

接触に基づくマニピュレータ作業空間  
の自律的学習に関する研究

2018年 3月

原田 篤

接触に基づくマニピュレータ作業空間  
の自律的学習に関する研究

原田 篤

システム情報工学研究科  
筑波大学

2018年 3月

# 概要

本論文は、マニピュレータが能動的な動作に基づき自己及び環境との相互作用を通じて自身の作業空間を自律的に学習する手法を提案するものである。制御対象として取り上げる人間型ロボットの腕部は、冗長自由度を持つマニピュレータであり、一般に自己衝突や外部環境との衝突が発生する問題がある。また、未知環境での利用を考えた場合、環境の変化に対して適応可能なシステムが必要である。

提案手法は、関節駆動部のアクチュエータに流れる電流を計測することで、異常な接触などによるアクチュエータへの過負荷を検出することで、駆動部の保護を行うとともに、その際の姿勢情報に基づき自身が動作可能な領域を獲得することで、作業空間を自律的に学習するものである。可動領域を獲得するため、少ない学習データでも汎化能力の高い学習が可能であるベイズ学習を用いた。ベイズ学習に用いる学習データは制御対象である腕部の関節角度になり、関節角度空間上にてロボットの可動領域に関するベイズ識別面が作成される。これにより、外部環境のモデルを予め用意しなくても、自身の動作負荷に基づき関節角度空間上で可動領域を獲得することで作業空間の自律的な学習が可能であることを示す。

まず、電流センサの値から異常な接触に基づく過負荷の検出が可能であることを示すと同時に、提案する可動範囲の獲得手法について述べる。次に、過負荷発生時の関節角度の履歴に基づき経路計画を行うことで、環境変化への適応が可能であることを示す。さらに、タスク実行中に獲得した過負荷発生時の関節角度を用い、変分ベイズ学習により可動領域の獲得が可能であることを示す。最後に、制御・学習機構を連動させることにより、可動領域を動作に応じて逐次的にオンライン学習を行うとともに、環境変化に対して適応可能であることを示すことで、作業空間の自律的な学習が可能であることを示す。

以上より、関節駆動部に生じる動作負荷に基づき、マニピュレータの能動的な動作により可動領域を獲得することで、マニピュレータ作業空間の自律的な学習が可能となり、自身を含めた環境の変化に適応することが可能であるという知見が得られた。

# 目次

|            |                                |           |
|------------|--------------------------------|-----------|
| <b>第1章</b> | <b>緒言</b>                      | <b>1</b>  |
| 1.1        | 関連研究                           | 2         |
| 1.1.1      | マニピュレータの制御に関して                 | 2         |
| 1.1.2      | 学習と自己モデル化に関して                  | 3         |
| 1.2        | 目的                             | 4         |
| <b>第2章</b> | <b>提案手法</b>                    | <b>7</b>  |
| 2.1        | 接触検出モデル                        | 10        |
| 2.1.1      | 電流センサを用いた過負荷検出による手法            | 10        |
| 2.1.2      | 力センサを用いた手法                     | 12        |
| 2.2        | 能動的な可動領域の獲得                    | 12        |
| 2.2.1      | Rapidly-exploring Random Trees | 15        |
| 2.2.2      | 過負荷発生姿勢の情報のみに基づく経路計画           | 16        |
| 2.3        | 可動領域の確率的学習                     | 17        |
| 2.3.1      | 混合正規分布モデル                      | 18        |
| 2.3.2      | 変分ベイズ学習                        | 18        |
| 2.3.3      | 可動領域のモデル化                      | 19        |
| 2.4        | 可動領域を用いた経路計画                   | 21        |
| 2.5        | 提案手法における前提条件                   | 22        |
| <b>第3章</b> | <b>システム構成</b>                  | <b>24</b> |
| 3.1        | ハードウェア構成                       | 24        |
| 3.2        | ソフトウェア構成                       | 26        |
| <b>第4章</b> | <b>実験</b>                      | <b>29</b> |
| 4.1        | 接触検出実験                         | 29        |
| 4.1.1      | 電流センサを用いた過負荷検出実験               | 29        |
| 4.1.2      | 力センサを用いた接触検出実験                 | 31        |
| 4.2        | 荷重増加実験                         | 33        |



|              |                                   |           |
|--------------|-----------------------------------|-----------|
| 4.3          | 接触に基づく環境変化への適応 . . . . .          | 35        |
| 4.3.1        | 1 自由度での環境変化への適応 . . . . .         | 35        |
| 4.3.2        | 多自由度での環境変化への適応 . . . . .          | 36        |
| 4.4          | 変分ベイズ学習による可動領域の獲得 . . . . .       | 40        |
| 4.4.1        | リーチングタスクによる姿勢情報の獲得 . . . . .      | 40        |
| 4.4.2        | 学習データ . . . . .                   | 43        |
| 4.4.3        | 変分ベイズ学習 . . . . .                 | 43        |
| 4.5          | 可動領域の探索と構造変化に伴う解析 . . . . .       | 45        |
| 4.6          | 作業空間の自律的学習 . . . . .              | 47        |
| <b>第 5 章</b> | <b>考察</b>                         | <b>52</b> |
| 5.1          | 接触による負荷の検出に関する考察 . . . . .        | 52        |
| 5.2          | 荷重増加実験に関する考察 . . . . .            | 52        |
| 5.3          | 接触に基づく環境変化への適応に関する考察 . . . . .    | 53        |
| 5.4          | 変分ベイズ学習による可動領域の獲得に関する考察 . . . . . | 53        |
| 5.5          | 可動領域の探索と構造変化に伴う解析に関する考察 . . . . . | 54        |
| 5.6          | 作業空間の自律的学習に関する考察 . . . . .        | 54        |
| 5.7          | 今後の展望 . . . . .                   | 55        |
| <b>第 6 章</b> | <b>結言</b>                         | <b>57</b> |
|              | 謝辞                                | <b>59</b> |
|              | 参考文献                              | <b>60</b> |

# 目次

|      |   |    |
|------|---|----|
| 1.1  | iARM[1]                                   | 1  |
| 1.2  | マイ Spoon [7]                              | 1  |
| 1.3  | Pepper[17]                                | 1  |
| 1.4  | 可動領域と作業空間                                 | 4  |
| 1.5  | 環境変化に伴う可動領域の更新                            | 5  |
| 2.1  | 作業空間と可動領域の関係                              | 7  |
| 2.2  | 作業空間の学習のためのサイクル                           | 8  |
| 2.3  | 提案手法の概要                                   | 8  |
| 2.4  | 確率モデルと経路計画の概念                             | 9  |
| 2.5  | マニピュレータと環境との接触の力の釣り合い                     | 10 |
| 2.6  | 可動領域獲得のための動作手順                            | 13 |
| 2.7  | 可動領域モデルを用いた経路計画の概念図                       | 14 |
| 2.8  | The basic RRT construction algorithm [37] | 15 |
| 2.9  | The EXTEND operation [37]                 | 16 |
| 2.10 | RRTs を用いて生成された経路の例                        | 17 |
| 2.11 | 可動領域の自律的学習の手順                             | 18 |
| 2.12 | 可動領域モデルと可動範囲の関係性                          | 20 |
| 2.13 | 確率モデルを用いた経路計画                             | 22 |
| 3.1  | 多自由度マニピュレータ搭載人間型ロボット (Genie)              | 24 |
| 3.2  | 5DOFs マニピュレータ                             | 25 |
| 3.3  | システム概要                                    | 26 |
| 3.4  | クライアントアプリケーション (Marionette)               | 27 |
| 4.1  | 過負荷検出実験に用いた関節                             | 29 |
| 4.2  | 電流センサ値と過負荷の検出                             | 30 |
| 4.3  | iCub ( developed by IIT[12])              | 31 |
| 4.4  | 力センサを用いた接触検出                              | 32 |

|      |  |    |
|------|--|----|
| 4.5  | 力センサによる接触検出実験 . . . . .                  | 33 |
| 4.6  | 鉛直方向への荷重増加 . . . . .                     | 34 |
| 4.7  | 鉛直方向の荷重増加実験による可動範囲の変化 . . . . .          | 34 |
| 4.8  | 障害物挿入による環境変化 . . . . .                   | 36 |
| 4.9  | 環境変化への適応動作 . . . . .                     | 37 |
| 4.10 | 環境変化への適応実験 . . . . .                     | 38 |
| 4.11 | 視覚情報に基づく可動角マップの切替 . . . . .              | 38 |
| 4.12 | 環境変化への適応による障害物回避動作 . . . . .             | 39 |
| 4.13 | リーチングタスクの目標領域 . . . . .                  | 40 |
| 4.14 | リーチングタスクにおける動作軌道と過負荷発生位置 . . . . .       | 41 |
| 4.15 | 接触による過負荷発生時の手先位置 . . . . .               | 42 |
| 4.16 | 変分ベイズ学習による可動領域の獲得 . . . . .              | 44 |
| 4.17 | 探索による可動領域の獲得と自身の構造変化による可動領域の学習 . . . . . | 45 |
| 4.18 | 探索学習後の手先座標における確率値 . . . . .              | 46 |
| 4.19 | 腕部振り上げタスクにおける環境変化 . . . . .              | 48 |
| 4.20 | 駆動関節と作業空間の遷移 . . . . .                   | 48 |
| 4.21 | 作業空間の学習過程における可動領域の遷移 . . . . .           | 49 |
| 4.22 | 作業空間学習後の手先座標における確率値 . . . . .            | 50 |
| 5.1  | 異なるプラットフォームへの応用 . . . . .                | 56 |

# 表 目 次

|                                       |    |
|---------------------------------------|----|
| 4.1 学習に用いたデータと学習後の平均確率値と最頻値 . . . . . | 46 |
|---------------------------------------|----|

# 第1章 緒言



Fig. 1.1: iARM[1]



Fig. 1.2: マイスプーン [7]



Fig. 1.3: Pepper[17]

これまでSFの中でしか語られなかった人とロボットが一緒に暮らす世界が既に始まっている。主に産業用機械として用いられてきたマニピュレータにおいても、Exact Dynamics 社の iARM[1] や Kinova Robotics 社の JACO[2] に代表されるような多自由度マニピュレータを車椅子に搭載し、人の生活を補助する研究も進められている [3]-[6]。また、SECOM 社のマイスプーン [7] のような上肢障害者を対象とした支援用途への応用に関する研究も進められている [8]-[11]。さらに人間型ロボットの腕部など、人と密接に関わる環境での動作を対象とし、その役割が広がっている [12]-[16]。そして、SoftBank 社の Pepper[17] に代表されるような多自由度マニピュレータを持つ一般ユーザー向けの人間型ロボットも実用化されている。

これより、多自由度マニピュレータを持つロボットの作業空間の多様化が進み、ロボットが未知環境で適切に動作することが求められている。特に、人間型ロボットのように冗長自由度が多い場合には、自己衝突や外部環境との衝突を引き起こす場面が多くあり、それらを回避するもしくは自身の構造を保護するように動作するのが一般的である。しかし、多様化する環境においてはロボット自身による学習が必要であり、そのような学習系においては能動的な動作を積極的に用いることで環境への適応を計る手法も提案されている。

## 1.1 関連研究

### 1.1.1 マニピュレータの制御に関して

作業環境が既知である場合、一般的にはその環境のモデルを事前に作成することで制御対象を安全に動作させる [18]。また、制御対象自身に関しても事前にモデリングすることで自己衝突を防ぐことが可能である。Kuffnerらは、人間型ロボットを簡単なポリゴンモデルで表現し、自己衝突が発生すると思われるボディパーツ毎のペアを固定することにより、少ない計算量で自己衝突を回避する経路をシミュレーション上にて生成している [19]。瀬戸らは、制御対象のモデルに弾性体の概念を加えることで、ボディパーツ間の距離が近づくほど仮想的な反発力が発生する制御則を提案するとともに、人間型ロボットを用いて自己衝突が回避可能なことを示した [20][21]。岡田らは、連鎖したリンクのペアでの自己衝突検出とそれ以外のボディパーツ間での自己衝突検出を組み合わせたリアルタイム自己衝突検出システムを提案している [22]。しかし、これらの手法では既知環境での障害物との衝突、もしくは自己衝突の回避は可能であるが、想定されない環境の変化や、ロボット自身の構成の変化に対して脆弱なシステムとなる。

未知環境において障害物等との衝突回避を回避する手法として、視覚センサなどを用いて外部環境のモデルを逐次更新しながらロボットの動作生成を行う手法がある。未知環境にて動作することを前提とし、人や物との接触を考慮した研究として、細田らはヴィジュアルサーボと力制御のハイブリットコントローラを開発し、未知の拘束面に対して画像内にて与えられる目標軌道に対する追従制御を提案している [23]。

また、未知環境にてあるタスクを実行しようとした場合、そのタスクに合わせた行動が必要となる。岩田らは、全身触覚センサスーツを開発し、そこから得られるセンサ情報から人との接触を検知するだけでなく触覚インタフェースとして動作生成にも利用している [24][25]。

加賀美らは、ステレオビジョンによって外部環境を逐次モデリングし、その環境モデルを用いることで経路計画を行い障害物回避やグラスピングが可能であることを示した [26][27]。岡田らは、人間型ロボットを日常生活におけるタスクを実行させることを目的として、視覚情報に基づいて動作を検証するシステムを開発し、掃除やお茶汲み、洗い物などの動作を実際に行えることを示した [28]。

一方、環境のモデリングにおいて接触を積極的に用いている手法は昔から研究されており、特にカメラと力センサによる視触覚融合システムの研究自体は20年以上前から行われている [29][30]。ただし、力センサは衝撃に対して脆弱であり、センサ自体も高価であるため、力センサレスの力制御の研究が行われている [31][32]。

しかし、力センサを用いることで関節負荷や可動範囲に合わせた行動選択を行う手法に関しても研究が進められている [33]。特に、物体操作など環境との接触を伴う行動の場合、その状態に合わせた行動を生成するためには、自身や環境の状態を逐次推定しながら動作を更新して行く必要がある、物体と環境、ロボット間の接触状態にあわせた動作実行法に関する研究も進められている [34][35]。これらは未知環境への対応をするためにカメラや触覚センサといった特定の追加装置を必要とするものである。

一般に、対象システムにあるタスクを実行させようとした場合、経路計画や動作計画が必要になる。冗長自由度を持つマニピュレータなどの場合、手先座標の移動経路とマニピュレータの姿勢は一意に決まらないため、拘束を与え、逆運動学を解くことで経路計画を行う手法が一般的である [36]。しかし、逆運動学を解く場合、汎用性や解の収束性の問題がある。

そこで、経路計画の手法の一つとして、ランダム探索を用いたものがある。ランダム探索の手法の一つである Rapidly-exploring Random Trees (RRTs) は高次元空間にて解の探索を行う手法である [37]。Kuffner らは、経路計画に RRTs を用いシミュレーションを行った [38]。また、吉田は人間型ロボットの全身の動作計画を RRTs を用いて行い、障害物のくぐり抜け動作に適用した [39]。そして、Bertram らは冗長自由度を持つマニピュレータの逆動力学問題に RRTs を組み合わせることで、より効率的に経路計画を行った [40]。

本研究では、経路計画の手法としてこの RRTs を用いるとともに、RRTs による経路計画のシミュレーションを可能としたソフトウェアである Motion Strategy Library (MSL) を用いることとした [41]。

### 1.1.2 学習と自己モデル化に関して

マニピュレータを用いた研究、特に人間型ロボットに搭載されたマニピュレータにおいて、その研究の 1 分野として身体性に基づく知の創発に関する研究が多数報告されてい [42]-[44]。これは、身体性認知科学ともリンクしており、実際にロボットを動作させることでそのセンサデータに基づき自己身体モデルを自律的に獲得する研究とも言える。

Bongard らは、実際のロボットを動作させることでそのセンサ情報を取得し、シミュレータ上のロボットの身体構造を自律的に獲得するセルフモデリングの手法を提案しており、シミュレータの更新と実際のロボットの動作を逐次更新することで自己身体の構造を獲得させた [45]。

三枝らは人間型ロボットの腕部を用いて知覚運動性学習 (Sensorimotor learning) にて、確率モデルとニューラルネットワークを用いて手先に着けたマーカーをカメラで

見ながらその移動と腕部の動きを自律的に学習する手法を提案している [46]。

Sylvain らは混合正規分布モデルとその回帰モデルを用いて少ない教示動作からリーチングタスクにおいて、物体の位置が多少違っていたとしても同じような動作を自律的に生成可能な手法である **Programing by Demonstration (PbD)** という手法を提案している [47][48]。そして、Zadeh はそれをより発展させ複数の教示データにおける同一のタイムスタンプの姿勢を関連づけることで、その時間スタンプ毎の正規分布のマージンを逐次最大化し統合することで自身の動作可能な領域を学習する手法を提案している [49]。

一般に、ある観測データ集合が与えられた場合、統計的学習を用いることでモデルのパラメータ推定が可能である。統計的学習の有力なアプローチであるベイズ学習は、すべての未知量を確率変数として扱い、未知パラメータも確率として推定することができる。しかし、ベイズ学習には困難な期待値計算を伴うため、解析的に求めることは困難ため、何らかの近似を行う必要がある。そこで、本研究ではベイズ学習に変分近似を援用した変分ベイズ (VB: Variational Bayes) 法を用いることとする [50]-[59]。

## 1.2 目的




Fig. 1.4: 可動領域と作業空間






Fig. 1.5: 環境変化に伴う可動領域の更新

本研究において、作業空間、可動領域、ならびに可動範囲は以下のように定義している。

- 作業空間 (Working space): 制御対象が動作する直交座標空間
- 可動領域 (Operating space): 制御対象のパラメータ空間上に設定された動作可能領域
- 可動範囲 (Operating range): 各軸毎に設定された動作可能範囲

そして、Fig.1.4にてマニピュレータの可動領域を破線で囲われた灰色の領域で示し、作業空間を一点鎖線で囲んで示している。本研究では、マニピュレータの可動領域を学習することにより、そのマニピュレータの作業空間の学習を行うこととしている。

以上のことから本研究では、多自由度マニピュレータを制御対象とし、自身を含む環境との接触時にアクチュエータに発生する負荷を観測することで、関節角度空間上に可動領域を決定する指標となる識別面を確率モデルとして表現し、自身の動作可能範囲内の環境を含む作業空間を自律的に学習することを目的とする。これは、外部環境との相互作用である接触を関節駆動部へ発生する負荷の検出を用いることで、マニピュレータ自身の能動的な動作に基づき作業空間の学習を行う自律的学習モデルである。作業空間の学習には、少ない学習データにおいても汎化能力の高い学習が可能であるベイズ学習を用いることとし、確率モデルで表現される動作可能な領域のことである可動領域を逐次更新していくことで作業空間の学習を行うこととする。

Fig.1.5 に示すように、本研究における可動領域  $O$  は自己を含む環境に対する危険度を表すため、マニピュレータが取り得る全姿勢の関節角度  $\Theta$  に基づき、変化する確率モデル  $p$  によって定義する。道具の利用による自身の構造の変化や障害物の挿入による環境変化に対して、環境への接触を積極的に用いることで関節駆動部に生じる負荷とその姿勢に基づき、可動領域を自律的な学習によって更新することによって、作業空間の学習を行うこととする。

## 第2章 提案手法




Fig. 2.1: 作業空間と可動領域の関係

本章では、電流センサを用いたアクチュエータにかかる過負荷の検出手法と、その時点における関節角度を記録したデータベースから可動領域を決定する確率モデルの学習手法について述べる。

本研究では、人間型ロボットの腕部を制御対象として、その腕部の動作時に発生した異常な接触による関節駆動部の過負荷を検出することにより、その時の腕部の関節角度を記録することにより、腕部の可動範囲を獲得し、可動領域を学習する。可動範囲とは関節駆動部における動作範囲のことであり、実際に動作することによって得られたデータのみから獲得される。可動領域とは可動範囲の獲得時に得られたデータを変分ベイズ学習することによって得られた可動可能な領域である。また、可動範囲は関節角度空間上の点の集合として表されるのに対して、可動領域は関節空間上にベイズ識別面として表される。

