

修士論文

生活支援ロボットにおける食器類の教示認識と
適応的操作学習の実現

令和4年1月27日提出
指導教員 稲葉 雅幸 教授
岡田 慧 教授



東京大学大学院 情報理工学系研究科
知能機械情報学専攻
48-206554 若林 隼平

生活支援ロボットにおける食器類の教示認識と適応的操作学習の実現

若林隼平 指導教員 稲葉 雅幸 教授 岡田 慧 教授

Key Words: 生活支援ロボット, 適応的操作, 視触覚, 動作教示, ソフト制約

1 はじめに

生活環境において、家事作業を代替するロボットの進出が試みられている。生活支援における片付けを行うロボットは、毎日変化する環境の中で、形状や性質が未知である対象物を扱えることが求められ、従来のモデルベースの動作計画ではタスクの実現が困難であった。食器類片付けタスクはその顕著な例であり [1], 皿やスプーン、コップという複数の物体クラスに加えて、大きさや形状、表面性状が個々に異なる。さらに、使用済み食器類は汚れ方もそれぞれ異なり、それぞれに対応した操作を実行する必要がある。

本研究では、生活支援ロボットにおいて、視覚と操作教示に基づく認識情報から適応的な操作を実現した。生活支援ロボットが使用済み食器類の片付けを行うタスクにおいて、把持と洗浄に着目しその有用性を実施した。形状や性質が未知である食器類に対して適応的な操作を実現するために、教示を含んだ認識学習が有効である [2]。また、オンラインで目標値や制約を柔軟に追加できる学習、推論システムが有用である [3]。提案システムは、視覚と操作教示より直接操作量を算出するのではなく、目標値に関して逆伝播を行うことで、適応的な操作量を推論できる。把持においては、周囲環境により姿勢に制限のある中で、汚れを避けた把持の実現を目標とする。洗浄においては、安定した力で食器をスポンジで擦り、水を飛び散らさぬよう濯ぎ、意図せぬ状況下での操作修正の実現を目標とする。システムの概要図を Fig.1 に示す。

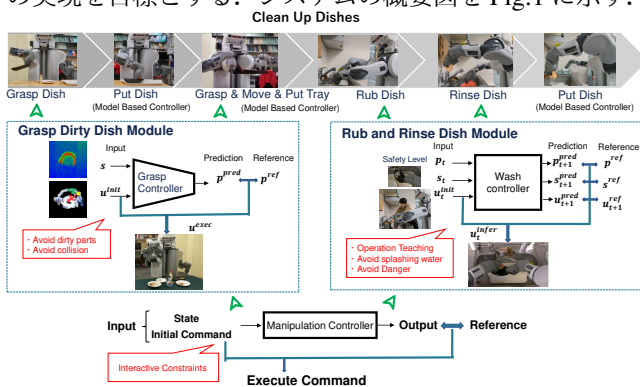


Fig. 1: 視覚と操作教示に基づく適応的操作学習システム

2 視覚情報に基づく把持箇所に関する制約のある食器類の把持学習

使用済み食器類の把持においては、視覚情報と把持経験に基づいて、食器類の状態と周囲環境に関して適応的に把持点と姿勢を修正する、Fig.2のシステムを提案する。

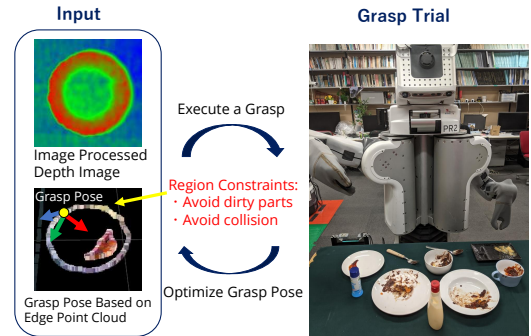


Fig. 2: 把持点と姿勢に関する柔軟な制約を付加可能な把持学習システム

食器類は複数の把持点を有するため、把持点とグリッパの姿勢について冗長である。冗長性を生かして、把持点領域に制約がある場合に、適応的に把持点と姿勢を選択することを明らかにした。具体的には、深度画像と物体端部の点群の入力から、把持成功確率を出力するネットワークを考案した。このとき、把持位置や把持姿勢のアノテーションを行うことなく自動的に把持位置を獲得した。ネットワークの学習後、誤差逆伝播により、入力把持点と姿勢が修正された。把持点と姿勢は初期値に依存しており、入力制約条件を柔軟に反映可能であった。したがって、制約が陽に与えられない場合には、初期値付近で掴みやすい把持点と姿勢が選択された。また、入力点群に制約を加えることで、把持範囲を狭めて物体の所望の部位を把持した。その結果、汚れた食器類の把持において、汚れを避けた点において、腕が障害物と接触しない最適な把持点と姿勢を選択することを実証した (Fig.3)。




