって駆動される。3つめは全方位カメラであり、ロボットの中心上方に設置されている。このカメラは人間の接近を検出し、前記2つのカメラで注視すべき対象を選択するために使用される。

## 9眼マルチベースラインステレオ視覚装置

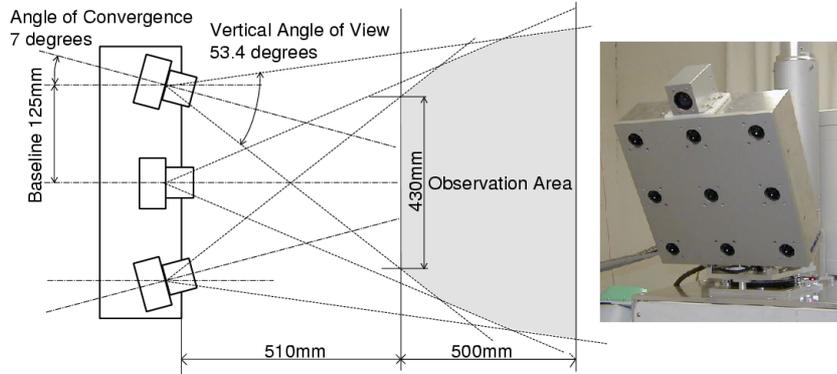


図 5.2: ステレオ装置の測定範囲

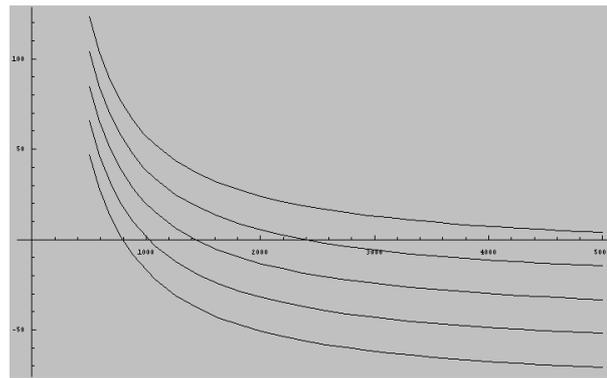


図 5.3: 視差の測定カーブ

9眼マルチベースラインステレオ視覚装置は、周囲の環境のカラー情報と距離の情報を実時間で計測するために搭載された。このシステムの内ステレオ対応を計算する部分のハードウェアはコマツ株式会社の製品 [77] であり、装置の特徴を以下に示す。

- ロバストなステレオ対応の計算

マルチベースラインアプローチ [78] によりの 8 つのステレオ対 (中央のカメラと周辺のカメラ) を歪パラメータも含めてハードウェアで同時に計算し、SSAD (Sum of Sum of Absolute Difference) 指標によって最も信頼性のあるステレオ対の視差情報を採用する。

- 実時間処理

ステレオ処理はカスタムチップの上で実行され、 $280 \times 200$  の視差マップを実時間 (15fps から最大 30fps) で出力することができる。ただし、解像度は固定である。この時、視差マップと同時に中央のカメラで同期して撮像されたカラー画像をも同時に出力できる。視差マップは中央のカメラでの視差に変換されて出力されるため、カラー画像ではレンズ歪が補正されていない事を除いて両者の座標系は一致する。

- カメラ配置の自由度

ユーザは、自由にカメラ配置を設計することが可能である。我々は、手作業の観察と再現を目的としており、必要とする測定範囲はカメラから 510 mm から 1010mm の間である。そのため、この範囲で最も密に視差マップを獲得できるように、図 5.2 に示すように外周のカメラを内側に輻輳角をつけて取りつけた。

図 5.3 にこのカメラ配置で測定し得る視差の測定カーブを示す。これは、ステレオ対応を計算する時にエピポーラ線上のどの範囲で視差を計算するのかを規定するもので、範囲の bit 数はハードウェアで決まっているため奥行き方向の位置のみを決定することができる。通常は、図の最も左側のカーブ、つまり最も近接した範囲を使用しており、この時の測定範囲が上記の 510mm から 1010mm になる。

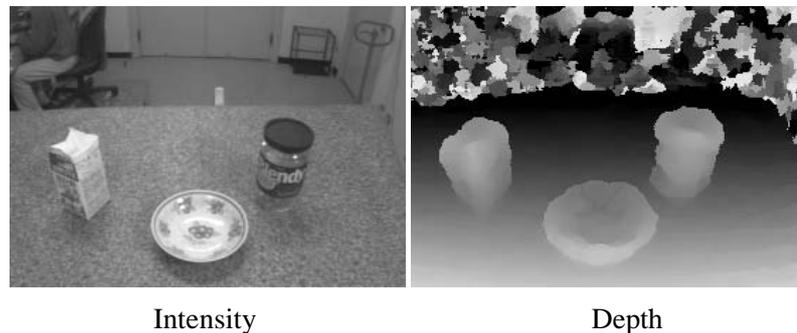


図 5.4: 輝度と距離画像 (白：近い点, 黒：遠い点)

図 5.4 に、ステレオ視覚から得られるデータの例を載せる。

### 5.2.2 アームとハンド

本ロボットには、関節自由度が 7 の既成のロボットアーム (三菱重工業製 PA10) を両側に搭載しており、肩から手首までの自由度は人間と同じになっている。

ハンドについては、有用な既成のハンドは無いため目的に応じて設計する必要がある。例えば DLR-Hand II[79] では、上腕内の空間を使用することなく、ハンドの内部に駆動系と電気系

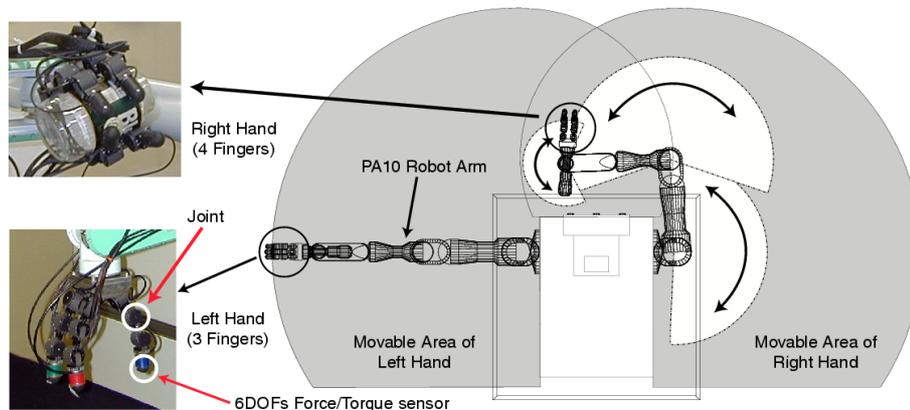


図 5.5: ロボットアームとハンドの設計

を完全に統合した，多関節・多指ハンドを開発した．他の特徴は，圧力把握と精密把握の操作形態に応じて指の基部の機構を可変にできること，位置・トルクセンサを統合していること．ハンドと外部のケーブルが 12 本で済み任意のロボットアームに装着可能なことなどである．