Fig.2.1 はロボットが実際に動作する作業空間と関節角度空間を示したものである。

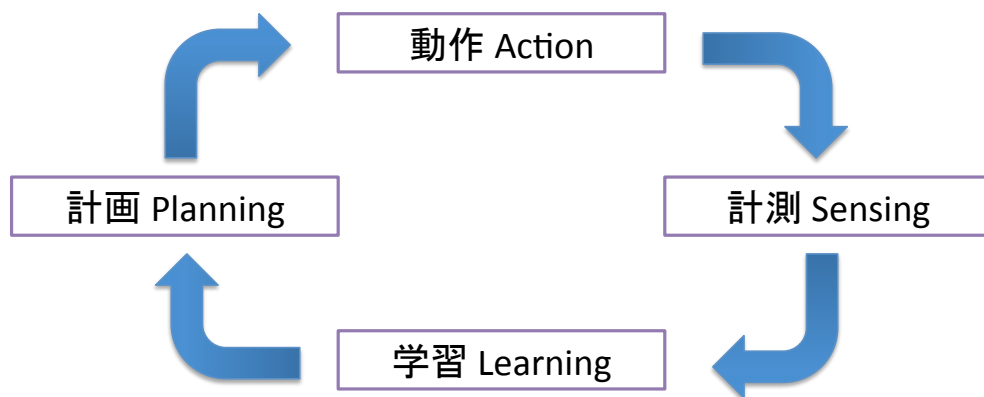


Fig. 2.2: 作業空間の学習のためのサイクル

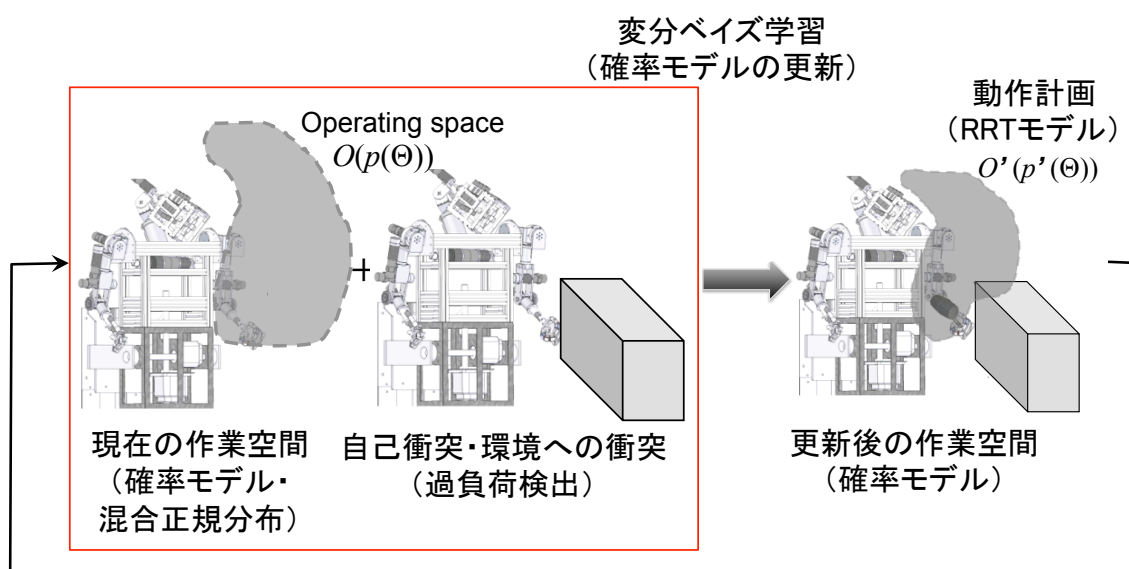


Fig. 2.3: 提案手法の概要

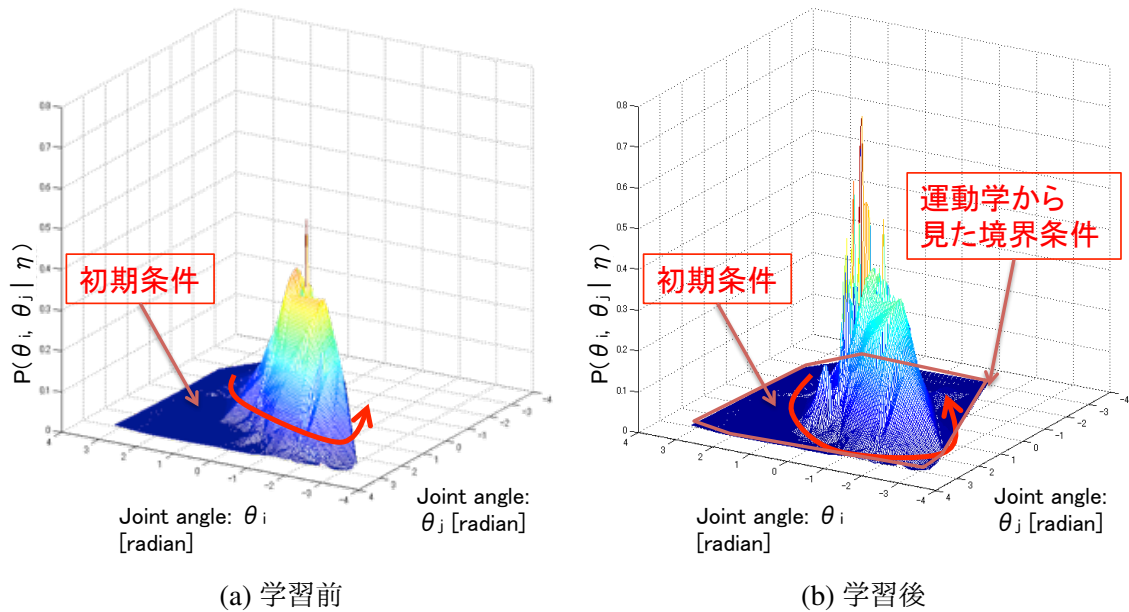


Fig. 2.4: 確率モデルと経路計画の概念

左図に示すように作業空間上で接触による過負荷が発生した場合、関節角度座標として記録され、それをマッピングしたものが右図となる。 $\otimes$ が記録された関節角度座標となっており、この集合が可動角マップである。左図の一点鎖線はマンピュレータのエンドエフェクタが動作可能な領域を示しており、この線内の領域がエンドエフェクタの作業空間となる。右図の破線は関節角度空間上において動作可能な領域とそうでない領域を分ける境界線である。本研究では、この境界線を求めることで可動領域を逐次更新し、作業空間の学習を行うこととしている。Fig.2.2に作業空間の学習のための基本的なサイクルを示す。経路計画により動作を生成し、その動作中におけるセンサ情報に基づき学習を行い、その学習したモデルに基づき再度経路計画を行うサイクルにより作業空間を逐次学習することとする。

そして、Fig.2.3が提案手法の概要を示したものである。また、Fig.2.4に確率モデルを用いた経路計画の概念を示す。学習により、確率モデルによって構成される可動領域が更新され、それに合わせ経路を変更することで、作業空間の学習を行っている。




Fig. 2.5: マニピュレータと環境との接触の力の釣り合い

## 2.1 接触検出モデル

### 2.1.1 電流センサを用いた過負荷検出による手法

内界センサの一種である電流センサを用いてアクチュエータに流れる電流を計測することは、逐次的にアクチュエータにかかる負荷を計測することといえる [60]-[62]。

Fig.2.5で示すようにマニピュレータの手先と環境が接触していて、物体から力  $\mathbf{f} = (f_x \ f_y \ f_z)^T$  とモーメント  $\mathbf{m} = (m_x \ m_y \ m_z)^T$  が加わって、その力が釣り合って全体が静止している場合、マニピュレータ自身は物体に対して  $-\mathbf{f}, -\mathbf{m}$  の力とモーメントを及ぼしている。このとき、 $n$ 個の関節が発生しているトルクを列ベクトル  $\boldsymbol{\tau} = (\tau_1 \ \tau_2 \ \cdots \ \tau_n)^T$  と表せば、 $\boldsymbol{\tau}$  は仮想仕事の原理から計算することができる。 $\mathbf{f}$  と  $\mathbf{m}$  をまとめて、 $\mathbf{F} = (f_x \ f_y \ f_z \ m_x \ m_y \ m_z)^T = (f_1 \ f_2 \ f_3 \ f_4 \ f_5 \ f_6)^T$  とおく。また、関節変位を  $\boldsymbol{\theta} = (\theta_1 \ \theta_2 \ \theta_3 \ \cdots \ \theta_n)^T$ 、エンドエフェクタの位置姿勢を  $\mathbf{r} = (r_1 \ r_2 \ r_3 \ \cdots \ r_6)^T$  とし、関節の微小変位を  $\Delta\boldsymbol{\theta} = (\Delta\theta_1 \ \Delta\theta_2 \ \Delta\theta_3 \ \cdots \ \Delta\theta_n)^T$ 、エンドエフェクタの微小変位を  $\Delta\mathbf{r} = (\Delta r_1 \ \Delta r_2 \ \Delta r_3 \ \cdots \ \Delta r_6)^T$  とすれば、マニピュレータと物体が微小な変位を起こしたとき、マニピュレータが物体になした仮想仕事と物体がマニピュレータになした仮想仕事が等しくなるので、関節トルク  $\boldsymbol{\tau}_J$  と力とモーメントのベクトル  $\mathbf{F}$  の間には、

$$\boldsymbol{\tau}_J = \mathbf{J}(\boldsymbol{\theta})^T \mathbf{F} \quad (2.1)$$

という関係が成立する。

また、DC モータにおいて発生するトルク  $\tau_I$  の大きさは流す電流  $I$  の大きさに比例し、以下の式で与えられる。

$$\tau_I = K_T I \quad (2.2)$$

$K_T$ [Nm/A] はトルク定数である。

よって、準静的な環境において (2.1) 式と (2.2) 式の間には以下のような関係性が成り立つ。

$$\tau_J = \tau_I \quad (2.3)$$

$$\approx K_T I \quad (2.4)$$

(2.4) 式は各関節トルクとモータトルクが比例関係にあることを示している。

よって、電流センサを各アクチュエータ毎に備えることで、簡便に可動領域の探索が可能となる。しかし、単純に電流センサの計測値を用いて過負荷を検出することは困難であるため、本研究では以下の過負荷検出のための判定式を用いる。

$$\begin{aligned} e_j(t) &= h(u) \\ &= h\left\{W_i \sum_{\tau=1}^T |I(t-\tau)| - e_{th} - |W_p I(t) - W_d \{I(t) - I(t-1)\}|\right\} \end{aligned} \quad (2.5)$$

$$h(u) = \begin{cases} 1 & (u > 0) : \text{unexpected event} \\ 0 & (u \leq 0) : \text{normal state (under control)} \end{cases}$$

$I$ : current-sensor value,  $e_{th}$ : threshold,  $W_p, W_i, W_d$ : weight parameters

$e_j$  は、時間  $t$  における各アクチュエータ  $j$  毎の過負荷検出の有無を表す。 $I(t)$  は時間  $t$  における電流センサの値である。過去 100 点分 ( $T = 100$ ) の電流値の絶対値の総和と現在の電流値、電流値の後退差分、及び経験的に定めた閾値  $e_{th}$  と同じく経験的に定めた各項の重み係数  $W_p, W_i, W_d$  に基づき、過負荷検出の判別を行う。この後退差分と、100 ms 毎の絶対値の総和、及び経験的に定めた閾値  $e_{th}$  に基づき、過負荷検出の判別を行う。 $h(u)$  は 2 値化判別関数で  $h$  内の計算式  $u$  が  $u > 0$  の時、出力として 1 をそれ以外の時は 0 を返す関数である。右辺の関数  $h$  内の第一項は、単位時間におけるアクチュエータの消費エネルギーと経験的に定めた重み係数  $W_i$  との積である。また、関数  $h$  内の第二項 ( $e_{th}$ ) はオフセット項であり、定常状態におけるアクチュエータにおいて、関数  $h$  内の第一項が 0 以下となるような閾値とする。関数  $h$  内の第三項は、現在の電流センサ値に重み係数  $W_p$  を掛けたものからその後退差分に重み係数  $W_d$  を掛けたも

のを引いた値の絶対値であり、アクチュエータの消費エネルギーの変動を示している。これより、この2値化判別関数  $h(u)$  内の式  $u$  の値が正となった場合にアクチュエータに過負荷が発生すると定義する。制御周期 1 ms において一定の時間  $T$  ( $T = 100$  ms) 内に、上記判定式が一定値以上正となった場合に過負荷が発生したと判定するようにし、その時の関節角度を表す物として  $E$  で表記することとする。

### 2.1.2 カセンサを用いた手法

本研究では、カセンサの信号をそのまま判別式に入力するのではなく、力の変化量を判別式に入力することとする。力の変化量  $\Delta q$  は以下の式により求められる。

$$\Delta q(t) = q(t) - q(t-1) \quad (2.6)$$

判別式は、これまで電流センサで用いていた判別式と同様の式を用いる。これまで、判別式への入力には電流センサの値を用いていたが、今回はカセンサの変化量  $\Delta q$  を以下の式に入力することとする。

$$\begin{aligned} Q_j(t) &= h(u) \\ &= h\left\{W_i \sum_{\tau=1}^T |\Delta q(t-\tau)| - Q_{th} - (W_p \Delta q(t) - W_d(\Delta q(t) - \Delta q(t-1)))\right\} \quad (2.7) \end{aligned}$$

$$h(u) = \begin{cases} 1 & (u > 0) : \text{unexpected event} \\ 0 & (u \leq 0) : \text{normal state (under control)} \end{cases}$$

$Q_{th}$ : threshold,  $W_p, W_i, W_d$ : weight parameters

左辺第一項が、力の変化量の一定区間毎における積和にゲインを掛けたもの、第二項が閾値、第三項、第四項はそれぞれ比例項と差分項にゲインを掛けたものとなっている。

## 2.2 能動的な可動領域の獲得

一般的にマニピュレータの可動領域は、マニピュレータ自身の構造と作業空間の状況によって設定される。しかし、周囲の環境が変化するなど未知環境での作業を考え



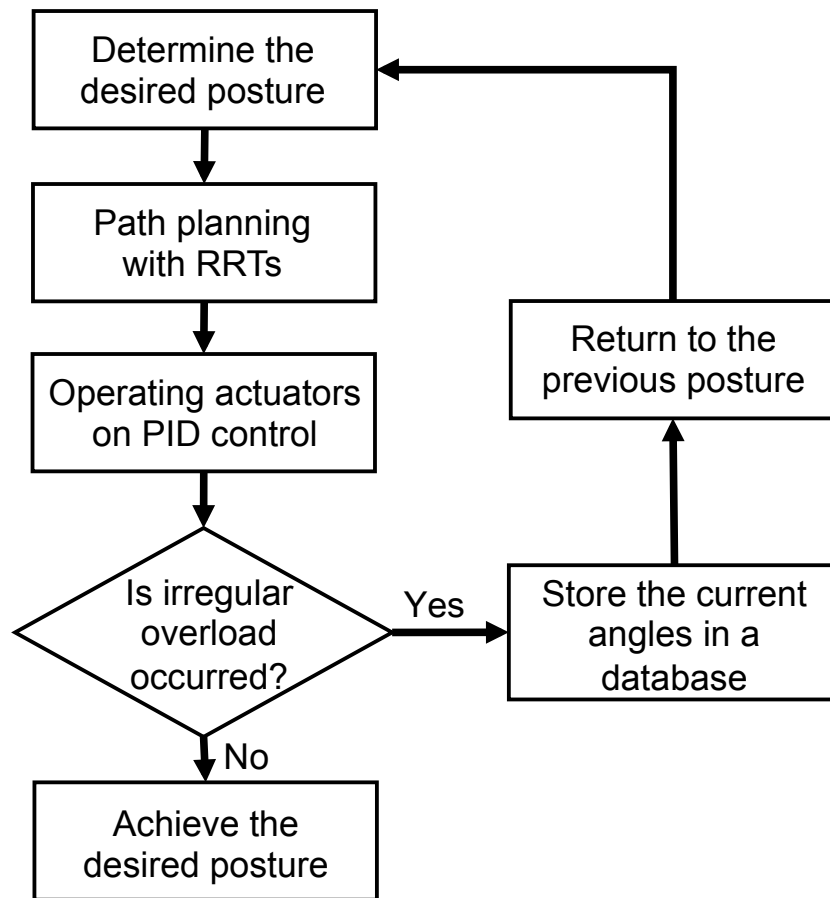


Fig. 2.6: 可動領域獲得のための動作手順

た場合、マニピュレータ自身による作業空間の学習が必要となる。そこで、本研究では前述のアクチュエータへの過負荷の検出を用い、過負荷が発生した時の姿勢を関節角度ベクトルとして記録することで作業空間の学習を行う。また、マニピュレータの移動を考慮しない場合、マニピュレータの作業空間は自身の動作に依存することになるので、可動領域を獲得することが作業空間の学習に繋がる。よって、マニピュレータを能動的に動作させ、過負荷が発生したときの姿勢を示す関節角度ベクトルを逐次記録することで、自身の可動領域を獲得することが可能となる。

マニピュレータが取り得る全姿勢内で過負荷が発生する姿勢があった場合、つまりある関節角度にて過負荷が発生した場合、それはマニピュレータの可動範囲に抵触していることになり、マニピュレータを実際に動作させ、取り得る姿勢を全探索すれば可動領域の獲得が可能となる。 $j$ 番目の関節の可動範囲  $R(j)$  は、過負荷が発生したときの関節角度を表す  $E$  とマニピュレータが取り得る全姿勢の関節角度ベクトル  $\theta$  の集

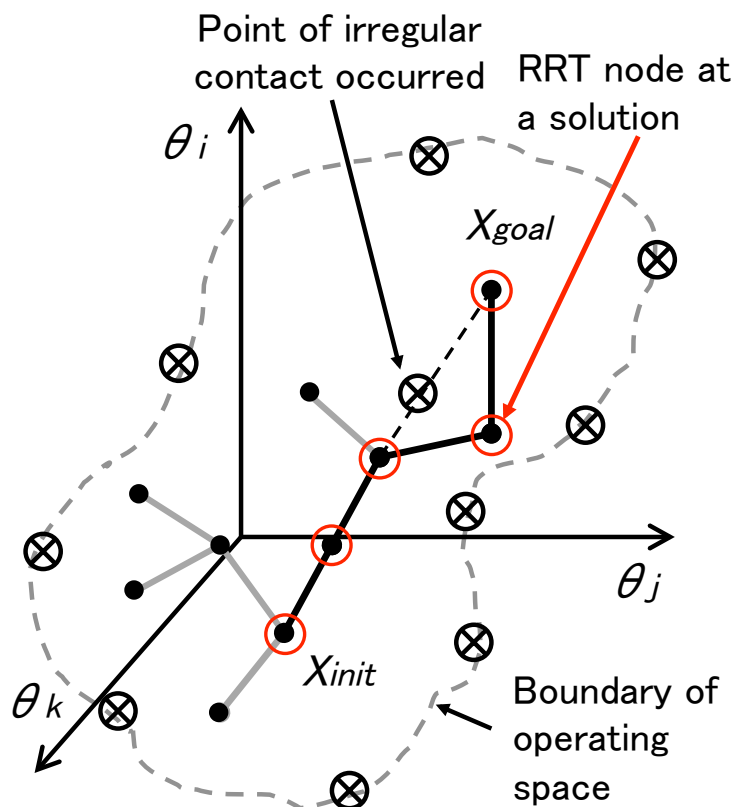


Fig. 2.7: 可動領域モデルを用いた経路計画の概念図

合  $\Theta = \{\theta\}$  により以下の式で与えられる。

$$R(j) = R(j; E, \Theta) \quad (2.8)$$

例として、1軸のみが動作する場合の可動範囲は動作範囲内に障害物等がない環境において、その関節軸の物理的動作限界  $\theta_{min}, \theta_{max}$  のみに左右され、その物理的動作限界の位置以上にマニピュレータが動作しようとするときアクチュエータに過負荷が生じ、(2.5)式により過負荷の検出が行われる。その結果、可動範囲は  $\theta_{min} < R(j; E, \Theta) < \theta_{max}$  となる。