Fig. 3: 把持点と姿勢の制約下における把持点と姿勢の最適化推論と実行結果

3 視覚と操作教示に基づく食器類の濯ぎと擦り操作学習

使用済み食器類の洗浄において、Fig.4に示す視覚情報と操作の直接教示に基づいて、適応的に擦り動作と水濯ぎ動作を行うシステムを提案した。擦り動作においては、




Fig. 4: 視覚と操作教示に基づく食器類の濯ぎと擦り操作学習システム

食器類の大きさや形状，表面性状に応じて，動作軌道や擦り力加減が変化する．濯ぎ動作においては，蛇口から出る水の食器上で跳ねを抑え，食器全体に水がかかるような角度や動作を生成する必要がある．これらは目標値が明確ではないため，操作を直接教示することで制御器を訓練した．実行時においては，擦り動作では，汚れ箇所に応じて軌道目標点を与え，食器が擦り動作中も静止することを目標として，動作を修正した．また，擦り動作と水濯ぎ動作において，教示時に人間が介入した状況を記憶し，実行時にその状況に近づくにつれて注意して動作を修正した．復帰不可能な危険状態と判断した場合は，操作を中止して食器をシンクに置いた．その結果，汚れた食器類に対して，Fig.5 右図のように安定した力で擦り，水を飛ばさぬように濯ぎ，Fig.5 左図のように安全度を向上させる操作を実証した．




Fig. 5: 濯ぎと擦り操作における安全度の変化(左図)と関節推定力の変化(右図)

4 使用済み食器類の片付けにおける統合実験

Fig.6 のように，使用済み食器類の片付けタスクにおいて，食器類の把持から運搬，水濯ぎと擦り洗い，水切り籠に置く動作を実現した．そのタスクの中で，把持と水濯ぎと擦り洗いの場面では，モデルベース型の動作生成ではなく，適応的な学習型動作生成の優位性を示した．これは，深層学習を用いることで，未知の大きさや形状，表面性状の食器類を扱うことを可能にし，誤差逆伝播による操作生成によって，食器類の汚れや操作危険度に応じて操作の修正が可能となったからである．一連の片付けタスクを行うことで，提案システムの実用性を示した．

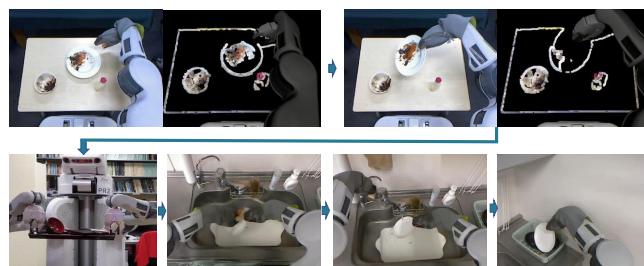


Fig. 6: 生活環境における食器類の片付けタスク遂行

5 結論

本研究では，生活支援ロボットが，オンラインで与えられる制約下において，未知の形状や性質の対象物における操作を行うことを目標として，ロボットにおける視覚や操作教示による認識に基づいて，制約を可能な限り満たしながら最適な操作を実行するシステムを提案し，操作における推論の最適化に適用して，その有効性を評価した．また，食器類の片付けタスクの中で，食器類の把持や洗浄動作において，教示認識に基づく適応的操作システムを構築し，生活支援ロボットを用いた，多様な状況下で多様な食器類に関して操作を実現した．以上のことから，本研究により，視覚認識と操作教示による学習型操作生成器におけるオンラインの操作修正法を提案し，実環境における自律的・適応的な多様な操作を行うシステムの構成法が明らかにされたと結論づけられる．今後，提案システムの汎用性と適応性が他のタスクに応用されることを期待する．