また梅津らは，サーボモータと制御部分が完全に独立している小型サーボモータを組み合わせ，3 本指 9 自由度のロボットハンドを設計し，フォースフィードバックを組み込んだ簡単な把持のスキルを実装している．

本ロボットも，梅津らと同じサーボモータを使用し，先端に 6 軸力トルクセンサを備えた 3 自由度の指によって構成される多指ハンドを設計した．本研究では，圧力把握及び精密把握が必要とされる把持であるため，これらを最も効率よく行えるように図 5.5 に示すように対向型の指配置とした．ただし右手は 4 本，左手は 3 本指である．

ここで人間とのスケールの差を見てみると，PA10 の肩関節 (S1,S2 軸) から手首関節 (W1, W2 軸) までの距離は 950mm となっており，人間が 450mm から 500mm 程であることを考えると 2 倍ほど長い．また，指関節も大体人間の 2 倍太いため，全体のスケールアップとして 2 倍となる．そのため，実験時には大きめの物体を選択するか，既存の物をモデラー等でコピーし倍の大きさに加工し直して実験に用いるなどの工夫をする必要がある．

### 5.2.3 体幹

ロボットの体幹の自由度は，ロボットアームや視覚の 3 次元空間での自由度を増すことに貢献する．例えば，静止物体を色々な方向から観察したい場合や，細長い机などワークエリアが大きく一度に全ての個所に到達出来ない場合に有用である．そのためホロノミックな全方向移動能力を持つ自律台車 [80] に体幹を搭載した．この台車により，ロボットは任意の並進運動と回転運動を組み合わせた移動が可能になる．

#### 5.2.4 CORBA に基づくソフトウェアアーキテクチャ

ロボットは LAN 結合された複数計算機上に分散した，複数のコンポーネントサーバによって制御される．一つ一つのコンポーネントサーバ (Component Server, 以下 CS) は，表 5.2 に示すように担当のハードウェアがあり，そのハードウェアの制御を請け負う．本ロボットでは制御すべきハードウェアが多いため，必然的に複数の計算機が混在し，かつ Linux と Windows の 2 種類の OS が混在する環境となっている．

表 5.2: ハードウェア制御のためのソフトウェアモジュール (CS)

CS	Control Devices	Functions
Audio	Speaker	Speech synthesis system
IP5000	IP5000 board	Image processing
PA10	PA10 manipulators	Calculation of inverse kinematics of the arms and Controller of the PA10 manipulators
Sensor Glove	Cyber Glove	HMM based gesture recognition
Vision	Zoom camera	Image processing by 2D Template Matching
Vision2	9-eye stereo vision	Image processing by 3D Template Matching
Viewer		Robot motion simulator
Visca	Zoom camera	Camera controller by Visca(TM) protocol
Robot	Fingers, neck, moving base	Control command generator for devices which require real-time servo control on RT Linux

これらを集中制御するのが Brain ソフトウェアであり，Brain は任意のマシンで実行され，必要とする CS とネットワーク通信を行い，センサに対応する CS で一次処理されたデータを受け取り，Brain 内部で入力処理と行動の生成を行った後，アクチュエータに対応する CS に対して制御命令を発行する．

この時，異なる計算機・異なる OS の混在する環境でそれらを意識せず統一した通信を行うための枠組みとして，分散オブジェクト技術の標準である CORBA(Common Object Request Broker Architecture)[76] を採用した．これを使うことで，インターフェースの部分を IDL (Interface Definition Language) によって依存性の無い形式で記述することができ，使用言語での実装がある場合には，リモートのプログラムをあたかも自身のプログラムの関数と同じ形式で呼び出すことが可能になる．本研究では，CORBA の実装系として，Windows と Linux 上の C++ 言語をサポートした TAO ORB [81] を採用した．