Fig.2.6に可動領域の獲得方法を、Fig.2.7に提案手法を用いた経路計画の方法を示す。本研究では、マニピュレータの能動的な動作により、関節駆動部に発生した過負荷を検出するとともに、その時点の関節角度ベクトルを記録することで可動領域の獲得を行う。これを繰り返すことにより、過負荷の発生した関節角度ベクトルの記録が集まることでそのマニピュレータの可動領域が詳細に構築されることになる。

### 2.2.1 Rapidly-exploring Random Trees

---

```

BUILD_RRT( $x_{init}$ )
1   $\mathcal{T}.init(x_{init});$ 
2  for  $k = 1$  to  $K$  do
3       $x_{rand} \leftarrow \text{RANDOM\_STATE}();$ 
4       $\text{EXTEND}(\mathcal{T}, x_{rand});$ 
5  Return  $\mathcal{T}$ 

```

---

```

EXTEND( $\mathcal{T}, x$ )
1   $x_{near} \leftarrow \text{NEAREST\_NEIGHBOR}(x, \mathcal{T});$ 
2  if  $\text{NEW\_STATE}(x, x_{near}, x_{new}, u_{new})$  then
3       $\mathcal{T}.add\_vertex(x_{new});$ 
4       $\mathcal{T}.add\_edge(x_{near}, x_{new}, u_{new});$ 
5      if  $x_{new} = x$  then
6          Return Reached;
7      else
8          Return Advanced;
9  Return Trapped;

```

---

Fig. 2.8: The basic RRT construction algorithm [37]

本研究では、ランダム探索の手法である RRTs [37] により経路生成が可能な環境を提供する MSL [41] を用いる。MSL はポリゴンで作られる制御対象の 3 次元モデル及び初期姿勢と目標姿勢を与えることにより、関節空間上における初期姿勢と目標姿勢の点からお互いに向かって枝を伸ばすように経路を探索する。この経路探索の部分に RRTs が利用されており、Fig.2.8 にそのアルゴリズムを示す。RRTs は初期位置および目標位置のそれぞれ双方向からお互いに向かって枝を伸ばすように解空間の探索を行う。Fig.2.9 は、その枝を伸ばす動作を示したものである。図中、 $x_{init}$  が初期位置を  $x$  が初期位置が枝を伸ばそうする目標位置を  $x_{near}$  が  $x$  に最も近いノードである。解の探索時において、新しいノードは解空間上でのある長さ  $\epsilon$  だけ離れた位置にランダムで複数個作成される。このとき、 $x_{near}$  の次のノード  $x_{new}$  は  $x$  に最も近いものが選択される。このように目標位置に向けて枝を伸ばすようにして、解空間の探索を行っている。




Fig. 2.9: The EXTEND operation [37]

### 2.2.2 過負荷発生姿勢の情報のみに基づく経路計画

マニピュレータの動作中に異常な接触による過負荷を検出した場合、Fig.2.7の⊗で示したように、その時点のマニピュレータの姿勢を関節角度空間上に履歴として記録する。この図では、3次元として例を示しているが、実際には、ロボット腕部と同じ自由度である5次元の空間上の点として示される。この異常な接触による過負荷発生座標の近傍を避けるように経路計画を行う。つまり、実験を繰り返し有意なデータが蓄積されることで、図中の破線のように関節空間上で可動可能な領域を獲得することが出来る。

Fig.2.7における  $X_{init}$  が初期姿勢を、 $X_{goal}$  が目標姿勢の座標点を示しており、黒の実線が生成される経路である。また、黒い実線上に示された各点が解として与えられるノードである。RRTsによって  $X_{init}$  および  $X_{goal}$  からお互いに向かって双方に枝を伸ばすことによって解の探索を行っている。この各ノードにおける関節角度を1秒毎に制御対象に与えることにより、制御対象を動作させる。

Fig.2.10にMSLに与える腕部のモデルとMSLによって生成された経路の例を示す。ここでは、腕部のモデルの精確さが重要でないため、非常に単純なモデルを用いている。Fig.2.10の破線で作られた直方体の部分は、モデル上では存在しないが、実際のロボットでは胴体部にあたる。各関節に付された実線・一点鎖線の経路は、胴体部との自己衝突が生じると想定される代表的な腕部の姿勢を与えて計算した結果である。このように、異常な接触の発生座標を利用して可動範囲のマップを生成し、経路計画を行うことにより、胴体部を避けるような経路を生成することが出来る。




Fig. 2.10: RRTs を用いて生成された経路の例

## 2.3 可動領域の確率的学習

前述までの可動領域の獲得手法では、膨大な試行回数を行わないと詳細な自身と周辺環境を含む作業空間の学習は不可能である。そこで、学習データ数が少なくとも汎化能力が高く、スパースなデータにも対応な統計的学習の一種であるベイズ学習を用いることで、確率モデルとして可動領域を定義する。このときの可動領域は、自身の動作可能範囲内においてその姿勢を採ることで過負荷が発生することによる危険度が確率値として表現された空間であり、学習した確率モデルに関節角度ベクトルを入力することで、その姿勢の危険度を出力するものである。学習データは過負荷が発生した時点の関節角度ベクトルを逐次記録したものとする。

また、目標とするタスクを実現するための学習のフローチャートを Fig.2.11 に示す。経路計画を行い、動作、学習を繰り返すことで、目標とするタスクを実現する動作を可動領域の学習を行いながら獲得する。

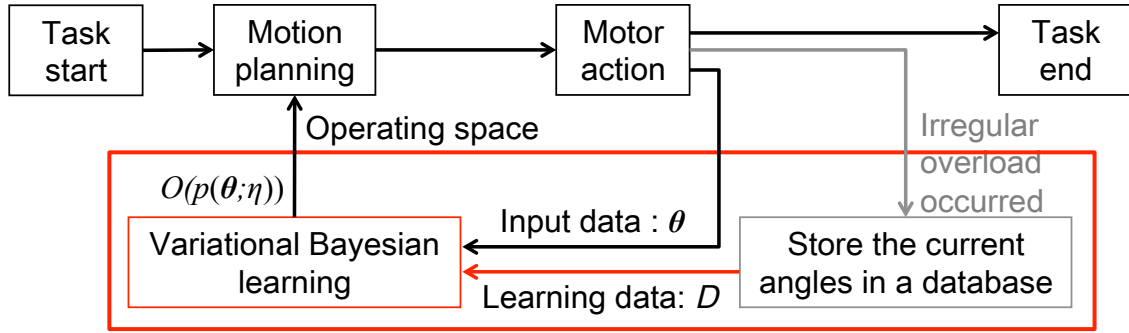


Fig. 2.11: 可動領域の自律的学習の手順

### 2.3.1 混合正規分布モデル

本研究では、可動領域を構成するモデルを次式のような混合正規分布とする。

$$p(\mathbf{x}; \eta) = \sum_{i=1}^m \alpha_i \mathcal{N}(\mathbf{x}; \mu_i, \mathbf{S}_i^{-1}) \quad (2.9)$$

ここで、 $\mathbf{x} \in \mathbb{R}^d$  は、次元  $d$  の入力である。本研究では、 $\mathbf{x}$  は制御対象であるマニピュレータの関節角度ベクトル  $\boldsymbol{\theta}$  となる。 $\eta = \{\alpha_i, \mu_i, \mathbf{S}_i\}_{i=1}^m$  は、混合要素数  $m$  における未知パラメータであり、混合比  $\alpha$ 、平均ベクトル  $\mu$ 、共分散の逆行列（精度行列） $\mathbf{S}$  が含まれている。学習の際には、 $\mathbf{x} = (\boldsymbol{\theta} - \mu_i) |\mathbf{S}_i|^{1/2}$  で正規化を行ったものを入力とする。また、 $0 < \alpha_i < 1$ 、 $\sum_{i=1}^m \alpha_i = 1$  とし、各確率密度関数  $\mathcal{N}_i$  それぞれは  $\mathcal{N}_i(\mathbf{x}) / \int \mathcal{N}_i(\mathbf{x}) d\mathbf{x}$  とすることで正規化し、その出力値は  $0 \sim 1$  の範囲を取る [53]。よって、 $p(\mathbf{x}; \eta)$  の出力値は、 $0 \leq p(\mathbf{x}; \eta) \leq 1$  として正規化される。そして、確率密度関数  $\mathcal{N}$  は次式のように定義され、

$$\mathcal{N}(\mathbf{x}; \mu_i, \mathbf{S}_i^{-1}) = (2\pi)^{-d/2} |\mathbf{S}_i|^{1/2} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \mu)^T \mathbf{S} (\mathbf{x} - \mu) \right\} \quad (2.10)$$

平均ベクトル  $\mu$ 、共分散の逆行列（精度行列） $\mathbf{S}$  でパラメータ化された多次元正規分布を表す。

### 2.3.2 変分ベイズ学習

統計的学習の有力なアプローチであるベイズ学習は、すべての未知量を確率変数として扱い、未知パラメータも確率として推定することができる [58]。しかし、ベイズ学習には困難な期待値計算を伴うため、解析的に求めることは困難なため、何らかの

近似を行う必要がある。そこで、本研究ではベイズ学習に変分近似を援用した変分ベイズ (VB: Variational Bayes) 法を用いる [59]。

変分ベイズ学習は、 $q(Z | m)$  と  $q(\eta_l | m)$  を反復アルゴリズムにより逐次推定することにより解を得る。ここで、 $Z$  は潜在変数 (非観測データ)、 $m$  はモデル指標 (混合分布モデルの場合、 $m$  は混合要素数に相当)、 $\eta$  は未知パラメータである。また、 $D$  を学習データ、 $k$  を反復ステップ数とすると、変分ベイズ学習の逐次推定アルゴリズムは以下のようなになる [54]。

[Variational Bayesian algorithm]

Step 1. 初期分布  $q(\eta | m)^{(0)} = \prod_{l=1}^L p(\eta_l | m)^{(0)}$  を設定し、  
 $k \leftarrow 0$  とする。

Step 2. 以下を収束するまで繰り返す。

(VB-E step)

$$q(Z | m)^{(k+1)} \propto \exp \langle \log p(D, Z | \eta, m) \rangle_{q(\eta|m)^{(k)}} \quad (2.11)$$

(VB-M step)

$l = 1, \dots, L$  について

$$q(\eta_l | m)^{(k+1)} \propto \exp \langle \log p(D, Z | \eta, m) \rangle_{q(Z|m)^{(k+1)}, q(\eta_{-l}|m)^{(k)}} \quad (2.12)$$

$k \leftarrow k + 1$  として再び VB-E step, VB-M step を繰り返す。

$\langle f(x) \rangle_{p(x)}$  は  $f(x)$  の  $p(x)$  に関する期待値 :

$$\langle f(x) \rangle_{p(x)} = \int f(x)p(x)dx \quad (2.13)$$

を表すものとする。また、 $\eta_{-l}$  は  $\eta$  中の  $\eta_l$  以外のパラメータ集合を表す。変分ベイズ学習は逐次最大化を行うアルゴリズムであるため、推定結果が試験事後分布の初期値に依存し、低品質な局所解に収束する可能性がある。これより本研究では、未知パラメータ  $\eta$  の初期値にある程度大きな値を取り、複数回試行した後の最も良い  $\eta$  を選択することとする。

### 2.3.3 可動領域のモデル化

変分ベイズ学習により混合正規分布の未知パラメータ  $\eta$  が与えられ、 $\mathbf{x} = \boldsymbol{\theta}$  の入力を与えられたとき、確率モデル  $p$  は次式のようなになる。

$$p(\boldsymbol{\theta}) = p(\boldsymbol{\theta}; \eta) \quad (2.14)$$

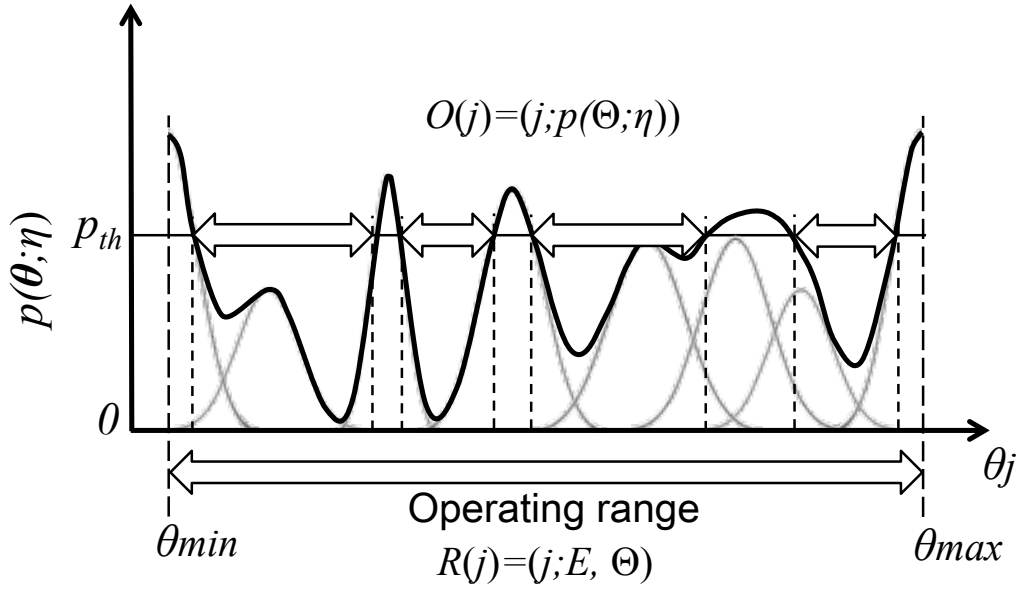


Fig. 2.12: 可動領域モデルと可動範囲の関係性

$p$  は  $\eta$  の学習に用いたデータ  $D$  に依存しているので、例えば  $D$  が過負荷が発生したときの関節角度ベクトルを記録したデータ  $D_A$  とすると、そのデータで学習した未知パラメータは  $\eta_A$  となり、 $p_A(\theta) = p_A(\theta; \eta_A)$  の値が大きいほど、入力した関節角度ベクトル  $\theta$  の姿勢で過負荷が発生しやすいこととなる。そして、可動領域  $O$  は次式で与えられる。

$$O = O(p(\Theta; \eta)) \quad (2.15)$$

ここで、 $\Theta = \{\theta\}$  は関節角度ベクトル  $\theta$  の集合で、制御対象のマニピュレータが取り得る全姿勢を表しており、可動領域が関節角度空間上に識別面としてモデル化されることを示している。また、ある関節  $j$  における部分可動範囲は次式のように定義される。

$$O(j) = O(j; p(\Theta; \eta)) \rightarrow R(j; E, \Theta) = R(j) \quad (2.16)$$

$$O(j) = O(j; p(\Theta; \eta)) \quad (2.17)$$

Fig.2.12 に (2.17) 式を模式化したものを示す。 $\theta_{min}, \theta_{max}$  は (2.8) 式の説明に用いたものと同じ、その関節軸の物理的動作限界である。可動領域  $O$  は混合正規分布による



混合モデルで表されるため、図中の薄い実線で表されるように複数の正規分布  $N_i(\mathbf{x})$  に混合比  $\alpha_i$  による重みをかけたものによって構成される。そして、それらを合成した混合正規分布  $p(\mathbf{x}; \eta)$  を太い実線で表している。また可動領域から生成される部分可動範囲は、可動領域の部分領域  $O(j)$  として表され、 $p(\theta; \eta)$  の大きさの閾値  $p_{th}$  の大きさに左右されることとなる。このとき、可動領域から生成される部分可動範囲は他の関節の影響を強く受けていることを示している。ある関節軸  $j$  のみに着目した場合の可動範囲  $R(j)$  と可動領域の部分領域  $O(j)$  の関係は、Fig.2.12 のようになる。実際には関節軸  $j$  の可動範囲は他の関節軸の影響を受けるため、可動領域の構築が必要である。マニピュレータが取り得る姿勢を全探索して可動範囲から可動領域を構築するには、膨大な探索時間が必要となるため、本研究では可動領域を混合モデルで表し、その確率モデル  $p$  の未知パラメータ  $\eta$  を学習していくことで可動領域を形成する。そして、 $p_{th} = 1$  のとき可動領域  $O(j)$  における可動範囲は  $\theta_{min} < O(j; p(\Theta; \eta)) < \theta_{max}$  となり、 $R(j)$  と同一となることから可動領域はそれぞれの関節の可動範囲も内包することとなる。よって、確率モデル  $p$  の未知パラメータ  $\eta$  を学習していくことで、可動領域を形成する。

## 2.4 可動領域を用いた経路計画

前述の通りに求めた可動領域を経路計画に用いるにあたり、過負荷が発生したときの関節角度ベクトルを記録したデータを  $D_A$ 、最新の関節角度ベクトルから一定区間遡った関節角度ベクトルを記録したデータを  $D_T$  とし、それぞれに対応する危険度と安全度に相当する二つのモデル  $p_A, p_T$  を用いることとする。 $p_A$  は前述までに定義したものと同一であり、関節角度ベクトル  $\theta$  を入力したとき過負荷が発生する危険度を出力するものであり、 $p_T$  はある一定期間における安全度を出力するものである。この二つのモデルを以下の式で組み合わせた混合モデル  $p_O$  を経路計画に用いる。

$$p_O(\theta) = \{p_A(\theta; \eta_A) + (1 - p_T(\theta; \eta_T))\} / 2 \quad (2.18)$$

ここで  $\eta_A, \eta_T$  は、それぞれ学習データ  $D_A, D_T$  により変分ベイズ学習により与えられる混合モデルの未知パラメータである。過負荷検出で1が出たときのデータで学習した  $p_A$  と0が出たときのデータで学習した  $p_T$  は相反関係にあり、 $p_A, p_T$  の出力値は(2.9)式にて正規化されているため、その出力値は0~1の範囲を取るため、(2.18)式は成り立ち、その出力は1に近いほど過負荷が発生しやすくなる確率モデルとなる。その出力の値が大きいほど過負荷が発生しやすくなるモデルとなる。

(2.18)式を経路計画に用いる場合、一先ずRRTsにより経路計画を行い、出力された経路を示す関節角度ベクトルを(2.18)式に入力していき、出力された値がある一定