参考文献

- [1] Kei Okada, Mitsuharu Kojima, Yuichi Sagawa, Toshiyuki Ichino, Kenji Sato, and Masayuki Inaba. Vision based behavior verification system of humanoid robot for daily environment tasks. *Proceedings of the 2006 6th IEEE-RAS International Conference on Humanoid Robots, HUMANOIDS*, Vol. 00, pp. 7–12, 2006.
- [2] Yasuo KUNIYOSHI, Hirochika INOUE, and Masayuki INABA. Teaching by Showing: Generating Robot Command Sequences Based on Real Time Visual Recognition of Human Pick and Place Actions. *Journal of the Robotics Society of Japan*, Vol. 9, No. 3, pp. 295–303, 1991.
- [3] Daisuke Tanaka, Solvi Arnold, and Kimitoshi Yamazaki. EMD net: An encode-manipulate-decode network for cloth manipulation. *IEEE Robotics and Automation Letters*, Vol. 3, No. 3, pp. 1771–1778, 2018.

目次

第1章	序論	9
1.1	本研究の背景	11
1.2	本研究の目的	12
1.3	本論文の構成	14
第2章	生活支援ロボットにおける教示認識による適応的操作学習	15
2.1	はじめに	17
2.2	ロボットにおける認識と操作	17
2.3	ロボットにおける教示認識と適応的操作	20
2.3.1	認識から回帰的に操作入力を入力するシステム	20
2.3.2	認識と操作入力から誤差逆伝播により操作入力を修正するシステム	22
2.4	本研究のアプローチ	24
2.4.1	生活支援ロボットの活用	25
2.4.2	教示認識の設計	25
2.4.3	教示認識から適応的操作の生成	26
2.5	本研究で取り組むタスク	26
2.5.1	使用済み食器類の片付けタスクの全体像	26
2.5.2	汚れた食器類の把持とトレイ上に配置	26
2.5.3	食器類を載せたトレイのシンクへの運搬	26
2.5.4	汚れた食器類の水濯ぎと擦り動作による洗浄と水切り籠に配置	27
第3章	視覚情報に基づく把持箇所に制約のある食器類の把持学習	29
3.1	はじめに	31
3.1.1	関連研究	31
3.1.2	本研究における食器類の把持システムの特徴	32
3.2	視覚認識からの把持成功確率の推論とその逆伝播による把持点と姿勢の選択	33
3.2.1	把持学習ネットワーク構成	33
3.2.2	教師あり学習用のデータセットの自動収集	34
3.2.3	収集データからのネットワークの学習	35

3.2.4	ネットワークの逆伝播による把持点と姿勢の最適化	36
3.2.5	把持点と姿勢における制約の考慮	39
3.2.6	ニューラルネットワークの詳細	39
第4章	動作教示を伴う視力覚に基づく食器類の濯ぎと擦り操作学習	41
4.1	はじめに	43
4.1.1	関連研究	43
4.1.2	本研究における食器類の洗浄システムの特徴	45
4.2	動作教示を伴う視力覚認識からの自己認識モデルの推論とその逆伝 播による適応的操作量の修正	45
4.2.1	認識からの自己認識モデルの構成	45
4.2.2	食器類の水濯ぎと擦り動作のデータセットの収集	46
4.2.3	食器類の水濯ぎと擦り動作の訓練	47
4.2.4	ネットワークの逆伝播による水濯ぎと擦り動作軌道の最適化	48
4.2.5	ニューラルネットワークの詳細	50
第5章	生活支援タスクを行うロボットシステムの構成	53
5.1	はじめに	55
5.2	台車移動型双腕ロボット PR2 のハードウェア	55
5.2.1	ハードウェアシステムの全体像	55
5.2.2	視覚	55
5.2.3	腕部	57
5.2.4	エンドエフェクタ	57
5.2.5	体内通信システム	57
5.3	認識と操作のための基盤ソフトウェアプラットフォーム	58
5.3.1	ROS	58
5.3.2	OpenCV	58
5.3.3	MoveIt Grasps	59
第6章	使用済み食器類の片付けにおける統合実験	61
6.1	はじめに	63