図 5.6 に，ソフトウェア的なアーキテクチャを図解した．

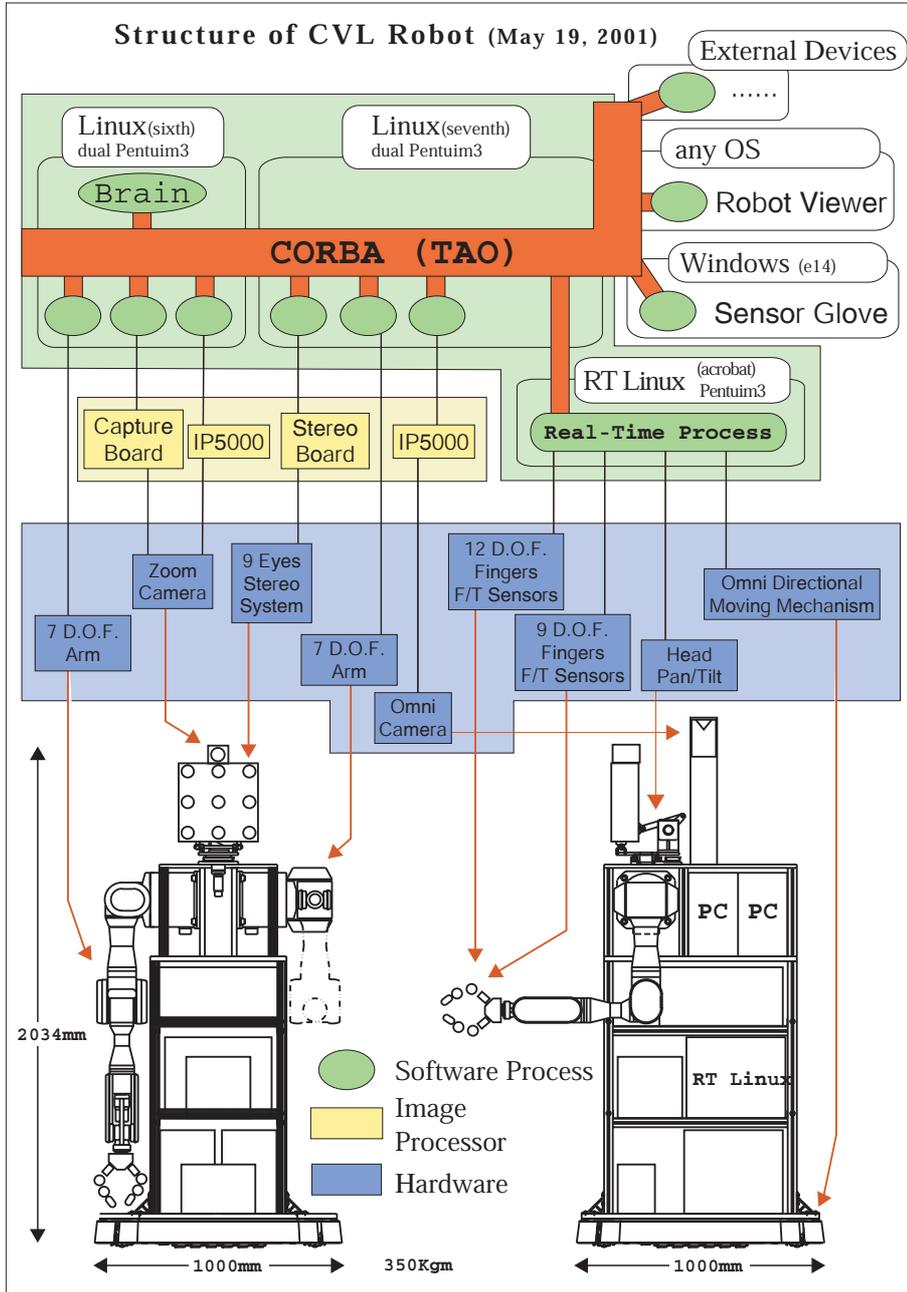


図 5.6: ロボットのソフトウェア構造

### 5.2.5 データグローブ

表 5.3: データグローブの仕様

Device	Specification
Data glove	Joints angle: 18 DOF Pose & orientation: Polhemus 6DOF Tactile sensors: 11 DOF

本研究では、教示における入力系として前述のロボット併用してデータグローブを用いる。表 5.3 に示すのがデータグローブから得られる情報である。このうち、指の関節角の情報と Polhemus 位置・姿勢はあらかじめあったが、本研究では掌の接触圧分布の情報を計測してロボットハンドへの把持のマッピングに使用するために、触覚センサを分布させた。

鎌倉は、把持を”圧力把握系”、”中間把握系”、”精密把握系”の3つの大枠にわけ、さらに全部で14種類の小分類を定めている。我々は、さらにこの中から利用頻度の高い7種類の把持を選択し(表 2.1 中の のついているもの)、これらの把持を分類できるように触覚センサの分布させた。



図 5.7: 触覚センサの分布

図 5.7 に設計したセンサ分布を示す。分布したセンサの数は11個である。

図 5.8 に、この接触センサ分布を利用して把持の認識を行った例を示す。上側が実際に把持

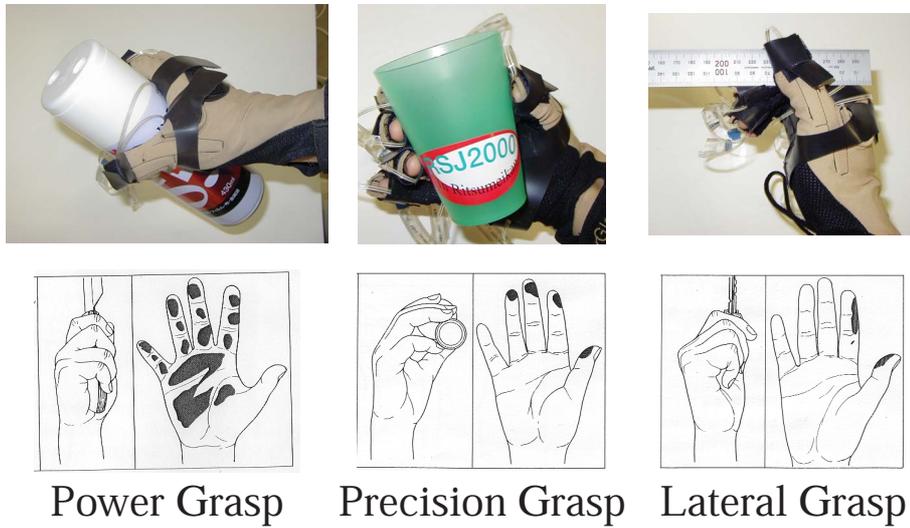


図 5.8: 接触点分布による把持の認識

を行っている写真であり，下側が対応する鎌倉の把持分類である．

また約 15fps で指の関節角・手の位置姿勢・掌の触覚分布の情報を取得可能である．

### 5.3 作業の再現：動作プリミティブの獲得

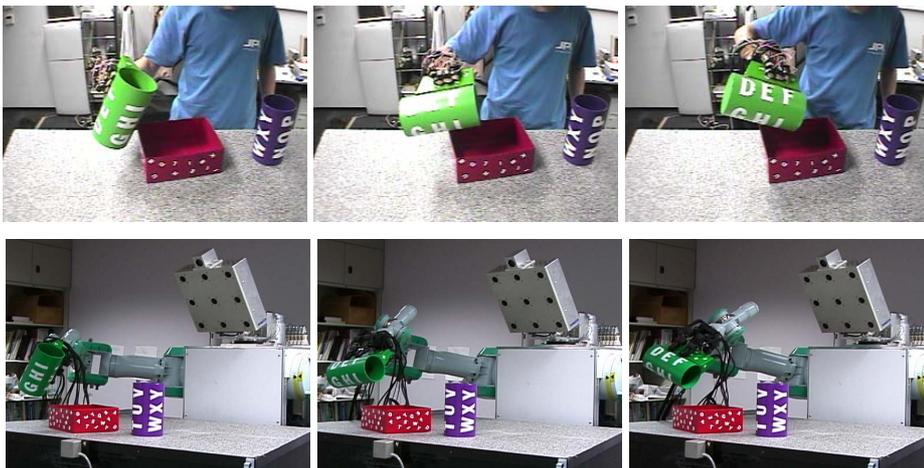


図 5.9: 物体 B への相互作用 (上：教示動作，下：再現動作)