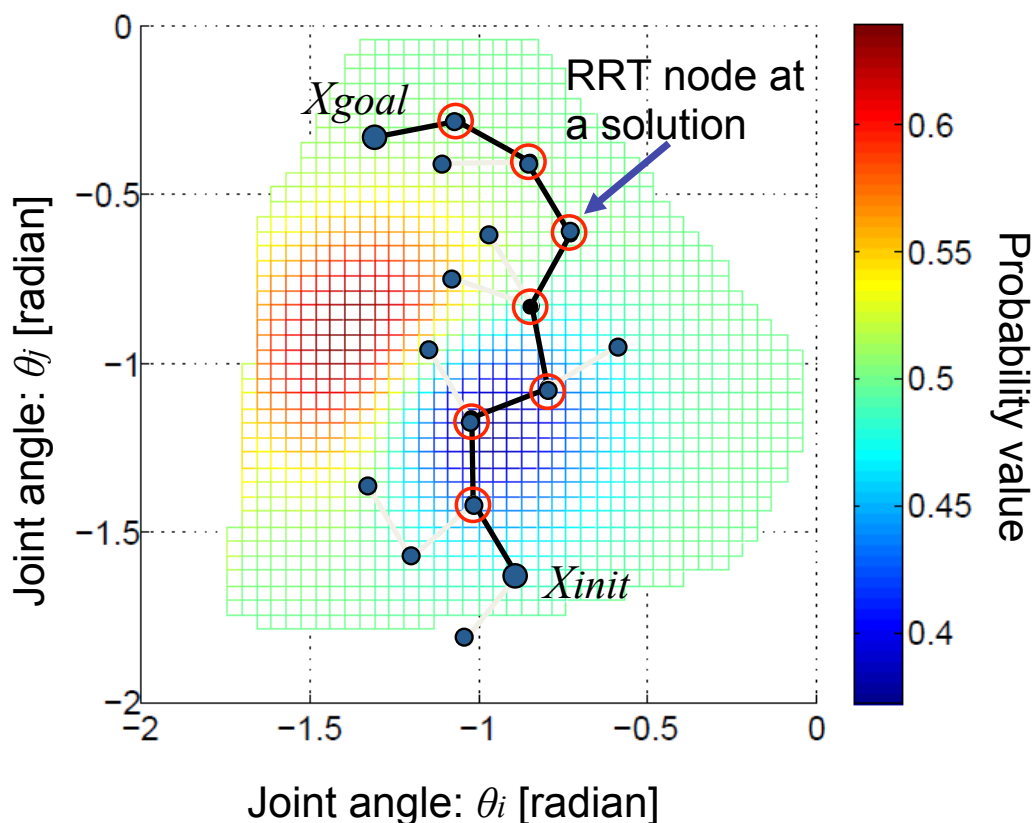


Fig. 2.13: 確率モデルを用いた経路計画

値 ( $p_{th}$ ) を超える場合、再度経路計画を行うことで、危険度の少ない経路を動作することが可能となる。Fig.2.13 にそのモデル図を示す。初期姿勢のノードから目標姿勢のノードへランダムにツリーを形成する際、そのノードの姿勢を確率モデルで評価し、過負荷の発生確率が少ないノード間を繋げていくことで、より安全な経路を計画することができる。

## 2.5 提案手法における前提条件

本研究で提案している手法を実際にマニピュレータに適用し実験を行うに当たって前提となる基本的な条件について述べる。まず、接触に関する前提として、

- 環境との接触を前提として作業空間の学習を行うため、作業空間内に破損しやすい物体を配置しない。

- マニピュレータには十分な剛性を備えたものを用いる。
- 動作トルクに十分な余裕がある。
- 動作速度は一定である必要はないがある程度ゆっくり動作させる。
- 接触検知を可能とする内界センサが搭載されている。
- 接触位置を検出しない。

を挙げる。

実験においては、作業空間の学習が提案手法にて行えるかを確認するために、剛体と剛体同士の接触を前提に考えているため、作業空間内に破損しやすいものは配置せず、マニピュレータにも十分な剛性を備えたものを用いる。また、マニピュレータのトルクが不十分な場合自身の質量による慣性モーメントの影響を受けやすくなるため、動作トルクにも十分な余裕が必要である。しかし、動作速度を速くしすぎた場合にも慣性モーメントの影響が大きくなるため速度を抑えて接触をさせる必要がある。そして、接触を検出するために内界センサを用いるためその搭載は必須であるが、接触位置は敢えて検出しないこととする。これは、接触位置による重み付けをせずとも学習が可能であることを確認するためである。

さらに、学習に関する前提譲渡して、

- 平面上で動作させる際には2自由度以上、直交座標空間上で動作させる際には3自由度以上の多自由度マニピュレータを用いる。
- 各駆動関節軸毎に関節角度値が取得できること。

を挙げる。

接触位置ではなく接触姿勢の近傍を避ける経路の生成を可能とするために、多自由度マニピュレータを用い、その学習を関節角度空間で行うために、各関節軸の関節角度値の取得が必要となる。

## 第3章 システム構成

### 3.1 ハードウェア構成




Fig. 3.1: 多自由度マニピュレータ搭載人間型ロボット (Genie)




Fig. 3.2: 5DOFs マニピュレータ

Fig.3.1 は、本研究で利用した人間型ロボット (Genie) の外観図である。Genie は上半身のみで構成され胴体部は壁面に固定されており、頭部 8 自由度、胴体部 3 自由度、右腕部 7 自由度、右手部 4 自由度、左腕部 5 自由度の計 27 自由度を持つ。Fig.3.2 は、制御対象とした左腕部を示しており、その稼働方向は図中の矢印にて示してある。S1, S2, A3 はモータによる直接駆動、A1, A2 はベルト駆動する。また、全ての駆動部にはハーモニックドライブギアを用いている。各モータに流れる電流はモータドライバに内蔵された電流センサにて計測する。頭部には単眼の視覚センサが搭載されている。

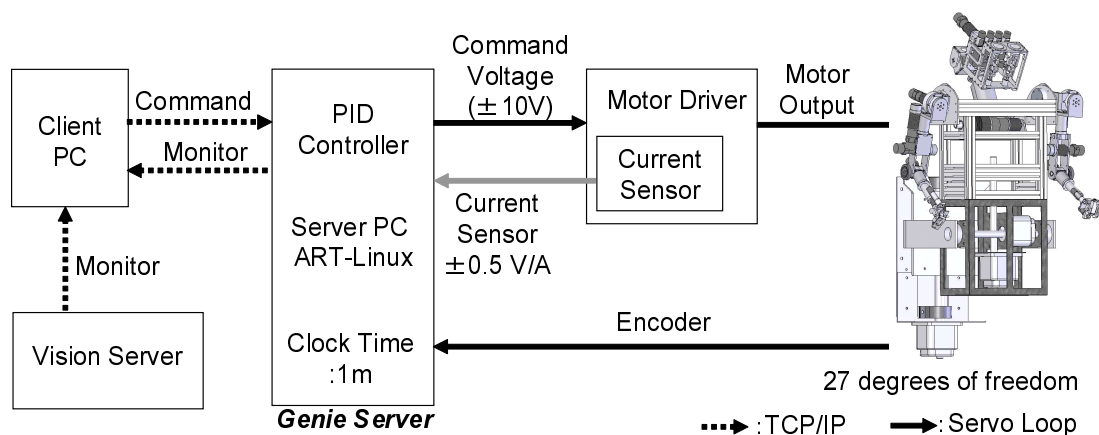


Fig. 3.3: システム概要

## 3.2 ソフトウェア構成

Fig.3.3に制御システム構成を示す。図中、黒い線が本システムのサーボループを示しており、破線はTCP/IPを示している。本システムはClient PCからの指令を受けてServer PCが実行するClient-Server方式を採用した。Client PCでは経路計画を行うとともに、生成した経路をServer PCに送ることでServer PCが制御対象である人間型ロボットを制御する。また、Client PCは人間型ロボットのセンサ情報をServer PCから受け取っており、その情報に基づき制御指令を送る。Vision Serverは人間型ロボットの頭部に搭載されたカメラ画像を解析して情報をClient PCへ送る。制御用のServer PC(CPU:Celeron, 2.00 GHz, Intel)は実時間性を確保するためにART-Linux OSを利用する。また、Server PCにはHRP Interface Boardが2枚用いられており、Counter 32ch, A/D 32ch, D/A 32chまで対応可能である。

Fig.3.4は、人間型ロボットを制御するためのクライアントアプリケーションである。各種サーバとの通信モジュールを備えるとともに、スライダバーによる人間型ロボットの制御を可能としている。このアプリケーション内には、経路計画のモジュールであるRRTsが組み込まれており、タスク実行時には自動的に経路計画を行い、ロボットが動作する仕組みとなっている。また、このクライアントアプリケーションから数値計算ソフトであるMATLABを呼び出すことも可能であり、変分ベイズ学習をMATLABで行えるようになっている。

(3.1)式は本システムにおけるPID制御則を示している。制御周期は1 msecとし、各関節駆動は角度指令に基づくPID制御によって行う。

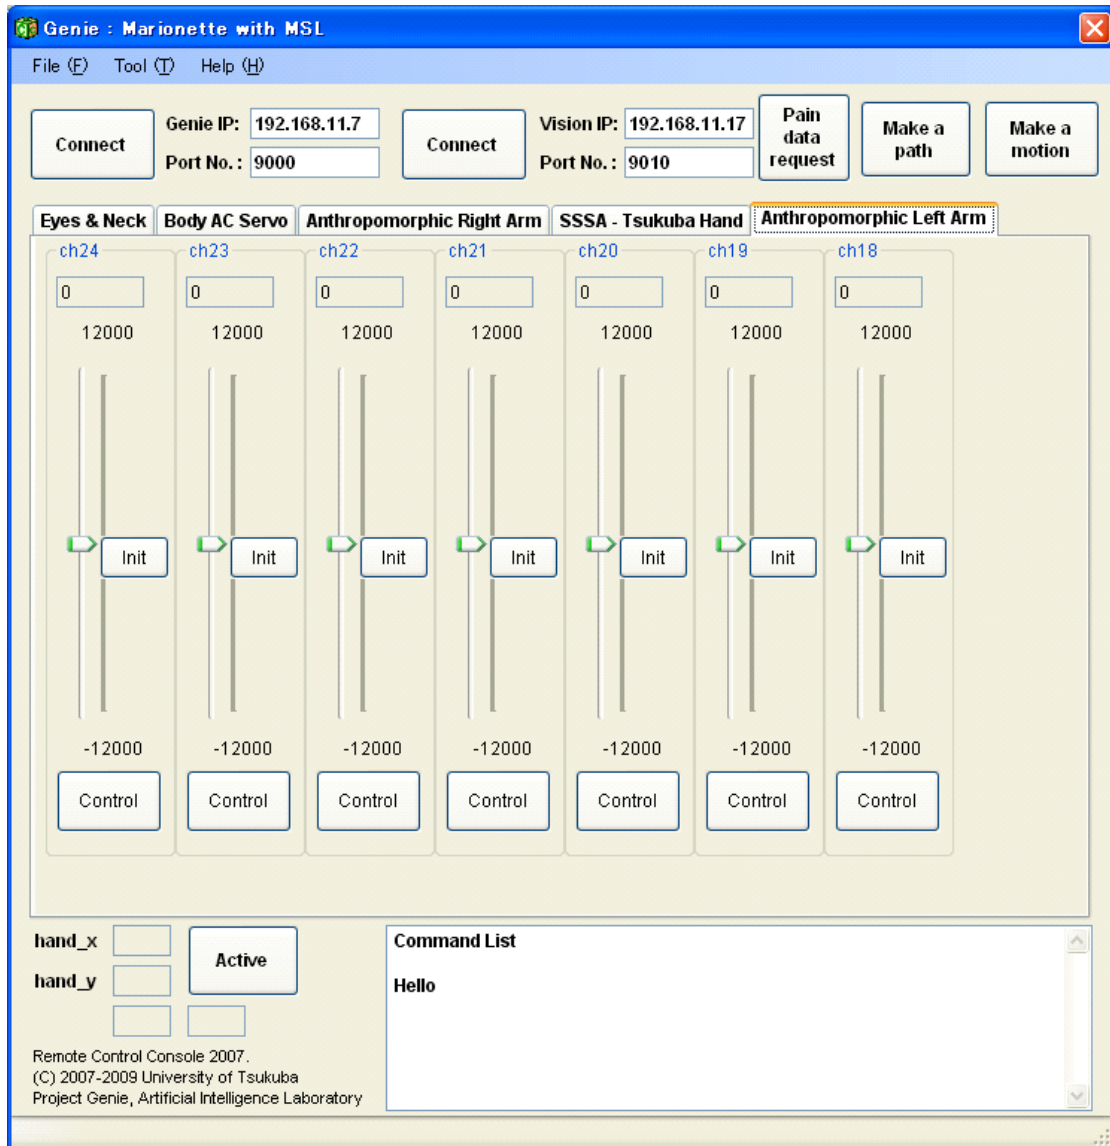


Fig. 3.4: クライアントアプリケーション (Marionette)

$$V_i = K_p(\theta_r - \theta_i) + K_i \sum \frac{\theta_r - \theta_i}{1000} + K_d(\theta_i - \theta_{i-1}) \quad (3.1)$$

$V_i$ : 指令電圧値,  $\theta_r$ : 目標角度  
 $\theta_i$ : 現在角度,  $\theta_{i-1}$ : 1 周期前の角度  
 $K_p, K_i, K_d$ : ゲインパラメータ

右辺第一項は目標角度  $\theta_r$  から現在角度  $\theta_i$  を引いた偏差であり, 右辺第二項は累積誤差であり, 偏差を 1 msec で和分したものである。右辺第三項は角速度であり, 後退差分によって求めている。これらの項に経験的に定めた PID ゲインを掛けることで指令電圧  $V_i$  を定める。



## 第4章 実験

### 4.1 接触検出実験

#### 4.1.1 電流センサを用いた過負荷検出実験




Fig. 4.1: 過負荷検出実験に用いた関節

まず，提案手法において過負荷の検出によって接触の検出が可能であることを確かめるため実験を行う。Fig.4.1の関節に角度指令命令を与え，その関節を目標姿勢へ動作させる。その過程で障害物の設置及び，自己衝突を起こす命令を与えることで(2.5)式により発生する過負荷を検出する。この時，時系列に記録した目標角度値，現在角度値，電流センサ値のログをパソコン上に取り込み，そのログを使い(2.5)式において経験的に定めたパラメータである  $e_{th}$ ,  $W_p$ ,  $W_i$ ,  $W_d$  の決定も行った。ある関節が物理的な限界可動範囲以上に動作しようとした場合 (Fig.4.2 Stage 3 のような状態)，アクチュエータには過負荷が発生しているはずであり，この時の電流センサ値の絶対値を総和したものの重み係数  $W_i$  をある程度大きな値として最初に決定する。次に，同一のデータを用いてアクチュエータの動作が定常状態 (Fig.4.2 Stage 1 のような状態) に

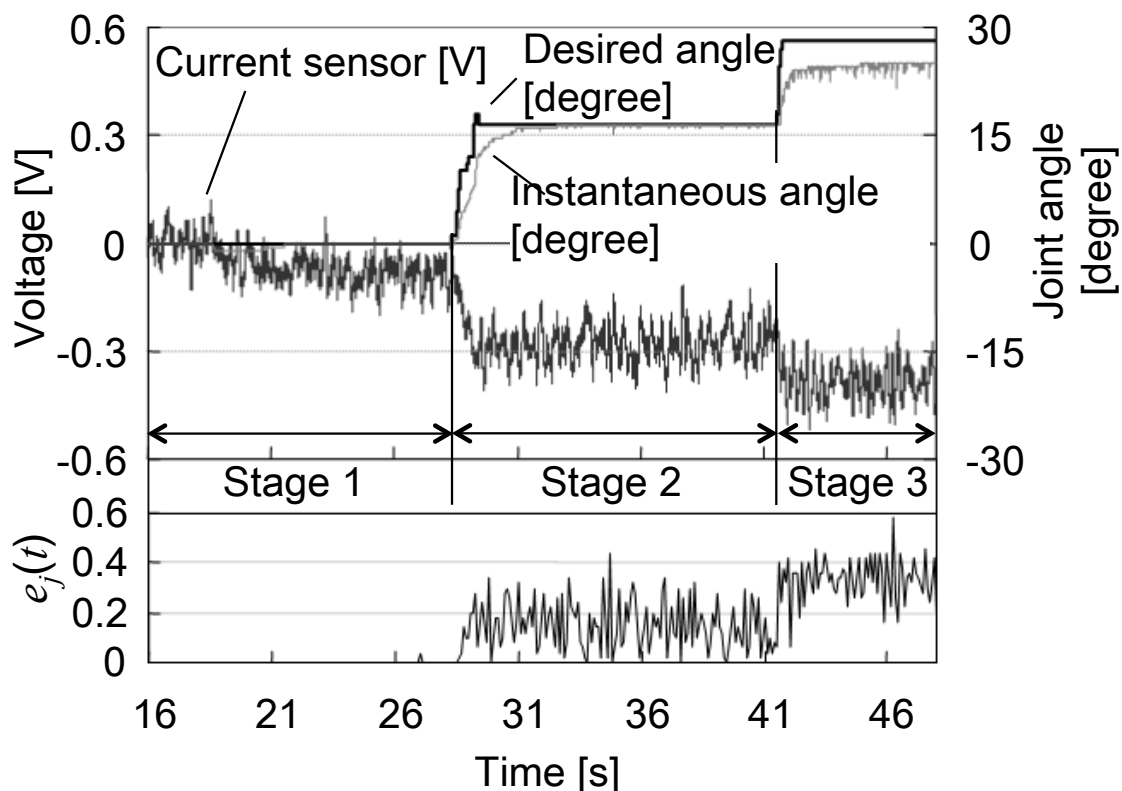


Fig. 4.2: 電流センサ値と過負荷の検出

ある場合は、過負荷が発生しないはずであるため、 $h$ 内の式 $u$ が0以下となるように $e_{th}$ を決定する。最後に、アクチュエータの急激な動作による誤検出を防ぐため、同一のデータにおいて目標角度値が急激に変化する状態 (Fig.4.2 Stage 2 の立ち上がりのような状態) を用いて  $W_p, W_d$  の重み係数を決定する。以上のような手順で、(2.5) 式における各パラメータを経験的に定めた。

パラメータ決定後、同一の実験を行いその結果を Fig.4.2 に示す。上部分の図の太線が目標角度、細線が現在角度である。関節角度  $17^\circ$  のあたりに障害物があり、目標角度に近づけないようになっている。また、障害物を取り除いた後も現在角度が  $25^\circ$  以上に到達しないことが図からわかる。この  $25^\circ$  が可動範囲の限界であり、自己衝突を起こしている状態である。下部分の図は 100 ms 毎に、発生した過負荷の総和をとり、100 ms で平均した過負荷発生濃度のグラフである。約 27 s の時点でも一瞬、過負荷が発生しているが、最も顕著に発生しているのは目標角度に到達できていない状態の時である。特に、約 42 s 時点以降は駆動部が物理的制約により目標角度へ到達できない状態を示しており、常に過負荷が発生していると言える。

また、約 27 s の時点でわずかな時間、過負荷が発生しているが、これは有意な値とは見なされない。このような一瞬だけ発生する過負荷を抑制するため、100 ms 中に 5 回以上過負荷が発生したときに過負荷を知覚する方式を用いることで、誤検知を回避することができる。

#### 4.1.2 カセンサを用いた接触検出実験




Fig. 4.3: iCub ( developed by IIT[12])

Fig.4.3 に示す小型ヒューマノイドロボット iCub を用いて腕部への衝突の検出を行う。これは、IIT (Italian Institute of Technology) との共同研究として行った。iCub は全身 53 自由度を持つヒューマノイドロボットで、腕部は各 7 自由度と冗長自由度を持っており、肩から肘の間に力センサが埋め込まれている。