6.2	汚れた食器類の把持実験	63
6.2.1	実験準備	63
6.2.2	自動アノテーションによる把持訓練	64
6.2.3	未知食器類の適応的把持	64
6.2.4	考察	67
6.3	汚れた食器類の水濯ぎと擦り洗い実験	68
6.3.1	予備実験	68
6.3.2	食器類の洗浄における準備	71
6.3.3	食器類の擦りと濯ぎにおける操作教示	71
6.3.4	食器類の擦りと濯ぎにおける適応的操作	72
6.3.5	考察	74
6.4	生活支援ロボットにおける食器類の後片づけにおける統合実験	76
6.4.1	使用済み食器類の把持	76
6.4.2	使用済み食器類の運搬	76
6.4.3	使用済み食器類の洗浄と設置	77
第7章	結論	85
7.1	本研究の総括	87
7.2	本研究の成果	87
7.3	本研究の結論	88
7.4	本研究の課題と展望	88
	謝辞	91
	参考文献	97

第1章

序論

1.1 本研究の背景

家事支援ヒューマノイドロボットが家庭に浸透する日はいつ来るだろうか．これまで，主にロボットが導入されてきたのは産業界で，ヒューマノイドではなくアーム型ロボットである．産業用ロボットは，自動車や電子部品を生産する過程で，溶接や塗装，部品取り付けを行うものが多くみられる．これらの作業は，高温や粉塵などの過酷な環境である場合や，重量物の運搬である場合，決まった動作の繰り返しである場合，タスクに精度が必要である場合が多く，人が不得意でロボットが代替しやすい作業である．また，品質の安定性を保て，生産効率を向上させることができ，人件費を削減できることで，コストの観点においても利点が多い．産業用ロボットは，ファナック [1] や ABB [2], KUKA [3] などの企業が製造するものが多い．

一方，産業用ロボットと対となる存在としてサービスロボットがある．サービスロボットは，レスキューロボットや医療用ロボット，接客ロボットなどを含み，家庭に導入可能なサービスロボットは，清掃ロボットとコミュニケーションロボットが挙げられる．ここで，清掃ロボットは，洗濯機などの家電製品と異なり，状況に応じ自律的な行動をとるものとする．清掃ロボットは，床面を清掃する iRobot 社の Rumba が挙げられる．コミュニケーションロボットは，AIBO [4] や LOVOT [5] が人気を博している．このように，家庭で普及し始めているロボットは，家事の代替と家族の一員という2つの目的で家庭に迎えられている．ここからは特に，前者の家事の代替の面に着目する．世界のロボット家電・コンシューマ向けロボットの出荷台数は，Omdia によると，2020 年度で 1410 万台で 2023 年には 2410 万台に上ると予測されている [6]．アイロボットジャパン合同会社によると [7]，iRobot 社のルンバとブラーバは国内累計出荷台数が 2020 年末までに 400 万台を突破し，同社は 2023 年までに全国世帯普及率を 10% にすることを目標としている．しかしながら，床面清掃以外の家事において，自律型ロボットは普及していない．また，家庭に迎えられているロボットは，ヒューマノイドロボットではなく，一つのタスクや目的に特化した形状と性質を備えている．

サービスロボットの開発を促進すべく，複数のタスクや多様な対象物操作を課題とする，ヒューマノイドロボットを用いた競技大会が実施されている．ヒューマノイドロボットによる災害救助競技大会は，2015 年に DRC (DARPA Robotics Challenge)

が行われた。高度な不整地歩行やバルブ操作などの作業タスクを通じて、研究開発は大いに加速された [8]。しかし、タスクを全て遂行した機体は少なく、災害救助にヒューマノイドロボットを使う困難さが再確認された。2015年から開催された APC (Amazon Picking Challenge) [9, 10] では、物流の自動化課題に向けてのピッキングタスクが行われた。透明物体などの認識や柔軟物と極薄物体の把持の困難さが再確認され、基礎技術の見直しに繋がった。DRC では2足歩行ロボットが見られたが、APC では脚の無い双腕ロボットが見られた。これは、サービスロボットの実社会への導入のため、必要最低限のハードウェアを備えた、低コストなロボット開発の潮流と捉えられる。WRS (World Robot Summit) [11] の競技の一部では、トヨタ自動車株式会社製のロボットである HSR (Human Support Robot) [12] が起用されている。APC で見られた双腕ロボットと比較すると、HSR は単腕で小型で移動台車を備えている。WRS では、商品陳列タスクやトイレ清掃、部屋の片付けタスクの競技大会が行われ、コンビニなどの商業施設と、雑多な生活環境におけるサービスロボットの实用化を目指している。