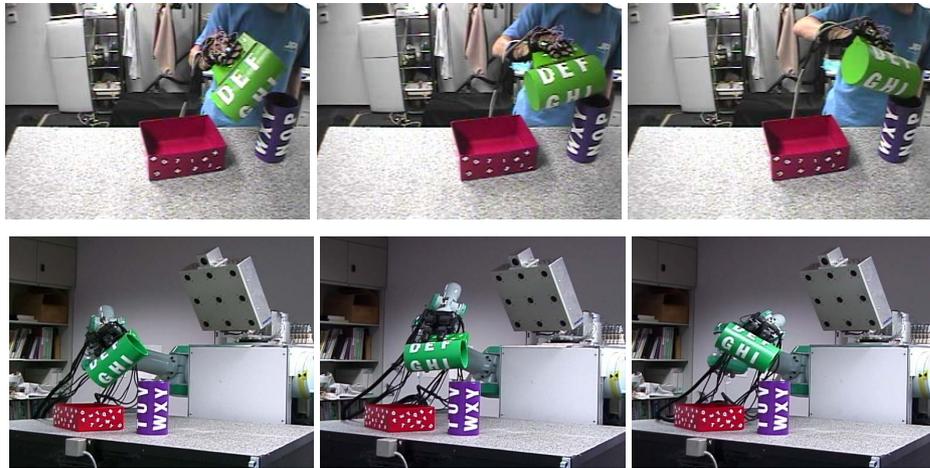


図 5.10: 物体 C への相互作用 (上：教示動作，下：再現動作)

図 5.9 及び図 5.10 は，図 3.5 の教示動作について，環境物体 B と C との相互作用の個所を人間型ロボットによって再現した結果である．上段に人間の教示動作，下段がその動作に対応して生成されたロボット動作である．

ロボットの動作は，把持物体の位置・姿勢が現環境での環境物体座標系において作業モデル中に記述されている相対軌跡を描くようにロボットアームの逆運動学を解くことで実現している．相互作用と相互作用を結ぶ区間については，1 つ前に実行した相互作用の終端座標から次の相互作用の初期座標へ直線的に移動するロボットアームの動作を生成する．これより，教示動作時とロボット再現時には環境物体の配置が異なっているにもかかわらず，作業の達成に重要な相互作用を正確に再現することを実現できた．

2 節の方法では，ロボットの動作は抽象的なシンボルに対応するものを個々に人間が手作業で生成した．本節の手法を使うことで，器用な動作を表す相互作用を人間の教示動作から自動的に軌跡の表現で獲得することが可能となり，かつ高レベルの動作の意味の推定に利用可能なシンボリックな表現との両立が可能となった．

#### 5.4 作業の再現：動作プリミティブ例 2 を認識に使用した例

図 5.11 に示すのは，人間が右手のみを使用してロボットに教示を行っている様子である．この例では，3 章の方法により相互作用区間を推定し，その区間に対して 2.1.2.5 で定義した動作プリミティブによって行為の推定を行い，ロボットの動作にマッピングしたものである．この例では，教示は 1 回とし，必須相互作用の推定は行っていない．認識結果は，順に (1)GRASP, (2)ROTL, (3)ROTL であり，2 回目の ROTL は RELEASE の誤認識である．



図 5.11: 教示動作 (右手のみ)

図 5.12 に示すのは、ロボットによる再現動作を行った例である。本来この動作は両手で行うものであるが、教示からは右手の情報しか分からないため、左手の情報については右手の情報から推測している。すなわち、把持物体と環境物体の識別は出来ており、把持物体を右手で掴んだと言うことは教示動作から分かるため、左手で環境物体を掴むという補償動作を自動的に挿入するようにした。



図 5.12: ロボットによる再現

## 5.5 作業の認識

図 5.13 に示すのは、実演教示から自動的に動作プリミティブを獲得した後に、その動作プリミティブを用いて動作認識を行い、ロボットが動作を模倣した結果である。上段が認識対象動作、下段が再現動作である。

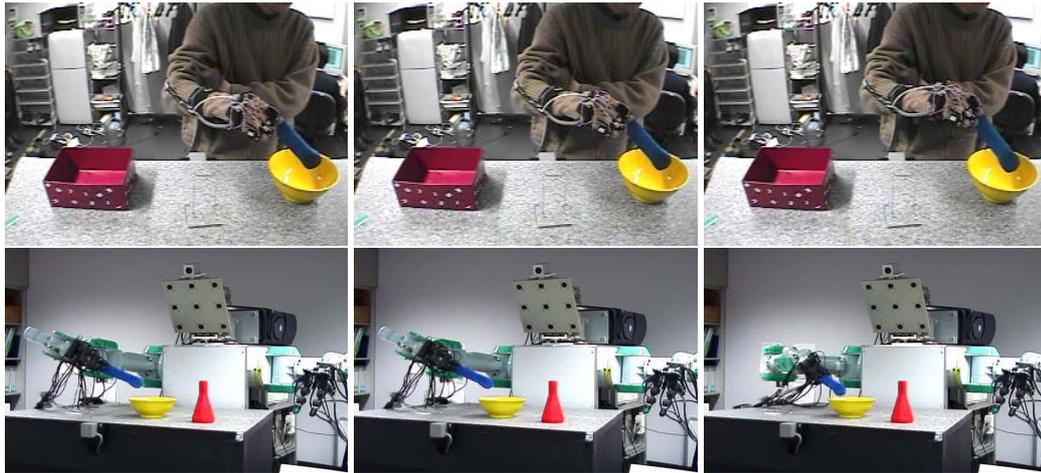


図 5.13: 新規動作プリミティブを用いた認識と再現

## 第6章 結論

近年になり研究・開発の著しい人間型ロボットは、従来の産業用ロボットとは異なり、我々一般人と共存し、人を直接支援することを目的としている。こういったロボットの使用目的は、支援されるユーザの要求に依存するため、必要に応じてユーザが簡単にロボットの動作を拡張することのできる枠組みが必要となる。このとき、人が人に対して教示を行う方法との類似性から、ユーザが実演教示することで、ロボットが観察に基づき自動的に対象動作を獲得することのできる枠組みが望ましい。