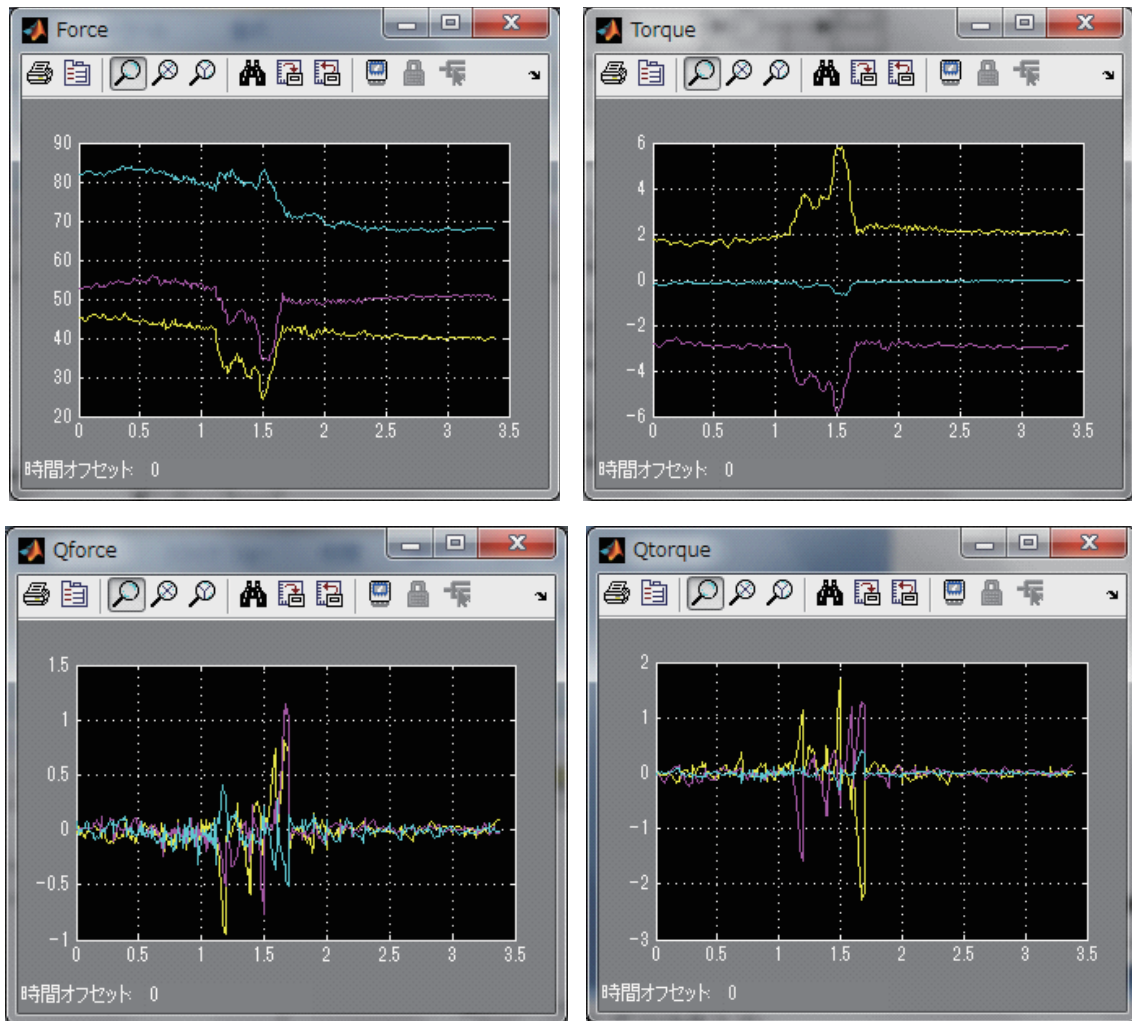


Fig. 4.4: カセンサを用いた接触検出

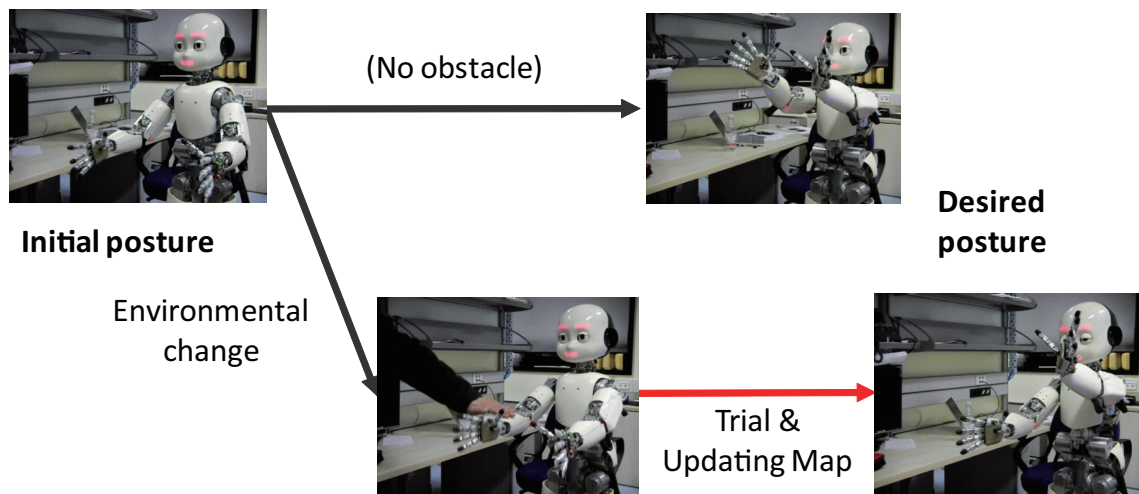


Fig. 4.5: カセンサによる接触検出実験

Fig.4.4 は実験に用いた 6 軸の力センサの力とトルク, (2.7) 式による腕部振り上げ動作時において衝突を行ったときの出力結果を示している。図上部, 左が力, 右がトルクを, 図下部, 左が力の衝突の検出結果を, 右がトルクの衝突の検出結果を示している。図上部を見る限り, 力センサでの衝突の検出は十分可能であることが見て取れる。特に, トルクに関しては, 値が顕著に変化していることが見て取れる。図下部は (2.7) 式の出力結果を示しており, この値に閾値をもうけることで衝突の検出を行うこととする。

Fig.4.5 に示すように実験を行った。図中, 上部左の初期姿勢から右の目標姿勢までを動作することとする。ロボット動作中に図中, 下部左のようにロボットの動作を妨げるように人の手により, ロボットの腕部を叩くこととする。(2.7) 式の出力結果により, 衝突を検出した場合, ロボットは検出した方の腕部の動作を停止するとともに, 表情を変化させる。また, 衝突を検出しなかった方の腕部はそのまま動作を継続することとした。その結果は, Fig.4.5 下部, 右のようになる。このことより, 力センサによる自身の状態変化を検出することが可能となった。

## 4.2 荷重増加実験

手首部の先端にワイヤを通じて 200 g から 1000 g まで 200 g 毎に異なる荷重を取り付け, 可動範囲獲得のための動作を行なわせた結果を Fig.4.7 に示す。Fig.4.7 の 0 g の部分が無負荷時におけるある関節について獲得した可動範囲を示したものである。なお  $\theta$  は関節角度を示す。




Fig. 4.6: 鉛直方向への荷重増加

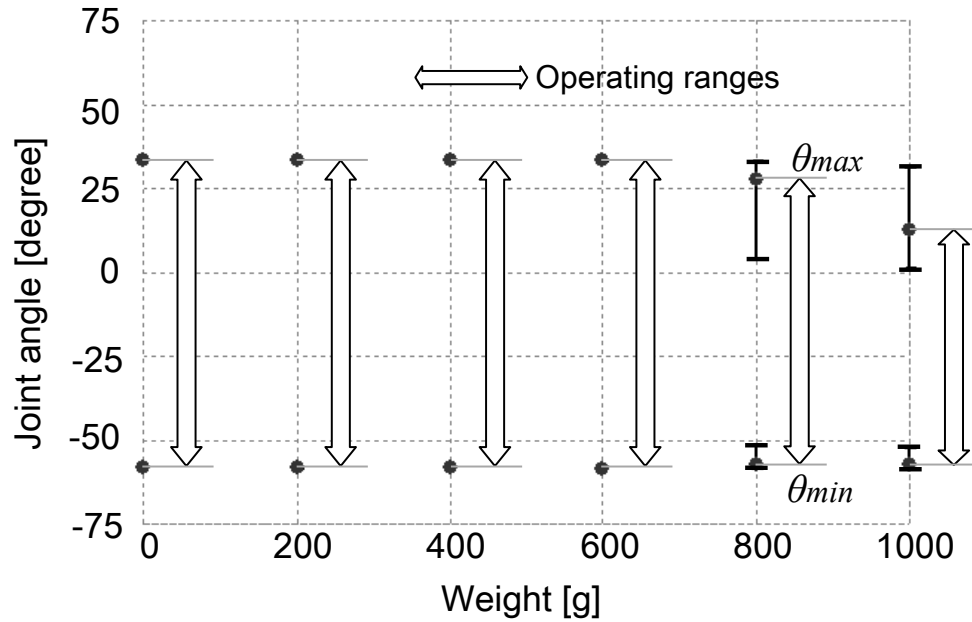


Fig. 4.7: 鉛直方向の荷重増加実験による可動範囲の変化

Fig.4.7に示す通り、この関節軸は鉛直方向に駆動するため、荷重が増加するにあたり過負荷が発生しやすく、無荷重のときに比べて可動範囲が小さくなっている。これは、この関節が荷重の持ち上げを行う部位に相当するからである。このように、マニピュレータの姿勢や外部環境の変化により異なる可動範囲を自身の動作と電流センサの値により獲得できていることがわかる。

また、このことから過負荷を知覚することで重力方向への動作を知ることができる。Fig.4.7において、持ち上げる動作方向である $\theta_{max}$ が荷重を大きくするほど小さくなっていることが見て取れる。つまり、重い物を持ち上げる程、過負荷が発生しやすいということをマニピュレータが学習することで、重力方向を知ることにも可能となる。

## 4.3 接触に基づく環境変化への適応

マニピュレータ自身の能動的な動作により、作業空間への接触が起こった際の関節駆動部への過負荷の検出により環境変化が起こった際に動作の適応が行えるかを実験により検証した。まず、1自由度にて過負荷の検出のみにより動的に可動範囲を更新することで環境変化に対して動作を適応する単純な実験の後、多自由度にて動作途中の過負荷発生姿勢の集合とその近傍を避ける経路計画にて障害物挿入による環境変化が起こった際に障害物回避動作として環境変化への適応が行えるかを実験した。

### 4.3.1 1自由度での環境変化への適応

提案手法が未知環境の変化に対して適応可能であることを確認するために、人間型ロボットの右腕部A2を用いて実験を行う。まず、A2の関節にある範囲を適当な速度で往復し続けるタスクを与える。その後、A2の動作軌道上にFig.4.8のように障害物を挿入し、A2の可動範囲が能動的に変化することを確認する。ただし、A1、A3、W1、W2の関節は初期位置を目標値として、PID制御を行うこととする。また、肩部(S1、S2)の関節はモータフリーとする。

Fig.4.9に異常な接触により発生する過負荷の検出を指標として環境の変化に対して、自身の可動範囲を能動的に獲得した様子を示す。図中、 $\theta_{max}$ 、 $\theta_{min}$ は事前に環境に物体が無い状態で自身の構造による物理的制約のみから定められたA2の限界可動角である。図中の丸で示した時点で異常な接触による過負荷が検出された。障害物は約25sの時点で挿入し、約38sで取り除いた。約30sのときと約35sのときに、腕部が障害物に衝突し、関節駆動部において過負荷が検出された。最初の衝突時に限界可動角の更新が行われたため、2回目の衝突時には障害物に軽く接触した程度だった。






Fig. 4.8: 障害物挿入による環境変化

また、新たに獲得した限界可動角に到達した際には、この角度より常に少し大きな動作を行うことで、新たな限界可動角を探すアルゴリズムを実装した。これにより、障害物を取り除いてやれば、次第に元の限界可動角に戻る様子が約 43 s ~ 83 s の部分から見て取れる。

このように、あるタスクを実行中に環境の変化が起こったとしても、障害物のモデルを予め定めることなく異常な接触による過負荷の検出を用いることで、アクチュエータ予期しない過負荷から保護するだけでなく、自己の能動的な動作により可動範囲を獲得することが出来た。

### 4.3.2 多自由度での環境変化への適応

Fig.4.10 の左上方に示す初期姿勢と右上方に示す目標姿勢における各関節の角度を MSL に与える。この時、初期姿勢と目標姿勢を繋ぐ最短経路上に障害物がなければ、図中の右上方の写真中の矢印で示すような、初期姿勢から目標姿勢に対し直線的な動作をすることが可能である。しかし、図中の左下方のようにその経路上に障害物を



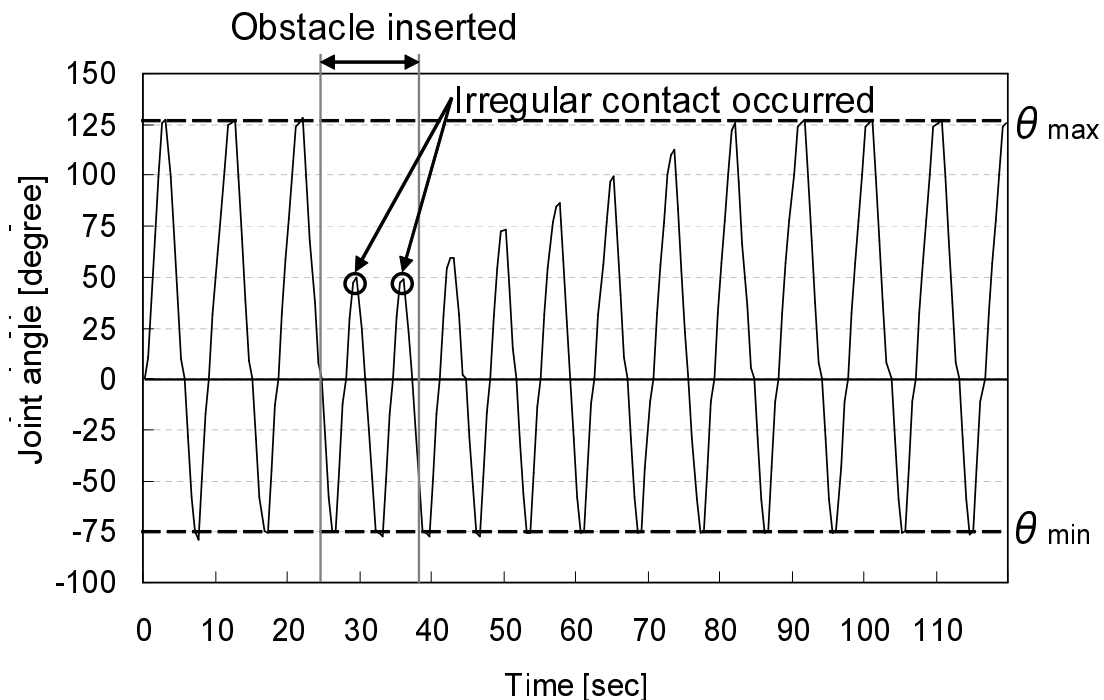


Fig. 4.9: 環境変化への適応動作

挿入した場合、それを回避するように動作する必要がある。そこで本実験では、提案手法により、外部環境のモデルを用いずに障害物を回避する経路の探索が可能であるかについて検証する。また、Fig.4.11のようにカメラ画像による入力から背景差分によって、環境の変化を識別するとともに、その画像状態にあわせて、適用する可動角マップを逐次更新することにより、障害物を取り除いた場合、再度、最短経路を生成することが可能である。

最初に、障害物がない状態にて経路計画を行い、制御対象である腕部を動作させた。この実験に用いている RRTs のアルゴリズムは関節角度空間上だけでなく、実空間上も考慮に入れて経路計画を行っているため、ほぼ最短経路を一回で生成することが可能であった。

次に、Fig.4.10に示す通り、初期姿勢と目標姿勢の最短経路上に障害物を挿入し、実験を行った。このとき、画像変化の識別により、ロボットは自動的に適用する可動角マップを変更し、可動範囲の獲得を行う。学習の初期段階においては、障害物との衝突を繰り返すが、自己衝突や外部環境との接触があった場合、提案手法により異常な接触が検出され、自動的に初期姿勢に戻るようになっているため、関節駆動部への過大な負荷は回避出来る。さらに、数十回程度の試行を繰り返す内に、Fig.2.7のような

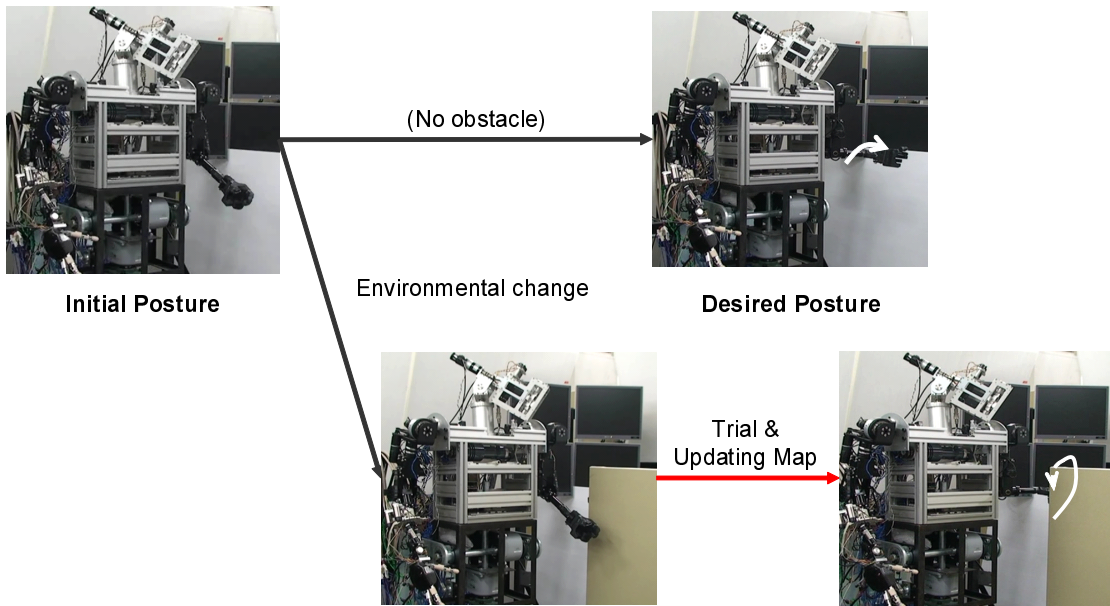


Fig. 4.10: 環境変化への適応実験




Fig. 4.11: 視覚情報に基づく可動角マップの切替




Fig. 4.12: 環境変化への適応による障害物回避動作

関節空間上の可動角マップが更新されていき、最終的にはFig.4.12のような障害物を回避する動作が得られた。

しかし、実際には障害物との衝突は起きており、提案手法における過負荷の検出が見られなかったために、目標姿勢に到達した。これは、剛体部分での接触および、負荷のかかった関節が肩の関節であるS1, S2だったからである。この二つに使われているモータは高トルクかつハーモニックドライブを介してのダイレクトドライブであるため、過負荷の発生しにくいからである。

また、今回用いたRRTsにおける探索の手法が実空間上での最短経路を考慮しているため、過負荷発生座標の近傍の姿勢を避けたとしても、実空間上での経路が、障害物を回避する経路になら事態が発生した。この問題を解決するためにも、関節角度空間上に可動領域を作成する必要がある。

## 4.4 変分ベイズ学習による可動領域の獲得

### 4.4.1 リーチングタスクによる姿勢情報の獲得




Fig. 4.13: リーチングタスクの目標領域

ロボット自身の能動的な動作によって、可動領域の構築が行えるかを確認するために、人間型ロボットの左腕を制御対象として、リーチングタスクを行うことで、学習データとなる姿勢情報の獲得を行った。Fig.4.13に示すように $3 \times 3 \times 3$ 領域に分け、その各領域に予め姿勢を用意しておく。ロボットは視界に特定の色の物体を検出した場合、その物体のある領域を決定し、その領域に設定されている姿勢と現在姿勢の関節角度情報を基に経路計画を行う。動作の流れは以下のように行われる。

1. 視界にある目標物が存在する領域の決定
2. 領域に定められている目標姿勢と現在姿勢，可動角マップを基に経路計画
3. 生成した経路を基に動作を開始
4. 動作中に異常な接触によるモータへの過負荷を検出した場合，その姿勢を稼動角マップに記録するとともに，動作を開始する前の姿勢に経路を逆にたどり戻る




Fig. 4.14: リーチングタスクにおける動作軌道と過負荷発生位置

以上のような動作を繰り返し行うことで、可動角マップを更新して行き、作業可能な空間の構築を行うこととする。

Fig.4.14は上記の動作を72回連続で行ったときの腕部手先位置の移動経路と過負荷が発生した点の手先位置を示している。実線が手先位置の移動経路で黒い四角形が過負荷発生時の手先位置である。そして、Fig.4.15が5回、35回、72回の時点での学習の様子を示したものである。図中の円の中心点が可動角マップに記録された関節角度での姿勢、つまり過負荷が検出された姿勢の時の手先位置で、この姿勢は経路計画にも用いているDHパラメータを用いて順運動学を解くことによって得た。ロボットは手先位置がこの円の領域内になるような姿勢を避けるように経路計画を行っている。