1.2 本研究の目的

1.1 節で、産業用ロボットからサービスロボットへの研究開発の潮流を概観した。サービスロボットは、災害現場や物流だけでなく商業施設や生活環境といった、より身近な場所に実用化する試みがなされている。また、サービスロボットは、より簡素なハードウェアで導入コストを下げている。

本稿では、移動台車付きの双腕ヒューマノイドロボットを用いて、生活支援タスクを行う。生活支援タスクの中でも、食器類を把持して運搬し洗浄するという、食器類片付けタスクは課題が多い。食器類片付けタスクの中でも「把持」と「洗浄」の場面の課題に着目した。把持する際は、食器類のどの箇所でも掴めるが、可能な限り汚れを避けて掴むのが望ましい。洗浄する際は、汚れを落とすために擦る動作が必要であり、食器を落とさず、水を飛ばさず、適度な力加減で擦るのが望ましい。また、移動台車付き双腕ヒューマノイドロボットを用いるのは、汚れの擦り動作をするためには双腕が必要であるからであり、食器類の運搬のために移動台車が必要であるからであり、人の普段使用するダイニングキッチンでタスクを行うためである。

食器片づけタスクは、当研究室でも過去に研究がなされている。岡田らは、HRP2 ロボット [13] で皿を水で濯ぐタスクを含めた日常生活タスクを行った [14]。藤本らは、アーム型ロボットを用いて食器類片付け操作の計画と制御を行った [15, 16, 17]。当研究室以外でも、コネクテッドロボティクス [18] や TRI [19] が、深層学習を組み合わせたソリューションを提供している。スマイルロボティクス社 [20] では、配膳ロボットを開発し、認識から食器類の把持と運搬を行う。これらのロボットを用いた食器片づけタスクの論文やデモ動画を見ると、確かに多種多様な食器類を扱うことができている。例えば、コップや平皿、スプーンを把持し、食器洗浄器に置くことができている。

しかしながら、論文の図や動画では不自然な場面が2点ある。1点目は、片付ける食器類の配置が整っていたり予めトレイの上においてあることである。現実では、使用済み食器は雑多に放置されている場合がある。2点目は、どの食器類も汚れが付いていないか、汚れがついていてもロボットは考慮せずに扱っている点である。現実では、ハンドが汚れるため可能な限り汚れを避けて掴む。また、頑固な汚れが洗浄器で本当に落ちるのは定かでない。

ここで、そもそも食器類を洗浄する機械は食器洗浄器があり、ヒューマノイドロボットは不要と思われるかもしれない。実際、食器洗浄器は飲食店や家庭に普及している。筆者は、4年間飲食店でよく洗い場を担当し、食器洗浄器を用いて使用済み食器を片付けていた。ここで重要なのは、食器洗浄器があるのにも関わらず、筆者のような洗い場担当が必要であるという現実である。洗い場担当は、汚れた食器類をそのまま洗浄器に入れず、汚れた皿を洗剤のついたスポンジで擦って濯いでから食器洗浄器に置く。これは、汚れた食器類全てをそのまま食器洗浄機で洗浄すると、複数の問題が生じるからである。一つは、汚れが大量に付着しているか、油汚れや焦げ付きという落ちにくい汚れが付着していることで、汚れが落とすきれない場合がある。また、食器洗浄器は、洗浄時の汚れを網で受け止めているが、洗浄器内で水を循環させているため、汚れた水を循環させることになる。さらに、耐熱温度の低い食器や鉄鍋、漆塗りの食器は、食器を痛めるため洗浄器を使わず、手洗いをする必要がある。このように、先行事例では、現実問題としての食器類片付けタスクに即していない。

そこで本研究は、現実問題としての食器類片付けタスクを行う。ロボットが、雑

多に置かれた複数種類の汚れた食器類をできるだけ汚れている箇所を避けて掴む点と、スポンジで擦って濯いで汚れを落とす点に注力する。このタスクを通して、汚れや水といった制限をどのようにロボットに教示するのか、また対象物の多様な状態に応じてロボットはどのような操作を実現すべきなのかを明らかにする。