本研究では、人間型ロボットに対する日常動作の簡便な教示方法の確立を目的とし、実演教示される作業を観察することで、作業の抽象表現である作業モデルを獲得し、同時に作業モデルを利用して作業の再現及び認識を行うことの可能な作業モデル獲得方法を提案した。このとき、ある時点において観察すべき場所・時刻・センサを規定する注視戦略を提案し、注視点を獲得過程に応じて変更することで、効率よく作業モデルを生成することを可能にした。

この作業モデルの獲得過程は、次の3つの過程に分けられる。

### 基本プリミティブに基づく作業の概略の認識過程

まず、人間の实演教示動作から作業の概略を獲得する。対象とする作業は把持物体と環境物体との動きを伴う相互作用であるため、全計測範囲の中からまず動きのある個所を大まかに推定しそこを注視点として設定する。次に、基本プリミティブを使用して注視個所で行われる作業の抽象化を行う。基本プリミティブとして、把持の分類・腕の動作の分類・物体の色情報・物体の幾何形状等を設計し、それぞれ掌の圧力分布・隠れマルコフモデル・統合テンプレートマッチング法による物体のロバスト同定法の手法を提案し、基本プリミティブを用いた作業の同定を可能にした。

この時、システムへのセンサ入力として種々のセンサが考えられるが、それらは一般に測定範囲や測定対象及び情報の抽象度が異なるため、これらを均一に扱うことは効率的ではない。また逆に、あるセンサの結果を利用して別のセンサの測定範囲や処理対象に拘束をかけることにより、効率のよい解析が可能になる。本研究では、データグローブと視覚装置を利用し、まずデータグローブの情報より時空間上で手の動作が行われている個所を推定し、次にそこを注視点として視覚装置の解析範囲を拘束し、注視点近傍を詳細に観察することで操作物体の情報を獲得する段階的な作業モデルの生成法を提案した。

### 複数回観察に基づく作業に固有のプリミティブの推定過程

上述の手法では、動作が行われている個所を推定し、基本プリミティブによって作業のモデルを生成したが、次の2つの問題がある。1つは、推定された動作から真の相互作用を推定することが困難であるという問題である。日常動作においては、注ぐ・かき回すといった直接的な接触を伴わない動作や、同時に多数の物体との接触を伴う動作が数多く存在するため、手の動作の近傍を探索するのみでは、相互作用を行う対象物体を確定することは難しい。2つ目の問題は、推定された動作がその作業を達成するために必須の動作であるか否かを判断することが困難であるという問題である。ある動作が検出されたとき、それが偶発的な動作であるのか、それとも意味を持った動作であるのかを上述の手法から判断することは難しい。

これらは単一の観察に起因する問題であり、本研究では本質的には同一の作業を表す複数の教示動作を観察し、各々に検出された相互作用候補を注視点とし、複数の結果を多次元 DP Matching を用いて統合することにより、相互作用を行う物体と必須動作の正否の両方を同時に推定する手法を提案した。また、これによって獲得された動作は、その作業に固有の動作であり、その作業ドメインを構成する固有の動作プリミティブと考えることができる。本研究では、推定された動作プリミティブを、基本プリミティブと把持物体の3次元追跡によって獲得される対象物体座標系での相対軌跡の情報で表現する手法について述べ、作業モデルはこれらの動作プリミティブの連続形として表現される。このとき、DP Matching によって関連付けられた各把持物体の相対軌跡を統合し平均軌跡とその分散を計算することによってロボットによる動作の模倣を可能にし、また時空間上の確率的な変化を扱える隠れマルコフモデルによって各把持物体の相対軌跡をモデル化することで、動作の認識器としても利用可能となった。

### 再観察に基づく失敗回避動作の生成過程

ここまでで構築された作業モデルに従ってロボットが作業を再現する場合、特に参照軌跡に従って把持物体の操作を行う区間において失敗することがある。ここでは、その要因を(1)観察データの誤差、(2)作業実行時の外乱の2つに限定し、それぞれについて補償を行う方法を提案した。

観察データの誤差の要因を取り除く方法として、入力センサであるステレオ視覚のズーム比率を段階的に変更する方法を提案した。センサの測定範囲と精度にはトレードオフの関係があり、作業モデル獲得の段階では教示動作が未知であるため測定範囲を広げておく必要がある。しかし、再観察時には教示動作が予測できるため、測定範囲を狭め精度を向上することで、観測データの精度を向上させる。3次元追跡における比較で、獲得軌跡の併進成分の精度が上がったことが確認できた。

また作業実行時の外乱については、予期せぬ接触などによって把持が崩れた場合の保障方法を提案した。この手法では、ロボットの腕の3次元幾何モデルを視覚データ中に投影し、localization によりキャリブレーション誤差を推定する。次に把持物体の3次元幾何モデルを、上記の誤差を補正した上で視覚データ中の予想位置に投影し、localization を行うことで把持

の崩れの基づく把持物体の移動量を推定する。最後に、この移動量をキャンセルするように腕を漸近的に駆動することで、握り直すこと無く把持の崩れの補償を行うことが可能になった。この方法は、処理が全てカメラ座標系での計算で済むため事前の強いキャリブレーションの必要がないことが特徴である。

また、作業モデルの構築と検証のための実験プラットフォームとして、人間の上半身を模したロボットを開発した。主な特徴は、9眼マルチベースラインステレオ視覚装置によって実時間(30fps)で色画像及び距離データを獲得できること、7自由度のロボットアームと多指ハンドを両腕に備えていることである。このプラットフォームを使用し、上述の手法を組み合わせることで手法の検証実験を行った。

上記の手順で獲得した作業モデルにより、把持物体と環境物体との動きを伴う相互作用の連続形として表現可能な日常の手作業について、実演教示に基づきロボットが動作を獲得し模倣することが可能になった。