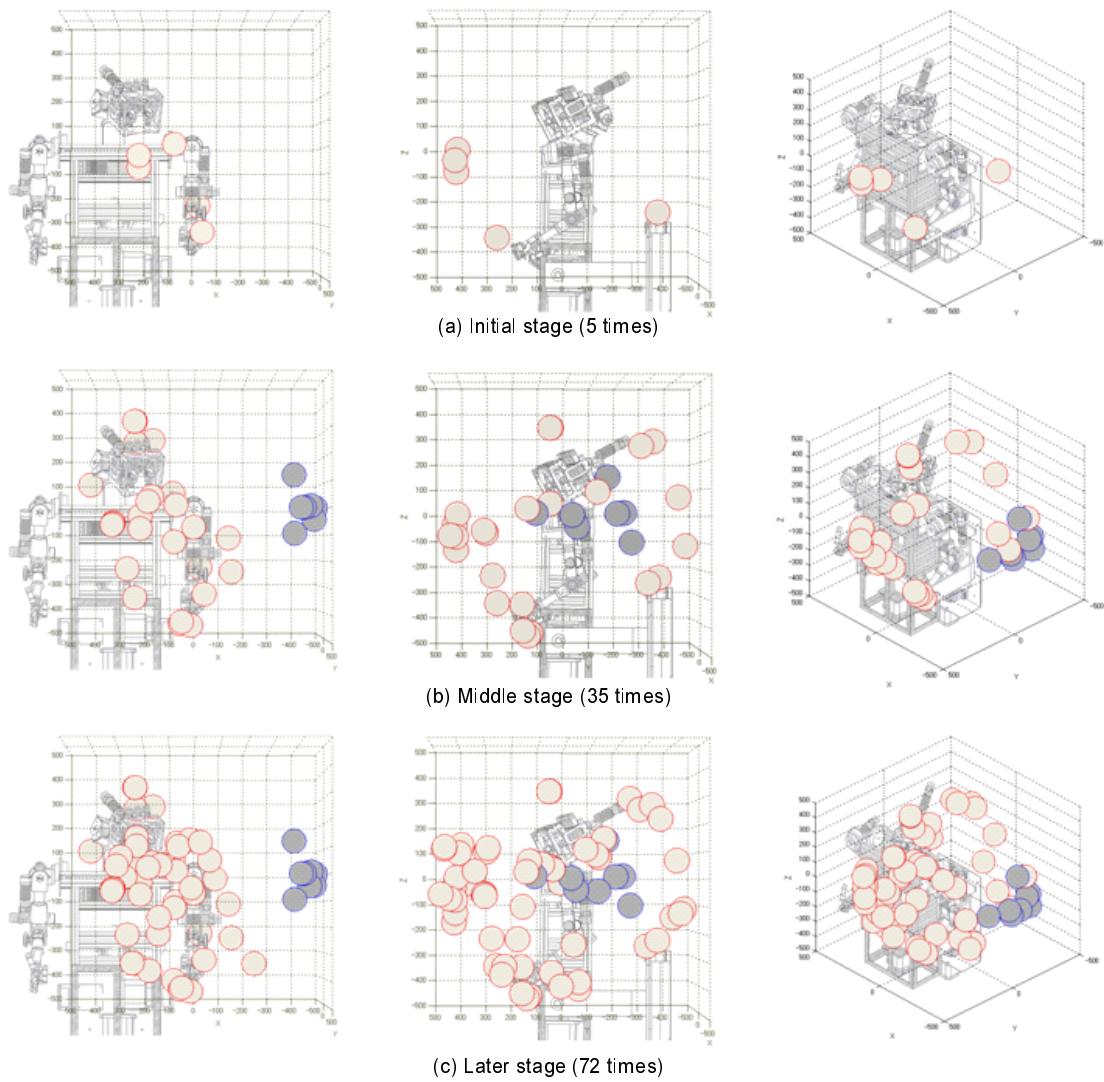


Fig. 4.15: 接触による過負荷発生時の手先位置

ただし、実際には関節角度にて避ける幅を与えているので、図中の円のような等方性の球体にはならない。ロボット左腕側の黒い円が外部環境との衝突を示しており、この部分には実際の環境では壁が存在した。また、それ以外の部分は自己衝突により発生した過負荷を検出した姿勢の手先位置である。このように試行回数を増やす毎に自身が動作可能な範囲を獲得していっていることが見て取れる。

#### 4.4.2 学習データ

変分ベイズ学習の学習データである異常な接触による過負荷が発生した時の関節角度とは、Fig.3.2 に示した左腕5自由度の関節角度に相当する。

学習データ  $D_A$  には前小節のリーチングタスクにより得た異常な接触による過負荷発生時の関節角度座標を用いた。モデルの混合比  $m$  を 15, 学習データの次元は 5, そのデータ長は 72 である。

#### 4.4.3 変分ベイズ学習

仮定した確率モデル ((2.9) 式) の未知パラメータ  $\alpha, \mu, \mathbf{S}$  を変分ベイズ学習によって学習し、可動範囲マップを獲得させた。これを視覚化するため、得られた確率モデルに手先姿勢がロボット左前方部にくるような関節パターンを入力し、その関節角度座標において異常な接触が起こると予想される確率を 3次元空間上にプロットしたものを Fig.4.16 に示す。

図中の赤いプロット点が異常な接触が発生すると予想される確率が 80% 以上、青いプロット点が 60% 以上を示す。ただし、この点は実際には関節角度空間上の点として表現されており、変分ベイズ学習により、関節角度空間上に識別面が作成される。Fig.4.16 はこれを順モデルを用いて表現したものである。赤い点が多数出現している場所は、図中左上の上面図にも記してあるとおり、自己衝突が起きやすい姿勢であり、実際に用いた学習データでも赤い円の枠内で示した所で自己衝突が多数発生していた。なお図中では、60% 未満の点は煩雑になるため、表記しなかった。これは、関節角度空間上にて異常な接触による過負荷が発生すると予想される混合正規分布モデルを作成したため、得られたモデルに関節角度情報を入力することで、腕部の姿勢がどのような時に、駆動部に過負荷が発生するかを予測することが可能となった。このように、異常な接触が発生した時の関節角度の情報のみから、自身の作業空間を学習することは十分可能であることを示している。

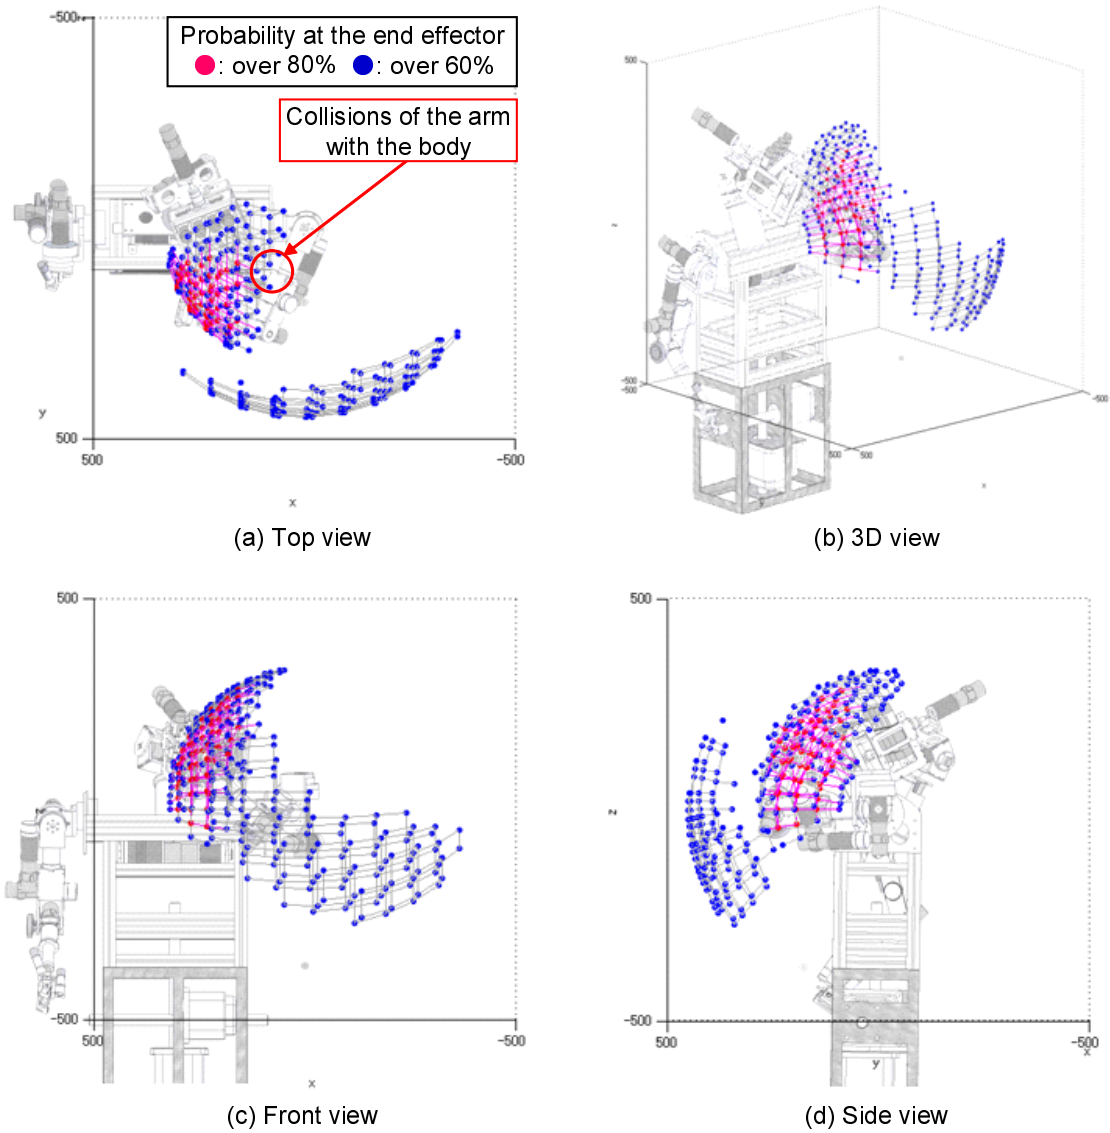


Fig. 4.16: 変分ベイズ学習による可動領域の獲得



## 4.5 可動領域の探索と構造変化に伴う解析

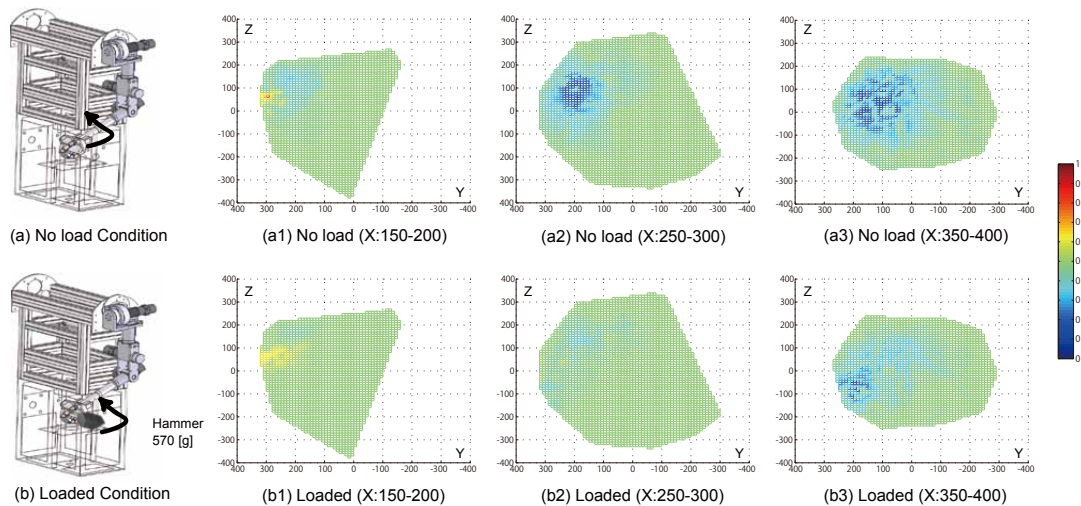


Fig. 4.17: 探索による可動領域の獲得と自身の構造変化による可動領域の学習

マニピュレータ自身に変化が生じた際、獲得される可動領域がどのように変化するかを調べるために実験を行う。タスクとして、予めマニピュレータを固定しているボディの前方部分にマニピュレータ先端部のハンドが来るように計27個の姿勢を用意する。1試行毎にランダムに姿勢を選択し、現在の姿勢から新たに選択された姿勢へ経路計画を行う。RRTsで作成される経路は代表点のみが出力されるため、その点間を5分割することで平滑化を行い、50 ms 毎にマニピュレータへ角度指令の送信を行う。また、マニピュレータのコントロール PC 側では制御周期 1 ms にて角度指令に基づく PID 制御を行うようにする。さらに、タスク実行中にある関節に過負荷が発生したことを検出した場合、直前に成功した姿勢へと自動的に戻るようにする。これにより、自己衝突などが発生した場合でも、安全にタスクを継続可能である。試行回数は100回とし、まずは無負荷状態にて行い、その後、Fig.4.17(b)のようにマニピュレータの手先部に重さ約570 gのゴムハンマーを固定し、同様に実験を行う。

学習データは、それぞれのタスク実行中に獲得したマニピュレータの関節駆動部への過負荷が発生した際の腕部の関節角度と、500 ms 毎に記録したタスク実行中の関節角度の履歴とした。Table 4.1 に学習に用いたデータ数と学習によって得た(2.18)式の混合モデル  $p_O(\theta)$  に対し、負荷の有無の両条件においてタスク実行中の関節角度を入力したときの出力を求め、その平均値及び最頻値を示す。なお今回の解析においては、モデル  $p_A, p_T$  の値はともに0~1の範囲内であることから、 $p_O$  の出力値の範囲も

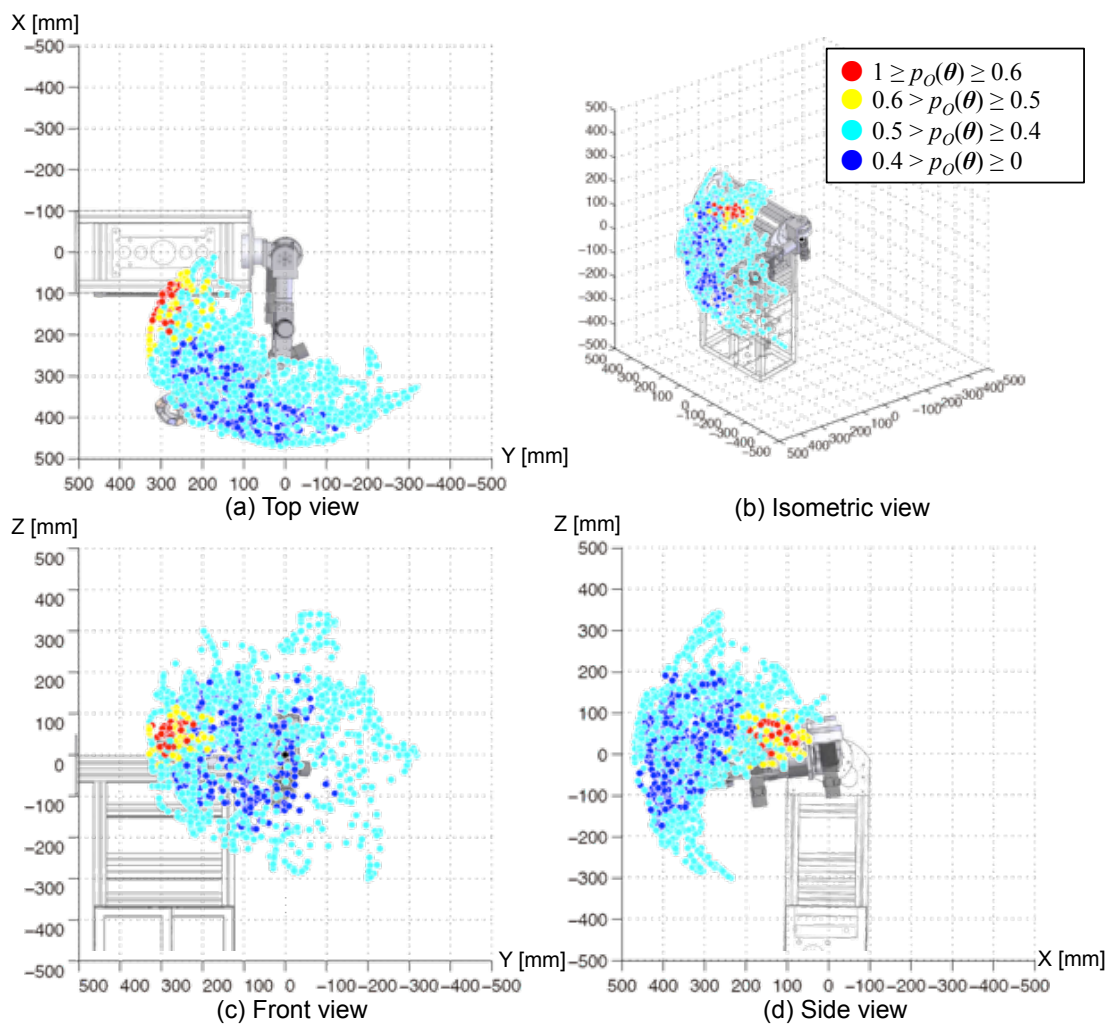


Fig. 4.18: 探索学習後の手先座標における確率値

Table 4.1: 学習に用いたデータと学習後の平均確率値と最頻値

|                                | No load | Attached load |
|--------------------------------|---------|---------------|
| Occurred irregular overload    | 97      | 137           |
| Historical data of joint angle | 2396    | 1974          |
| Mean value                     | 0.4085  | 0.4538        |
| Mode value                     | 0.4928  | 0.4890        |

0~1となる。このため、以降の実験結果の図においては、0~1の範囲のみ示すものとする。

この結果より、マニピュレータの手先に負荷を取り付けた場合には過負荷の発生回数が増加し、目的とする姿勢へ辿り付ける回数が減少していることが見て取れる。500 ms 毎の関節角度の履歴が負荷取り付け時の方が少ないのは、それだけ動作が制限されていたことを表している。また、平均値が有負荷時の方が大きいことから、有負荷時に獲得した可動領域の方が過負荷が発生しやすいことがわかる。これは、無負荷時と有負荷時で平均値の差に比べて、最頻値の差が少ないことからも見取れる。さらに一例として、これらの結果を直交座標空間に写像し、 $x = 175 \pm 25 \text{ mm}$ ,  $x = 275 \pm 25 \text{ mm}$ ,  $x = 375 \pm 25 \text{ mm}$  の位置における Y-Z 平面の図を Fig.4.17 に示す。Fig.4.17(a1)-(a3) に比べて、(b1)-(b3) の方が出力値が高いことがそれぞれの図中、左側から見て取れる。またこの図からも、無負荷時に比べ、有負荷時の方が過負荷が発生しにくい場所が少ないだけでなく、その分布が下方にあることから、マニピュレータ自身に変化が生じた際に獲得される可動領域に有意な変化が生じることが確認された。

また、Fig.4.18 に手先無負荷時における可動領域を直交座標空間に写像したものを示す。無負荷実験終了時における可動領域を構成するモデルである (2.18) 式に実験中に記録した関節角度ベクトル全てを入力し、その出力を対応する関節角度における手先座標に図中の凡例に示す範囲の色点として可視化している。この結果より、図中赤及び黄色の点で示される自己衝突を起こしている上部と上体の間のあたりがモデル上で過負荷が発生しやすいと示されている。また、図中青の点は過負荷が発生しにくい点であり、この点の姿勢は頻出姿勢である。