1.3 本論文の構成

本稿は、全7章から構成される。

第1章「序論」では、本研究の背景と目的、及び本論文の構成について述べた。生活支援ロボットへの関心が高まる中、生活支援ヒューマノイドをロボット用いて、食器片づけタスクを行うに至った。

第2章「生活支援ロボットにおける教示認識による適応的操作学習」では、生活支援ロボットとして求められる要素を先行研究を参照しながら議論し、タスクを遂行するためのシステムアーキテクチャについて述べる。

第3章「視覚情報に基づく把持箇所に制約のある食器類の把持学習」では、物体把持の観点から、把持箇所に制約のある中で、認識から最適な把持点と姿勢を出力するシステムについて述べる。

第4章「動作教示を伴う視覚に基づく食器類の濯ぎと擦り操作学習」では、擦り動作の観点から、擦り方に制約のある中で、認識と人の教示から危険を回避した擦り軌道を出力するシステムについて述べる。

第5章「生活支援タスクを行うロボットシステムの構成」では、提案システムを構築する、ロボットのハードウェアとソフトウェアアーキテクチャについて述べる。

第6章「使用済み食器類の片付けにおける統合実験」では、生活支援ロボットを用いて、教示認識と適応的操作学習を行い、実行結果の評価を行う。

第7章「結論」では、本研究の成果とその効用をまとめ、今後の研究への応用性について述べる。

第2章

生活支援ロボットにおける教示認識による適応的操作学習

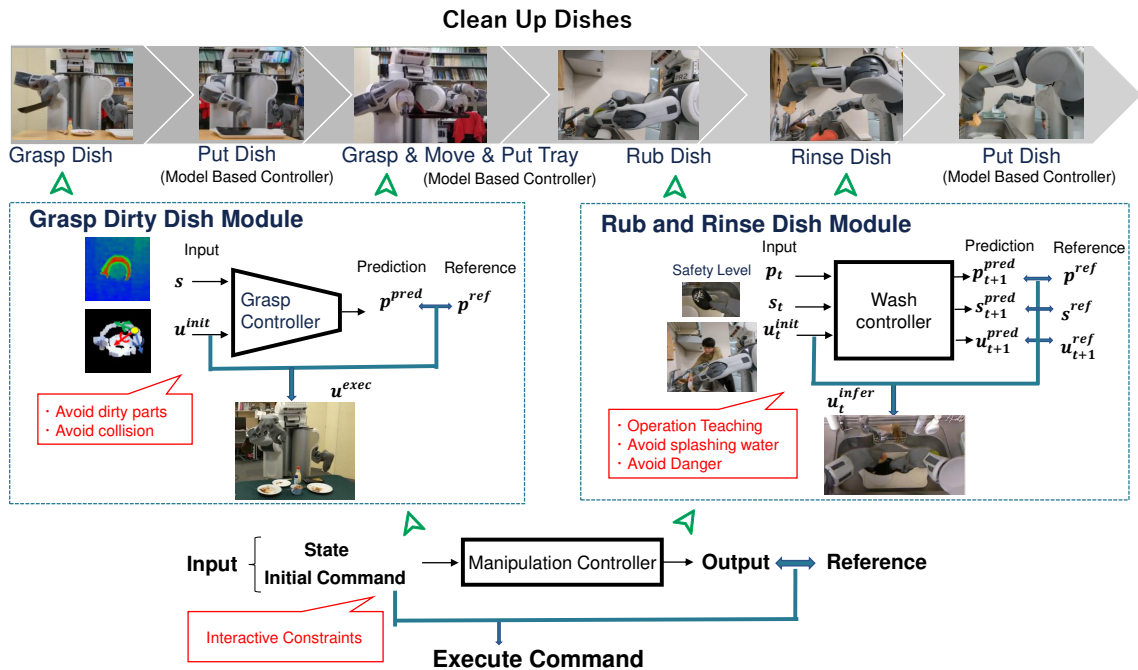


Fig. 2.1: Whole system overview

2.1 はじめに

本章では、ロボットが自身の認識と人の教示により、適応的な行動を実現するための戦略を考察する。はじめに、ロボットにおける認識や教示、動作計画における先行研究とその課題について述べる。次に、本稿におけるアプローチや特色を述べる。