これによってモデル化可能な作業は、把持物体と環境物体との動きを伴う相互作用の連続形として表現可能な作業であり、相互作用を検出するための実装上の理由から、相互作用中は把持を行う手が比較的静止しているとの条件を付けているが、この制限は例えば周期性のある連続動作や直角に曲るなど不自然な軌跡を通る動作を検出する機構を追加することによって緩和することが可能である。その場合、手を大きく・速く動かすことが本質的に重要である作業を含めて、多くの作業を獲得し模倣することが可能であると考えられる。

ただし、現段階では動作の意味を考えず単純に模倣しているため、実験で例に挙げた注ぐ動作においては、ロボットは真に動作を獲得したとはいえない。しかし、1章で述べた関連研究からの知見より、動作の模倣は動作の獲得の第一歩であり、模倣により獲得した動作に意味付けをしていくことで動作の獲得に至ることができると考えられる。

## 6.1 寄与

本研究の寄与は次の通りである。

1. 実演教示の観察において、解析範囲を拘束する注視戦略を決定する注視点の考え方を提案した
2. 先天的に備わる基本プリミティブによって手作業の概略を記述する方法を提案した
3. 複数の観察結果を統合することにより、作業に必須の相互作用を推定し、これを作業に固有の動作プリミティブとして自動獲得する方法を提案した
4. 人間による明示的な指摘及びロボットの自己観察によって、作業失敗の要因を自動的に補償する方法を提案した

5. 獲得した作業モデルによって動作の再現と認識の双方を行い得る枠組みを提案した
6. 人間型ロボットプラットフォームを開発し、これを用いた実験によって提案手法の有効性を検証した

## 6.2 今後の展望

現在人間の認知の仕組みを探る試みもロボットの動作獲得を目指す試みも、いずれも要素機能を厳密に同定しボトムアップ的に全体を構成する還元主義的な方法が主流であるが、複雑かつ巨大なシステムに対するこの方法の行き詰まりが指摘されており統合化の観点からのアプローチの必要性が問われている [34, 20]。感覚入力と運動出力を備え外界と相互作用を行うことのできるロボットは、要素機能が組合わさり全体としてどのような挙動を示すのかを検証するための格好のツールであり、このツールを用いて要素機能の同定とその組み合わせである作業モデルの妥当性評価の双方から作業理解の枠組みを探る試みは、ロボットの知能化のみならず人間の認知の仕組みを理解することの手助けとしても有効であると思われる。

本研究で提案した作業モデルにおいて、割り付けられた動作プリミティブを構造化し、相互比較することで高次の意味表現を自動的に抽出することができれば、より高次の概念の獲得につながる。また、現在はセンサの種類や教示方法が限定されているが、これらを増やすことは外界をよく理解することにつながり、動作の真の意味をロボットの体を通して直接学習することに繋がるため、必須であると考えられる。

さらに本研究で提案した作業モデルを拡張することで、無形文化財の保存や名人の技の保存など動作の電子保存に使うことが可能になれば素晴らしい。

## 参考文献

- [1] H. Kozima and E. Vatikiotis-Bateson. Communicative criteria for processing time/space-varying information. In *IEEE Int. Workshop on Robot and Human Interactive Communication*, pp. 377–382, 2001.
- [2] R. Brooks, C. Breazeal, M. Marjanovic, B. Scassellati, and M. Williamson. The cog project: Building a humanoid robot. *Computation for Metaphors, Analogy and Agents*, Vol. LNCS 1562, pp. 52–87, 1999.
- [3] C. Martens, N. Ruchel, O. Lang, O. Ivlev, and A. Graser. A friend for assisting handicapped people. *IEEE Robotics and Automation Magazine*, No. March, pp. 57–65, 2001.
- [4] T. Sato, Y. Nishida, and H. Mizoguchi. Robotic room: Symbiosis with human through behavior media. In *Int. conf. on Robotics and Automation*, pp. 185–194, 1996.
- [5] 加藤一郎. リリスボット - 生活支援ロボット - の構想. *日本ロボット学会誌*, Vol. 11, No. 5, pp. 614–617, 1993.
- [6] K. Hirai. Current and future perspective of honda humanoid robot. In *Int. conf. on Intelligent Robots and Systems*, pp. 500–508, 1997.
- [7] M. Fujita, H. Kitano, and K. Kageyama. Development of autonomous quadruped robot for robot entertainment. In *Autonomous Robots*, 1998.
- [8] H. Iwata, H. Hoshino, T. Morita, and S. Sugano. Human humanoid physical interaction realizing force following and task fulfillment. In *Int. conf. on Intelligent Robots and Systems*, pp. 522–527, 2000.
- [9] 小川原光一, 金広文男, 稲葉雅幸, 井上博允. ネットワーク環境におけるモバイルエージェント機構に基づいて個人の継続的な支援を目指した分散ロボット統合法. *日本ロボット学会誌*, Vol. 18, No. 7, pp. 132–137, 2000.
- [10] H. Inoue, S. Tachi, K. Tanie, K. Yokoi, S. Hirai, H. Hirukawa, K. Hirai, S. Nakayama, K. Sawada, T. Nishiyama, O. Miki, T. Itoko, H. Inaba, and M. Sudo. Hrp: Humanoid robotics project of miti. In *IEEE Humanoids 2000*, 2000.