## 4.6 作業空間の自律的学習

可動領域のオンライン学習の有効性を示すため、マニピュレータの肩部と肘部の2自由度を用いて実験を行う。タスクは Fig.4.19 に示すようにある初期姿勢から目標姿勢への腕振り動作であり、その動作中に障害物を挿入することで、その障害物を回避する動作が生成されることで、未知環境への適応が可能であることを検証する。

動作させる関節の2自由度は初期姿勢において、ピッチ方向に動作させる。Fig.4.20 に動作させた関節を示す。また、経路計画の際に拘束を与え、腕部がピッチ方向のみに動作させるとともに、他の関節は初期位置を維持するように動作させる。まず、障害物がない状態で初期姿勢から手先が斜め上に来る目標姿勢へと数回動作 (Fig.4.21(1), (2)) をさせ、その後、その経路を遮るように障害物を入れて可動領域の獲得を行う。

学習データはマニピュレータが障害物等に接触し、関節駆動部への過負荷が発生し

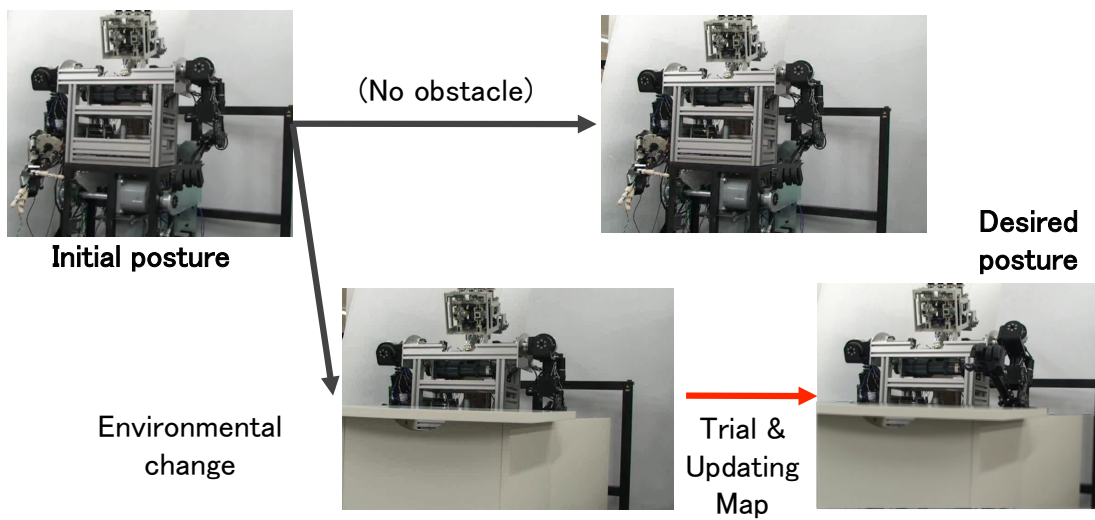


Fig. 4.19: 腕部振り上げタスクにおける環境変化




Fig. 4.20: 駆動関節と作業空間の遷移

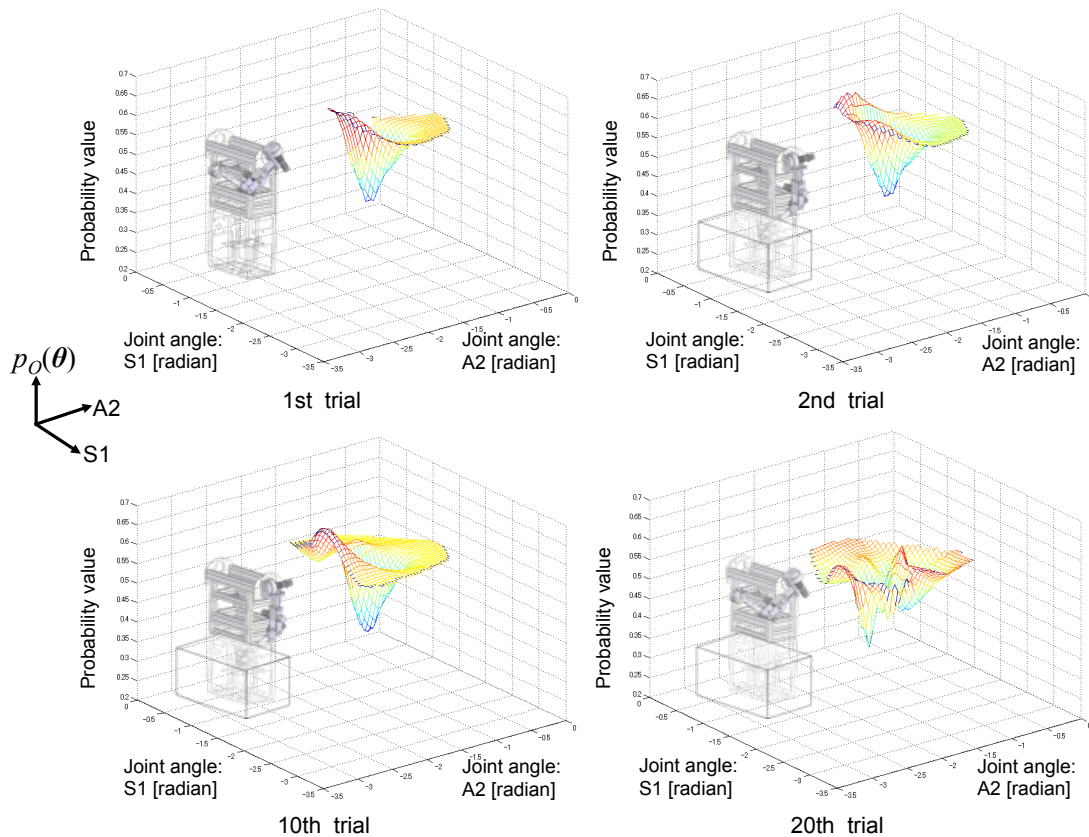


Fig. 4.21: 作業空間の学習過程における可動領域の遷移

た時の腕部の関節角度の履歴と、500 ms 毎に記録した過去 2000 回の関節角度の履歴とした。関節駆動部へ過負荷が発生した際は、Fig.2.11 で示したフローチャートに基づき実験を行う。Fig.4.21(1)-(4) に実験結果を示す。図中 1 回目のマニピュレータの姿勢が目標姿勢に相当する。図中の S1, A2 軸は動作させた肩部と肘部の関節角度とし、縦軸は関節角度ベクトルを入力したときに過負荷が発生すると予測される確率を示す。結果より上方向に行くほど、過負荷が発生する確率が高いことがわかる。1, 2 回目は障害物がない状態で動作させ、関節駆動部に過負荷が発生せず、実際に通った軌道の周囲の確率が低くなっていることがわかる。一方 3 回目の動作では、障害物を挿入した際にマニピュレータが障害物と接触し、関節駆動部へ過負荷が発生する場面である。その際の姿勢を記録し、初期姿勢に戻るとともに学習を行うことで、過負荷が発生すると予測される確率を関節角度空間上に識別面として学習する。この一連の操作を繰り返すことで、マニピュレータは自身が動作可能な領域である可動領域を獲得できる。






Fig. 4.22: 作業空間学習後の手先座標における確率値

Fig.4.22 にタスク達成後の可動領域を構成するモデルである  $p_o(\theta)$  に実験中に記録した関節角度ベクトル全てを入力し，その出力を対応する関節角度における手先座標に図中の凡例に示す範囲の色の点として直交座標空間に可視化したものを示す。障害物に衝突した姿勢においては過負荷が発生しているため，(2.18) 式の出力量は赤及び黄色の点で示される範囲となり，障害物を回避したときの姿勢では過負荷が発生していないため出力量は青及び水色の点で示される範囲となる。以上のことから過負荷の検出に伴う可動領域の能動的な学習により未知環境への適応が可能となることがわかる。

## 第5章 考察

### 5.1 接触による負荷の検出に関する考察

内界センサである電流センサを用いた過負荷の検出ならびに力センサを用いた接触の検出を行った。どちらも単純なルールで利用が可能であり、線形な力の検出には向かないが、ある閾値以上の力を検出する用途には利用可能である。電流センサによる手法はアクチュエータに流れる電流を検出する方式であるため、フィードバックループが組まれている制御系との相性がよく、モータ以外のアクチュエータにも適用可能である。ただし、その際にはアクチュエータ特性にあったパラメータの設計は必要となる。

一方、力センサを用いた手法においては敢えて力センサの情報を時間微分することにより、連続的な負荷より衝撃力を検出しやすくしている。これは力センサが衝撃力に対して脆弱であるため、力センサの保護に有用である。また、力センサを用いた実験に利用したロボットのマニピュレータにおいて、力センサは手先ではなく上腕部に搭載されていた。その下腕部へ軽く叩いたような力であっても検出可能であるので、例えばマニピュレータが道具を用いて自身の身体を拡張したとしても利用可能である。

内界センサを積極的に接触検出に用いることで、ロボット自身の体性感覚を学習することが可能であり、学習した体性感覚を制御に用いることで、自身の構造や環境の変化に適応した動作の生成が可能となる。

### 5.2 荷重増加実験に関する考察

荷重増加実験の結果からはアクチュエータに発生する過負荷から鉛直方向に動作する関節軸の可動範囲が荷重の増加とともに減少していることが分かった。特に持ち上げる方向に対して、指数関数的に可動範囲が減少していることから、重力による影響を受けていることが分かる。これは、マニピュレータの先端に重りを付けたマニピュレータの構造変化と可動領域の探索の結果にも表れている。このことから、ジャイロや力センサを用いなくても関節駆動部に生じる負荷とマニピュレータ自身の能動的な動作により重力方向を知ることが可能となる可能性を示唆している。



## 5.3 接触に基づく環境変化への適応に関する考察

マニピュレータが能動的に動作することにより、環境との接触が起こることによる関節駆動部への過負荷を検出し、その際の関節角度値を記録した情報に基づき経路計画を行うことで、作業空間上の環境変化に対して動作を適応させることが可能であることを実験から示した。このことから単純な関節角度情報から関節角度空間上で経路計画を行うだけで障害物回避動作の生成は可能であることを示している。しかし、このような単純な手法では更なる環境変化に対しては、過負荷発生姿勢のデータベースを切り替える等の対処が必要となるだけでなく、複雑な作業空間への適応は困難である。一方で、Fig.4.11のように視覚情報に基づいて過負荷発生時の姿勢のデータベースを切り替える手法は、センサフュージョンの一例でもあり、視覚情報と可動領域を関連づけることで、より詳細なモデリングを行える可能性を示唆している。

## 5.4 変分ベイズ学習による可動領域の獲得に関する考察

タスク実行中における関節駆動部への過負荷発生時の姿勢を記録し、そのデータベースを用いて変分ベイズ学習により可動領域の獲得を行った実験より、学習データはタスク実行中に発生した過負荷発生時の関節角度情報というスパースなデータではあるが、その学習後の確率モデルに、ロボット全面に半球状に展開するような関節角度入力を与え、その入力姿勢を直交座標空間にある一定以上の確率値を色分けして写像した結果である Fig.4.16 を見るに、自己衝突を頻繁に起こしていた姿勢の近傍の確率値が特に高くなっていることから、関節角度空間上にて混合正規分布モデルとしての識別面を学習することで可動領域の獲得が可能であることを示している。

また、マニピュレータが自己衝突を起こしている姿勢のみならず、マニピュレータが伸びきり慣性モーメントの影響を受けやすい姿勢においても負荷が発生しやすいと予測した結果が出ていることから、接触による負荷のみならず自身の姿勢による慣性モーメントの負荷も検出可能となる可能性を示しており、提案手法である関節駆動部への過負荷の検出モデルのパラメータの調整次第では、エネルギー的に負荷の少ない動作を生成できる可能性がある。一方でそのために、過負荷検出モデルの閾値を下げすぎれば、少し速く動くだけで過負荷が発生したと見なす可能性があり、その結果自身の取れる姿勢の選択肢を必要以上に狭める可能性がある。一種の過学習のような状態となり、タスク実行の妨げとなる可能性も考えられるため、過負荷検出モデルのパラメータに関する調整法は今後の研究課題とする必要がある。

## 5.5 可動領域の探索と構造変化に伴う解析に関する考察

過負荷発生時の関節角度情報のみで確率モデルを学習した場合、過負荷が発生しやすい姿勢を予測することは前節の考察からも分かる通り十分可能である。一方で、実際にマニピュレータが動作して過負荷が発生しなかった姿勢情報も作業空間の学習には重要な情報の一つである。可動領域の探索と構造変化に伴う解析に関する実験では、過負荷発生時の姿勢情報で作られる確率モデルと過負荷が発生していない時の姿勢情報で作られる確率モデルを組み合わせることで、可動領域を構築している。特に、Fig.4.16とFig.4.18の結果を比較すると後者の方がより自己衝突を起こしやすい姿勢をピンポイントで予測しているだけでなく、慣性モーメントの影響の小さい中心部の確率値が下がっていることが見て取れる。学習的には頻出姿勢であったために確率値が下がったと見なすと考えるべきであろうが、一方でそれだけ過負荷の発生によるタスクの中断が少なかったからこそ頻出姿勢となったとも考えることも可能である。そして、自身の構造変化によって学習後の可動領域に差異がでることからも自己の身体性を学習可能である可能性を示唆している。

## 5.6 作業空間の自律的学習に関する考察

本研究では、作業空間の学習を直交座標空間上の位置ではなく関節角度空間上の姿勢として学習している。Fig.4.22の結果からも分かる通り、関節角度空間上で可動領域を確率モデルとして学習することで、作業空間の学習は行えている。一方で、作業空間上の障害物を検出することのみに着目すれば接触位置を検出し、直交座標空間上で学習する方が効率的であるし、ステレオビジョンやレーザーレンジファインダを用いれば、作業空間上の障害物もモデリング化が可能であるので、経路計画を行う際に環境モデルを構築し、それと組み合わせれば作業空間の学習効率は向上することも確かである。しかし、そのためには接触位置を検出することが不可欠であり、マニピュレータに接触センサや力センサの搭載が必要となり、システム全体としてのコストが増大することとなる。また、直交座標空間上で学習し、その情報に基づいて経路計画を行う際には逆動理学による計算が必要となり、システムの特性に合わせた設計が必要となることから、自身の構造変化に対してもその検出が必要となる。つまり、精確なモデリングが不可欠である。

一方で、本提案手法のように関節角度空間上で確率モデルとして作業空間を学習する場合、その精度は直交座標空間上で学習することに比べれば劣るが、内界センサのみでの学習が可能であり、外部装置を必要としない。また、接触位置の検出も不要でありながら、接触時の姿勢の近傍を避けるように経路計画が可能となる。例えば、砂

の中や透明ではない液体の中のような環境と接触しているが外界センサでのモデリングが困難な状況のような手探りで探索が必要な状況にも適用可能である。つまり、直交座標空間上での接触位置が不可能なシステムや状況においても適用可能となる。そして、複雑な作業空間でもパラメータの調整次第で対応可能である。さらに、直交座標空間上での探索では過負荷検出位置を避けるように経路の探索を行う必要があるため、多自由度マニピュレータにおいては、その位置における姿勢の選択肢を一律に除外してしまい同一の手先位置を取れない可能性がある一方で、関節角度空間上での学習では過負荷が検出した位置の近傍の姿勢を確率的に評価しているため、その姿勢を避けながら手先は直交座標空間上で同一な位置への経路計画が可能となる。しかし、接触によって作業空間内の物体や自身が破損しない状況での適用が基本となるため、壊れやすいものが配置されている環境では事前に外部環境のモデリングを行い経路計画に反映させる必要がある。

## 5.7 今後の展望

本研究ではDHパラメータで表現される簡単なリンク構造のみのマニピュレータのモデルしか事前に与えられていない。そのため、自己や環境との接触を積極的に用いることで、自身の動作可能な領域である可動領域の探索を行うことで、作業空間の学習を行っている。これは、身体性に基づく学習であるモータバブリングによる運動学習によって、多自由度マニピュレータにおける自身の構造と周辺環境を含む作業空間を学習することに繋がっている。特に直交座標空間ではなく、関節角度空間で自身の動作可能な領域を確率モデルとして学習していることが重要な要素を担っている。

本研究で提案している手法は、ボトムアップ的に作業空間を学習する手法であり、体性感覚という身体性から自律的に可動領域を獲得することで、マニピュレータの制御における新たな手法としての評価のみならず、身体性に基づく人工知能研究分野にも活用可能である。なぜならば、関節駆動部に生じる過負荷を「痛み」もしくは「疲労」と置き換えて考えるならば、過負荷が生じないように動くことは、人に置き換えて考えると「苦痛」を生じないように動くことであり、人の動作生成の本質と同様に考えることができるからである。

最後に、本研究で用いている手法は内界センサの情報に基づき、自身の動作可能な領域は自律的に学習する仕組みであり、そのために外界センサなどの特別な装置を必要とせず、自身の体性感覚のみによって学習可能であるため、非常に応用性に優れている。本提案手法をサブシステムの的に用いることで、モデリングの精度向上や経路計画への補間等への応用が期待できる。そして、Fig.5.1に示すように、実際に使用した人間型ロボットのみならず車椅子搭載型のマニピュレータにも応用可能である。

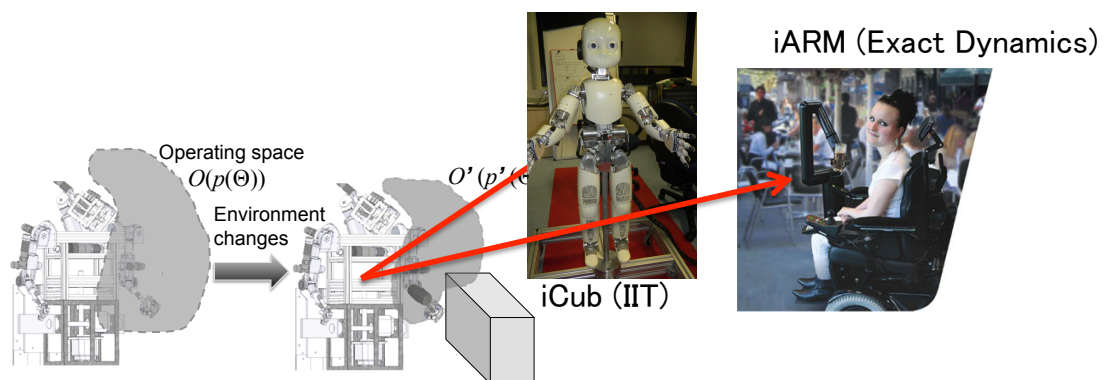


Fig. 5.1: 異なるプラットフォームへの応用

また、接触に基づいて内界センサに発生する負荷から学習するという原理はマニピュレーションのみならず、例えば筋電義手などの細かい制御に向かない機器にも利用可能である。

## 第6章 結言

本研究では、多自由度マニピュレータが動作する際、関節駆動部のモータに発生する負荷を電流センサから計測することで、自身の可動領域を能動的に獲得する手法について述べた。さらに、関節駆動部の各モータにおける過負荷の検出に基づき、異常な接触が発生した時点の関節角度の履歴を利用することで、その近傍を避けるように動作計画を行う手法を提案した。これにより、駆動部の保護を行いながら、かつ獲得フェーズと利用フェーズの別なく、連続した能動的な動作により可動領域が構築できることを明らかにした。さらに、接触に基づき関節駆動部への過負荷発生時の関節角度を用いた変分ベイズ学習により、関節角度空間上に識別面を構築することで、自身の動作負荷に基づく可動領域の学習と作業空間の学習が可能であることを示した。提案手法により、人や周囲の物体といったマニピュレータ付近の環境が変化した際でも自身の作業空間を自律的に学習する新しい制御法の有効性を明らかにした。