- 
- [11] K. Kosuge, M. Sato, and N. Kazamura. Mobile robot helper. In *Int. conf. on Robotics and Automation*, pp. 583–588, 2000.
- [12] 水川真, 小山俊彦. 産業用ロボットの教示方法のお現状と展望. *日本ロボット学会誌*, Vol. 17, No. 2, pp. 24–29, 1999.
- [13] A.N. Meltzoff and M.K. Moore. Imitation of facial and manual gestures by human neonates. *Science*, Vol. 198, pp. 75–78, 1977.
- [14] 多賀巖太郎. 赤ちゃんの発達のダイナミクスと身体性. *Bit 別冊 身体性とコンピュータ*, pp. 133–145, 2000.
- [15] G. di Pellegrino, L. Fadiga, L. Fogassi, V. Gallese, and G. Rizzolatti. Understanding motor events: a neurophysiological study. *Experimental Brain Research*, pp. 176–180, 1992.
- [16] 銅谷賢治. 脳科学とロボット. *日本ロボット学会誌*, Vol. 17, No. 1, pp. 7–10, 1999.
- [17] 川人光男. 脳の計算理論. 産業図書, 1996.
- [18] S. Schaal. Is imitation learning the route to humanoid robots? *Trends in Cognitive Sciences*, Vol. 3, No. 6, pp. 233–242, 1999.
- [19] M. Mataric. Sensory-motor primitives as a basis for imitation: Linking perception to action and biology to robotics, 2000.
- [20] A. Triesman. The binding problem. *Current Opinion in Neurobiology*, No. 6, pp. 171–178, 1996.
- [21] O. C. Jenkins, M. J. Mataric, and S. Weber. Primitive-based movement classification for humanoid imitation. In *IEEE-RAS Int. Conf. on Humanoid Robots 2000*, 2000.
- [22] A. Fod, M. Mataric, and O. C. Jenkins. Automated derivation of primitives for movement classification. In *IEEE-RAS Int. Conf. on Humanoid Robots 2000*, 2000.
- [23] L. R. Rabiner and B. H. Juang. An introduction to hidden markov models. *IEEE ASSP MAGAZINE*, pp. 4–16, 1986.
- [24] T. Inamura, Y. Nakamura, H. Ezaki, and I. Toshima. Imitation and primitive symbol acquisition of humanoids by the integrated mimesis loop. In *Int. conf. on Robotics and Automation*, pp. 4208–4213, 2001.
- [25] M. Kawato, F. Gandolfo, H. Gomi, and Y. Wada. Teaching by showing in kendama based on optimization principle. In *Int. Conf. on Artificial Neural Networks*, Vol. 1, pp. 601–606, 1994.

- [26] H. Miyamoto, S. Schaal, F. Gandolfo, H. Gomi, Y. Koike, R. Osu, E. Nakano, Y. Wada, and M. Kawato. A kendama learning robot based on bi-directional theory. In *Neural Networks*, Vol. 9, 1996.
- [27] 浅田稔, 石黒浩, 國吉康夫. 認知ロボティクスの目指すもの. 日本ロボット学会誌, Vol. 17, No. 1, pp. 2–6, 1999.
- [28] 國吉康夫, ベルトゥーズリエク. 身体性に基づく相互作用の創発に向けて. 日本ロボット学会誌, Vol. 17, No. 1, pp. 29–33, 1999.
- [29] R. A. Brooks. A robust layered control system for a mobile robot. *IEEE Journal of Robotics and Automation*, Vol. 2, No. 1, pp. 14–23, 1986.
- [30] H. Asada and Y. Asari. The direct teaching of tool manipulation skills via the impedance identification of human motions learning tasks from a single demonstration. In *Int. conf. on Robotics and Automation*, pp. 1269–1274, 1988.
- [31] A. Ude. Trajectory generation from noisy positions of object features for teaching robot paths. *Robotics and Autonomous Systems*, Vol. 11, No. 2, pp. 113–127, 1993.
- [32] N. Delson and H. West. Robot programming by human demonstration: Adaptation and inconsistency in constrained motion. In *Int. conf. on Robotics and Automation*, pp. 30–36, 1996.
- [33] Christopher G. Atkeson and Stefan Schaal. Learning tasks from a single demonstration. In *Int. conf. on Robotics and Automation*, pp. 1706–1712, 1997.
- [34] 川村貞夫, 深尾典久, 櫛弘明. ロボットの教示と学習. 日本ロボット学会誌, Vol. 17, No. 2, pp. 6–9, 1999.
- [35] S. Arimoto. Robotics research toward explication of everyday physics. *Int. Journal of Robotics Research*, Vol. 18, No. 11, pp. 1056–1063, 1999.
- [36] Y. Kuniyoshi, M. Inaba, and H. Inoue. Learning by watching. *IEEE Trans. Robotics and Automation*, Vol. 10, No. 6, pp. 799–822, 1994.
- [37] J. D. Morrow and P. K. Khosla. Sensorimotor primitives for robotic assembly skills. In *Int. conf. on Intelligent Robots and Systems*, pp. 234–240, 1995.
- [38] 末広尚士, 高瀬國克. スキルに基づくマニピュレーションシステム. 日本ロボット学会誌, Vol. 8, No. 5, pp. 551–562, 1990.
- [39] K. Ikeuchi and M. Herbert. Task oriented vision. In *Int. conf. on Intelligent Robots and Systems*, pp. 2187–2194, 1992.

- 
- [40] K. Ikeuchi and T. Suehiro. Toward an assembly plan from observation part i: Task recognition with polyhedral objects. *IEEE Trans. Robotics and Automation*, Vol. 10, No. 3, pp. 368–384, 1994.
- [41] 津田雅之, 高橋友一, 小方博之. 実演教示による組み立て作業モデルの生成. 日本ロボット学会誌, Vol. 18, No. 4, pp. 73–82, 2000.
- [42] 津田雅之, 小方博之, 南條義人. 実演教示による多角形ワーク組立のための局所的な接触状態遷移モデル群の生成. 日本ロボット学会誌, Vol. 18, No. 4, pp. 83–92, 2000.
- [43] H. Kimura, T. Horiuchi, and K. Ikeuchi. Task-model based human robot cooperation using vision. In *Int. conf. on Intelligent Robots and Systems*, Vol. 2, pp. 701–706, 1999.
- [44] D. C. Bentivegna and C. G. Atkeson. Learning from observation using primitives. In *IEEE-RAS Int. Conf. on Humanoid Robots 2000*, 2000.
- [45] Y. Xu and J. Yang. Towards human-robot coordination: Skill modeling and transferring via hidden markov model. In *Int. conf. on Intelligent Robots and Systems*, pp. 1906–1911, 1995.
- [46] G. E. Hovland, P. Sikka, and B. J. McCarragher. Skill acquisition from human demonstration using a hidden markov model. In *Int. conf. on Intelligent Robots and Systems*, pp. 2706–2711, 1996.
- [47] 三浦純. センサ情報に基づく行動決定のための環境モデリング. 日本ロボット学会誌, Vol. 18, No. 3, pp. 17–22, 2000.
- [48] J. Napier. The prehensile movements of the human hand. *Journal of Bone and Joint Surgery*, Vol. 38B, No. 4, pp. 902–913, 1956.
- [49] M. R. Cutkosky. On grasp choice, grasp models, and the design of hands for manufacturing tasks. *IEEE Trans. Robotics and Automation*, Vol. 5, No. 3, pp. 269–279, 1989.
- [50] S. B. Kang and K. Ikeuchi. Toward automatic robot instruction from perception - mapping human grasps to manipulator grasps. *IEEE Trans. on Robotics and Automation*, Vol. 13, No. 1, pp. 81–95, 1997.
- [51] M. A. Arbib, T. Iberall, and D. M. Lyons. Coordinated control programs for movements of the hand. *Hand Function and the Neocortex*, pp. 111–129, 1985.
- [52] 鎌倉矩子. 手のかたち手のうごき. 医歯薬出版株式会社, 1989.

- [53] J. Takamatsu, H. Tominaga, K. Ogawara, H. Kimura, and K. Ikeuchi. Symbolic representation of trajectories for skill generation. In *Int. conf. on Robotics and Automation*, pp. 4077–4082, 2000.
- [54] J. Takamatsu, H. Tominaga, K. Ogawara, H. Kimura, and K. Ikeuchi. Extracting manipulation skills from observation. In *Int. conf. on Intelligent Robots and Systems*, pp. 584–589, 2000.
- [55] S. Brunnstrom. 臨床運動学. 医歯薬出版株式会社, 1970.
- [56] S. B. Kang. *Robot Instruction by Human Demonstration*. PhD thesis, CMU, 1994.
- [57] 島田伸敬, 白井良明, 久野義徳, 三浦純. 緩やかな制約知識を利用した単眼視動画像からの関節物体の形状と姿勢の同時推定. 電子情報通信学会論文誌, Vol. J81-D-II, No. 1, pp. 45–53, 1998.
- [58] 上田悦子, 松本吉央, 今井正和, 小笠原司. 多視点シルエット画像を用いた手の形状推定. In *Computer Vision Image Media*, No. 128, pp. 25–31, 2001.
- [59] T. Starner and A. Pentland. Real-time american sign language recognition from video. In *IEEE International Symposium on Computer Vision*, pp. 265–270, 1995.
- [60] 西村拓一, 向井理朗, 野崎 俊輔岡隆 一. 低解像度特徴を用いた複数人物によるジェスチャーの単一動画像からのスポッティング認識. 電子情報通信学会論文誌 D-II, 第 J80-D-II 巻, pp. 1563–1570, 1997.
- [61] K. M. Knill and S. J. Young. Speaker dependent keyword spotting for accessing stored speech. In *Cambridge University Engineering Dept., Tech. Report*, Vol. CUED/F-INFENT/TR, p. 193, 1994.
- [62] S. Iba, J.M. Vande Weghe, C.J.J. Paredis, and P.K. Khosla. An architecture for gesture based control of mobile robots. In *Int. conf. on Intelligent Robots and Systems*, pp. 851–857, 1999.
- [63] Hyeon-Kyu Lee and Jin H. Kim. An hmm-based threshold model approach for gesture recognition. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 21, pp. 961–973, 1999.
- [64] S. J. Young. *HTK: Hidden Markov Model Toolkit V2.2*. Entropic Research Lab Inc., Washington DC, 1999.
- [65] 千宗室. 初歩の茶道 風炉点前. 淡交社, 1976.
- [66] 吉見修, 山口博義. 膨張確度係数を用いた視差画像における物体輪郭の鮮鋭化. 第 6 回画像センシングシンポジウム講演論文集, 2000.

- 
- [67] M. D. Wheeler and K. Ikeuchi. Sensor modeling, probabilistic hypothesis generation, and robust localization for object recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 17, No. 3, pp. 252–265, 1995.
- [68] K. Ogawara, S. Iba, T. Tanuki, H. Kimura, and K. Ikeuchi. Recognition of human task by attention point analysis. In *Int. Conference on Intelligent Robot and Systems*, Vol. 3, pp. 2121–2126, 2000.
- [69] B. Dufay and J. C. Latombe. An approach to automatic robot programming based on inductive learning. *Int. Journal of Robotics Research*, Vol. 3, No. 4, pp. 3–20, 1984.
- [70] 小川原光一, 射場総司, 田貫富和, 木村浩, 池内克史. 9眼ステレオとデータグローブを用いたロボットによる人間行動の認識と再現. In *Computer Vision Image Media*, No. 122, pp. 57–64, 2000.
- [71] G. Fuellen. A gentle guide to multiple alignment. *Complexity International*, Vol. 4, pp. 1–56, 1997. <http://www.csu.edu.au/ci/vol04/mulali/mulali.html>.
- [72] K. Ogawara, H. Kimura, and K. Ikeuchi. Refining hand-action models through repeated observations of human and robot behavior by combined template matching. In *Int. Conference on Intelligent Robot and Systems*, 2001.
- [73] 滝沢穂高, 白井良明, 三浦純. 注視・ズームを用いた自律移動ロボットのための3dシーン記述の選択的精密化. *日本ロボット学会誌*, Vol. 13, No. 7, pp. 69–76, 1995.
- [74] H.L. Dreyfus and S.E. Dreyfus. Making a mind versus modeling the brain: Artificial intelligence back at a branchpoint. *The Artificial Intelligence Debate*, pp. 15–43, 1989.
- [75] K. Ogawara, J. Takamatsu, S. Iba, T. Tanuki, Y. Sato, A. Saegusa, H. Kimura, and K. Ikeuchi. Acquiring hand-action models in task and behavior levels by a learning robot through observing human demonstrations. In *The First IEEE-RAS International Conference on Humanoid Robots*, 2000.
- [76] Object Management Group. *Common Object Request Broker Architecture*, July 1995.
- [77] <http://www.komatsu.co.jp/research/study56.htm>.
- [78] 奥富正敏, 金出武雄. 複数の基線長を利用したステレオマッチング. *電子情報処理学会誌 (D-II)*, pp. 1317–1327, 1992.
- [79] H. Butterfab, M. Grebenstein, H. Liu, and G. Hirzinger. Dlr-hand ii: Next generation of a dextrous robot hand. In *Int. conf. on Robotics and Automation*, pp. 109–114, 2001.

- [80] S. Hirose and S. Amano. The vuton: High payload high efficiency holonomic omnidirectional vehicle. In *Int. Symp. on Robotics Research*, pp. 253–260, 1993.
- [81] <http://www.cs.wustl.edu/~schmidt/tao.html>.