本提案手法には、カメラや接触センサなどの外界センサを用いずとも内界センサによる接触検出と確率学習による環境モデルの作成がスパースなデータから可能となるため、応用が簡易であり拡張性が高い利点が挙げられる。これは、単純なルールに基づいて学習を行っていることと特別な外部装置を必要としないことから他のシステムとの組み合わせが容易であり、ベースシステムもしくはサブシステムとして用いることのできる拡張性があるからである。そして、今後のロボットの社会進出を考慮した場合、車椅子搭載型のマニピュレータであったり、介護ロボットであったりと人と密接に関わる環境での利用を想定していく必要があり、人や環境との接触は避けては通れない課題となる。本提案手法のように、接触を積極的に用いて作業空間を学習する枠組みは今後のロボットの社会進出に向けた技術的一助になると思われる。

また本提案手法は、ロボットの体性感覚学習でもあるため道具利用等の自己構造の変化にも自律的に適応可能であり、身体性に基づくボトムアップ的手法による学習のため人工知能研究分野への応用が期待できる。人間型ロボットにおいて、体性感覚を用いて自律的に学習することは、人間の知の理解に繋がるとともにロボットの知の創発に繋がると言える。古典的な人工知能研究では、人間の知の機能を機械的に実現することに重きを置かれており、それによって出来るのは知識の集合システムでしかなく、そこから知能の創発を目指すために必要なのはやはり自律的に学習する枠組みで

ある。一方で、ディープラーニングのように人間の脳機能の仕組みを模倣して知の創発を目指す研究は近年目覚ましく発展している。しかし、本質的には詰め込み学習であり、学生が教科書から勉強しているのと何ら変わらない。確かに、より効率的な動作を生成したり、次の動きを予測したりと端から見ると十分に知的な振る舞いを生成しているように見える。学習したものと似た命題なら十分応用が利くことから知の創発が行えているようにも見える。しかし、私には単純なデータの学習のみからは知の創発は起こらないのではないかと考える。

人間を例に考えた場合、赤ん坊の快・不快はそのまま生死に繋がる感情表現である。これは、自己保存の本能から発生されており、自身の動きによる環境との相互作用の結果として快・不快の感情を表しているとも言える。その行動の集積により自身の身体の動きを自律的に獲得していき、はいはいから掴まり立ち、そして自律歩行へと繋がっていくのである。このように、環境との相互作用を行うためには身体が必要であり、その身体性から知の創発を目指すべきではないかと私は考える。そのため、今後は複数の体性感覚情報に基づいて、ロボットの自律的な学習に関する研究に従事し、ロボットによる知の創発を行える枠組みを構築することを目標とする。

## 謝辞

本論文は、筆者が筑波大学大学院システム情報工学研究科知能機能システム専攻博士後期課程在籍中の研究成果をまとめたものです。本研究を進めるにあたり、数多くの有益な助言と手厚いご支援を賜りました筑波大学システム情報系 鈴木健嗣教授にこの場をお借りして心よりお礼申し上げます。また、研究遂行に当たり、貴重なご助言を頂きました筑波大学システム情報系 中内靖教授，矢野博明教授，望山洋准教授，名古屋大学 長谷川泰久教授に深く感謝いたします。イタリア工科大学にて Giulio Sandini 教授，三枝亮氏には力センサを用いた接触検出に関する研究を進めるに当たり指導頂きましたこと感謝いたします。筑波大学大学院システム情報工学研究科人工知能研究室のメンバーにもこの場をお借りして厚くお礼申し上げます。特に研究室の初期メンバーの Dushyantha Jayatilake 氏，大垣史迅氏には研究の相談だけでなく，多数の支援を頂きましたのでこの場にて感謝いたします。研究活動費においては，本研究の一部は日本学術振興会特別研究員奨励費（課題番号：22・1147）からのご支援を頂戴しました。最後に，いつも温かい励ましを送り続けてくれた家族に心から感謝いたします。

## 参考文献

- [1] EXACT Dynamics: <http://www.exactdynamics.nl/> (28 Sep. 2016 access)
- [2] KINOVA ROBOTICS: <http://www.kinovarobotics.com/> (28 Sep. 2016 access)
- [3] R. Alqasemi and Rajiv Dubey: “A 9-DoF Wheelchair-Mounted Robotic Arm System: Design, Control, Brain-Computer Interfacing, and Testing”, *Advances in Robot Manipulators*, INTECH, pp.51-78 (2010)
- [4] E. B. Rapacki, C. Niezrecki and Holly A. Yanco: “An Underactuated Gripper to Unlatch Door Knobs and Handles”, *Proc. of the Second Annual IEEE Int’l Conf. on Technologies for Practical Robot Applications*, pp.135-140 (2009)
- [5] W. Wang, Y. Ssuga and S. Sugano: “Contact Detection and Reaction of a Wheelchair Mounted Robotic Arm Equiped with Mechanical Gravity Cancellor”, *Proc. of the 2010 IEEE/RSJ Int’l Conf. on Intelligent Robots and Systems*, pp.4378-4383 (2010)
- [6] V. Maheu, J. Frappier, P. S. Archambault and F. Routhier: “Evaluation of the JACO robotic arm: clinico-economic study for powered wheelchair users with upper-extremity disabilities”, *Proc. of the 2011 IEEE Int’l Conf. on Rehabilitation Robotics*, pp.472-476 (2011)
- [7] SECOM マイスプーン: <http://www.secom.co.jp/personal/medical/myspoon.html> (28 Sep. 2016 access)
- [8] 石井純夫:「食事支援ロボット「マイスプーン」」, *日本ロボット学会誌*, Vol. 21, No.4, pp.378-381 (2003)
- [9] Y. Takahashi and S. Suzukawa: “Easy Human Interface for Severely Handicapped Persons and Application for Eating Assist Robot”, *Proc. on the 2006 IEEE Int’l Conf. on Mechatronics*, pp. 225-229 (2006)



- [10] E. Ohara, K. Yano, S. Horihata, T. Aoki and Y. Nishimoto: “Tremor suppression control of Meal-Assist Robot with adaptive filter”, Proc. on the 2009 IEEE Int’l Conf. on Rehabilitation Robotics, pp.498-503 (2009)
- [11] 尹祐根・脇田優仁・山野辺夏樹:「上肢に障害のある人の生活を支援するロボットアーム RAPUDA(ラピューダ)による自立支援」, バイオメカニズム学会誌, Vol.37, No.2, pp.100-104 (2013)
- [12] N. G. Tsagarakis, G. METTA, G. SANDINI, D. Vernon, R. Beira, L. Righetti, J. Santos-Victor, A. J. Ijspeert, M. C. Carrozza and D. G. Caldwell: “iCub: the design and realization of an open humanoid platform for cognitive and neuroscience research”, *Advanced Robotics*, Vol. 21, No. 10, pp.1151-1175 (2007)
- [13] H.Iwata and S.Sugano: “Design of Human Symbiotic Robot TWENDY-ONE”, Proc. of the 2009 IEEE Int’l Conf. on Robotics and Automation, pp.580-586 (2009)
- [14] K. Kaneko, M Morisawa, S. Kajita, S. Nakaoka, T. Sakaguchi, R. Cisneros and F. Kanehiro: “Humanoid robot HRP-2Kai — Improvement of HRP-2 towards disaster response tasks”, Proc. of the 15th IEEE-RAS Int’l Conf. on Humanoid Robots, pp.132-139 (2015)
- [15] S. Feng, X. Xinjilefu, C. G. Atkeson and J. Kim: “Optimization based controller design and implementation for the Atlas robot in the DARPA Robotics Challenge Finals”, Proc. of the 15th IEEE-RAS Int’l Conf on Humanoid Robots, pp.1028-1035 (2015)
- [16] G. Claudio, F. Spindler and F. Chaumette: “Vision-based manipulation with the humanoid robot Romeo”, Proc. of the 16th IEEE-RAS Int’l Conf. on Humanoid Robots, pp.286-293 (2016)
- [17] SoftBank Pepper: <http://www.softbank.jp/robot/> (28 Sep. 2016 access)
- [18] T. Hasegawa, T. Suehiro, and K. Takase, “A model-based manipulation system with skill-based execution”, *IEEE Trans. on Robotics and Automation*, Vol.8, No.5, pp.535-544 (1992)
- [19] J. J. Kuffner, K. Nishiwaki, S. Kagami, Y. Kuniyoshi, M. Inaba, and H. Inoue, “Self-collision detection and prevention for multi-DOF manipulator”, Proc. of the 2002 IEEE Int’l. Conf. on Robotics and Automation, pp.2265-2270 (2002)

- [20] F. Seto, K. Kosuge and Y. Hirata, “Self-collision Avoidance Motion Control for Human Robot Cooperation System Based on RoBE”, Proc. on the 2005 IEEE/RSJ Intl. Conf. on Intelligent Robots and Systems, pp.50-55 (2005)
- [21] 瀬戸文美, 小菅一弘, 平田泰久:「人間協調型ロボットにおける RoBE を用いた実時間自己衝突回避」, 日本機械学会論文集 (C 編), Vol.72, No.718, pp.122-127 (2006)
- [22] K. Okada and M. Inaba, “A Hybrid Approach to Practical Self Collision Detection System of Humanoid Robot”, Proc. of the 2006 IEEE/RSJ Int’l Conf. on Intelligent Robots and Systems, pp.3952-3957 (2006)
- [23] 細田耕, 坂本健二, 浅田稔:「三次元再構成を行わない視覚サーボ系のための障害物回避起動の生成」, 日本ロボット学会誌, Vol.15, No.2, pp.290-295 (1997)
- [24] H. Iwata, H. Hoshino, T. Morita, and S.Sugano, “Force detectable surface covers for multi-DOF manipulators”, Proc. on the 2001 IEEE/ASME Int’l Conf. on Advanced Intelligent Mechatronics, Vol.2, pp.1205-1210 (2001)
- [25] 岩田浩康, 星野優人, 森田寿郎, 菅野重樹:「人間共存ロボットのための全身触覚インタフェース」, 日本ロボット学会誌, Vol.20, No.5, pp.543-549 (2002)
- [26] 加賀美聡, 西脇光一, カフナー ジェームズ, 岡田慧, 稲葉雅幸, 井上博允:「三次元距離画像の RRT 探索によるヒューマノイドロボットの腕の動作計画」, ロボティクス・メカトロニクス講演会’02 予稿集, 2P2-L05 (2002)
- [27] S. Kagami, J. J. Kuffner, K. Nishiwaki, K. Okada, M. Inaba and H. Inoue: “Humanoid Arm Motion Planning Using Stereo Vision and RRT Search”, Proc. of the 2003 IEEE/RSJ Int’l. Conf. on Intelligent Robots and Systems, pp.2167-2172 (2003)
- [28] K. Okada, M. Kojima, Y. Sagawa, T. Ichino, K. Sato and M. Inaba: “Vision based behavior verification system of humanoid robot for daily environment tasks”, Proc. of the 6th IEEE-RAS International Conference on Humanoid Robots, pp.7-12 (2006)
- [29] K. Hosoda, K. Igarashi, and M. Asada, “Adaptive Hybrid Control for Visual Servoing/Force Control in Unknown Environment”, Proc. on the 1996 IEEE/RSJ Int’l Conf. on Intelligent Robots and Systems, pp.1097-1103 (1996)
- [30] 向井利春, 石川正俊:「アクティブセンシングを用いた視触覚融合システム」, 日本ロボット学会誌, Vol. 15, No. 1, pp.75-81 (1997)

- [31] 永井清, 益原絆, 山中和也:「ハーモニックドライブを有するマニピュレータに対する飽和特性とディザを用いた力センサレス・コンプライアンス制御」, 日本ロボット学会誌, Vol. 22, No. 3, pp.353-360 (2004)
- [32] 大賀淳一郎, 西原泰宣, 大明準治:「産業用ロボットアームの動力学モデルに基づいたセンサレス力制御」, 東芝レビュー, Vol. 66, No.5, pp.38-41 (2011)
- [33] 野沢峻一, 石田正穂, 植田亮平, 岡田慧, 稲葉雅幸:「関節負荷・可操作範囲に基づくヒューマノイドの物体操作戦略選択法」, ロボティクス・メカトロニクス講演会'11 予稿集, 2 P2-J06 (2011)
- [34] 野沢峻一, 室岡雅樹, 野田晋太郎, 岡田慧, 稲葉雅幸:「物体・環境・ロボット間接触状態に基づくヒューマノイドの物体操作記述と自律的フェーズ遷移による動作実行法」, ロボティクス・メカトロニクス講演会'13 予稿集, 2 P1-B05, (2013)
- [35] S. Nozawa, M. Murooka, S. Noda, K. Okada and M. Inaba: “Description and Execution of Humanoid’s Object Manipulation based on Object-environment-robot Contact States”, Proc. of the 2013 IEEE/RSJ Int’l Conf. on Intelligent Robots and Systems, pp.2608-2615 (2013)
- [36] 杉原知道:「逆運動学の数値的解法」, 日本ロボット学会誌, Vol. 34, No. 3, pp.167-173 (2016)
- [37] S. M. LaValle and J. J. Kuffner: “Rapidly-exploring random trees: Progress and prospects”, Algorithmic and Computational Robotics: New Directions, pp.293-308 (2001)
- [38] J. J. Kuffner and S. M. LaValle, ”RRT-connect: An efficient approach to single-query path planning”, Proc. on the 2000 IEEE Int’l Conf. on Robotics and Automation, pp.995-1001 (2000)
- [39] E. Yoshida, “Humanoid Motion Planning using Multi-Level DOF Exploitation based on Randomized Method”, Proc. on the 2005 IEEE/RSJ Int’l Conf. on Intelligent Robots and Systems, pp.25-30 (2005)
- [40] D. Bertram, J. Kuffner, R. Dillmann and T. Asfour: “An integrated approach to inverse kinematics and path planning for redundant manipulators”, Proc. of the 2006 IEEE International Conference on Robotics and Automation, pp.1874-1879 (2006)

- [41] S. M. LaValle, “Motion Strategy Library,” <http://msl.cs.uiuc.edu/msl/>. (15 Dec. 2009 access)
- [42] R. Brooks: “Intelligence Without Representation”, *Artificial Intelligence*, Vol.47, No. 1, pp.139-159 (1991)
- [43] R. Pfeifer and C. Scheier: 「知の創成 ー身体性認知科学への招待ー」(石田章夫, 小林宏, 細田耕訳), 共立出版 (2001)
- [44] R. Pfeifer and J. Bongard: 「知能の原理 ー身体性に基づく構成論的アプローチー」(細田耕, 石田章夫訳), 共立出版 (2010)
- [45] J. Bongard, V. Zykov, H. Lipson: “Automated Synthesis of Body Schema using Multiple Sensor Modalities ”, *Proc. of the 10th Int’l Conf. on Artificial Life*, pp.220-226 (2006)
- [46] R. Saegusa, G. Metta, G. Sandini: “Active Learning for Multiple Sensorimotor Coordinations Based on State Confidence,” *Proc. of the 2009 IEEE/RSJ Int’l Conf. on Intelligent Robots and Systems*, pp.2598-2603 (2009)
- [47] S. Calinon and A. Billard: “A probabilistic Programming by Demonstration framework handling constraints in joint space and task space”, *Proc. of the 2008 IEEE/RSJ Int’l Conf. on Intelligent Robots and Systems*, pp.367-372 (2008)
- [48] S. Calinon: “Robot Proframming by Demonstration : A Probabilistic Approach”, EPFL Press, (2009)
- [49] S. M. Khansari-Zadeh and A. Billard: “BM: An iterative algorithm to learn stable non-linear dynamical systems with Gaussian mixture models”, *Proc. of the 2010 IEEE Int’l Conf. on Robotics and Automation*, pp.2381-2388 (2010)
- [50] S. Waterhouse, D. MacKey and T. Robinson: “Bayesian methods for Mixtures of Experts”, *Neural Information Processing Systems 8*, MIT Press, pp.351-357 (1996)
- [51] H. Attias: “Inferring parameters and structure of latent variable models by variational Bayes”, *Proc. of the 15th Conf. on Uncertainty in Artificial Intelligence*, pp.21-30 (1999)
- [52] 佐藤雅昭:「オンラインベイズ学習によるモデル選択と動的環境への適応」, 電子情報通信学会技術研究報告 ニューロコンピューティング, Vol.99, No.685, pp.97-104 (2000)

- [53] I. T. Nabney: “NETLAB Algorithms for Pattern Recognition”, Springer (2002)
- [54] N. Ueda and Z. Ghahramani: “Bayesian model search for mixture models based on optimizing variational bounds”, Neural Networks, Vol.15, pp.1223-1241 (2002)
- [55] 上田修功:「ベイズ学習 [ I ] —統計的学習の基礎—」, 電子情報通信学会誌, Vol. 85, No. 4, pp.265-271 (2002)
- [56] 上田修功:「ベイズ学習 [ II ] —ベイズ学習の基礎—」, 電子情報通信学会誌, Vol. 85, No. 6, pp.421-426 (2002)
- [57] 上田修功:「ベイズ学習 [ III ] —変分ベイズ学習の基礎—」, 電子情報通信学会誌, Vol. 85, No. 7, pp.504-509 (2002)
- [58] 上田修功:「ベイズ学習 [ IV ] —変分ベイズ学習の応用例—」, 電子情報通信学会誌, Vol. 85, No. 8, pp.633-638 (2002)
- [59] M. J. Beal and Z. Ghahramani: “The Variational Bayesian EM Algorithm for Incomplete Data: with Application to Scoring Graphical Model Structures”, Bayesian Statistics 7, Oxford University Press (2003)
- [60] John J. Craig :「ロボティクス —機構・力学・制御—」(三浦宏文, 下山勲訳), 共立出版 (1991)
- [61] 有本卓:「新版 ロボットの力学と制御」, 朝倉出版 (2002)
- [62] 松元明弘, 横田和隆:「ロボットメカニクス —構造と機械要素・機構—」, オーム社 (2009)

## 発表論文

- [1] 原田篤, 鈴木健嗣:「人間型ロボットによる能動的な稼働範囲の獲得」, 情報処理学会第69回全国大会予稿集, 1R-5, 東京 (2007)
- [2] Atsushi Harada and Kenji Suzuki: “Active acquisition of operating ranges and path planning for a humanoid robot,” Proc. of the 2007 IEEE Intl. Conf. on Robotics and Biomimetics, pp.739-744 (2007)
- [3] 原田篤, 鈴木健嗣, 矢野翔:「人間型ロボットによる能動的な稼働範囲の獲得と動作計画」, 情報処理学会第70回全国大会予稿集, 1X-6, 茨城 (2008)
- [4] 原田篤, 鈴木健嗣:「人間型ロボットによる環境変化に応じた作業空間の構築と動作計画」, ロボティクス・メカトロニクス講演会'08 予稿集, 2A1-D13, 長野 (2008)
- [5] Atsushi Harada and Kenji Suzuki: “Action oriented self-modeling and motion planning for a humanoid robot,” Proc. of the 8th IEEE-RAS Intl. Conf. on Humanoids Robots, pp.367-372 (2008)
- [6] 原田篤, 鈴木健嗣:「人間型ロボットによる変分ベイズ学習を用いた稼働範囲の獲得」, 情報処理学会第71回全国大会予稿集, 3R-1, 滋賀 (2009)
- [7] 原田篤, 鈴木健嗣:「人間型ロボットのための逐次学習による可動領域の獲得」, ロボティクス・メカトロニクス講演会'09 予稿集, 2A1-D14, 北海道 (2009)
- [8] Atsushi Harada and Kenji Suzuki: “Action oriented bayesian learning of the operating space for a humanoid robot,” Proc. of the 2009 IEEE Int'l. Conf. on Robotics and Biomimetics, pp.633-638 (2009)
- [9] 原田篤, 鈴木健嗣, 「人間型ロボットの腕部における関節負荷変動と可動領域の学習」, 第28回日本ロボット学会学術講演会予稿集, 1A2-3, 名古屋 (2010)
- [10] 原田篤:「電流センサに基づくソフトウェアリミッタを用いた義手制御」, 第25回計測自動制御学会中国支部学術講演会予稿集, 2G-5, 広島 (2016)

- [11] 原田篤, 鈴木健嗣:「多自由度マニピュレータによる関節負荷に基づく作業空間の学習」, 電気学会論文誌 C, Vol.137, No.12, pp.1659-1668 (2017)