2.2 ロボットにおける認識と操作

ロボットが認識から操作計画を立て実行する方法を考察する。人の場合は、5感の認識から情報を得て意思決定に反映する。ロボットの場合は、センサを取り付けることで認識器を拡張する。

ロボットの認識における視覚と力覚

ロボットにおける認識の中で、視覚と力覚に着目する。視覚はロボットにカメラを付けることで実現でき、力覚は関節のモーターの電流値から推定できる。

まず、視覚から3次元の対象物を認識する方法を考察する。従来は、予め登録したCADモデルとカメラから得た距離画像を組み合わせて行われた。モデルと入力シーンとの対応関係を見つけるために、SHOTやFPFHをはじめとする特徴量抽出手法が用いられた。得られた特徴量から、予め登録した物体との対応付けを得るために、例えばICP(Iterative Closest Point)という手法が用いられた。しかしながら、従来手法は、正確に対応点を見つけるのが困難であり、演算時間も要した。最近では、深層学習を用いて、予めモデルを用意することなく、認識から直接対応点を見つける研究が盛んに行われている。物体の取手やハンドルなどの意味的な対応点を見つける研究や、物体表面全体に対応点をつけたDense correspondenceという研究が行われている。しかしながら、深層学習による対応点の検出には、人が物体に対してアノテーションをすることが必要である。また、正確に対応点を見つけた場合でも、ロボットの認識は行動計画と別の問題となる。

力覚を用いた認識は、接触センサをつける場合と、関節のトルクを用いる場合がある。前者は例えば、タクティルセンサを用いて圧力分布を認識する。タクティルセンサなどの接触センサを用いた認識は、操作力を微調節するタスクに適している。接触センサによる認識の課題は、ロボットに取り付けが困難な場合があること、センサが破損しやすいことが挙げられる[21]。関節のトルクを用いた認識は、関節にトルクセンサの有無で場合が分けられる。トルクセンサがある場合は、正確にトルクを認識できるため、制御理論に基づく正確な制御が可能である。トルクセンサがない場合は、関節のモータに流れる電流値から負荷トルクを推定する。正確なトルク値が不明な場合、制御理論に基づく正確な制御は困難である。ただし、学習型制御をする場合は、誤差を含めて訓練することで、誤差を考慮した推論が可能である。

認識に基づく操作計画

視覚や力覚における認識を用いて、操作計画を行う。操作計画は、人間が予め設計する場合と、人間が教示する場合と、ロボット自身の経験を元に自律的に計画する場合がある。

まず、人間が予め設計する場合について考察を行う。視覚に基づいてロボットが操作する例として、把持では把持点に対して人間が決めた位置と姿勢で把持する。力覚を用いた適応的な物体把持においては、圧力分布から物体を滑り落とさない最

小程度の力で把持を実行する研究が行われている [22]。また、手の中でボールの操り [23] や、双腕での押しや引き操作、ピボット操作にも応用されている [24]。人間が設計するため、人間の想定内でロボットが操作する安全性が保障される。一方、未知の物体に対して適応的に操作することは困難である。

人間が教示する研究は、國吉らが、人間の実演をロボットが実時間視覚認識によって教示する研究が行った [25]。人間の作業を認識した情報を行為単位に分節し、同等の別の作業をロボットが実行するシステムを構築した。適用タスクは、積み上げ作業をはじめとした [26] とした組み立て作業の教示実験を行った [27]。片手だけでなく、双腕を用いた複雑な教示を行う研究や [28]。幾何学的制約と合わせて教示する研究も [29] 取り組まれている。室岡ら [30] は、ロボットの全身を使い、教示と試行によって物理的整合性の推論に基づいて操作を行った [31]。しかしながら、ロボットの認識に依存する場合は、その認識精度がタスクの成功率に大きく寄与する。前述の研究は、認識が正確であることを仮定している。認識において対象物を特定しない場合は、混合ガウス分布に基づく隠れマルコフモデルを利用する研究がされている [32]。また、次元の大きなデータを扱う場合は、深層学習を利用して教示を認識するケースが多い [33]。例えば、一度の教示のみで、初見の物体を押し・持ち上げる・置く・ことできる [34]。ロボットの双腕を用いたタスクでは、例えば水を灌ぐタスクが成功している [35]。教示において、視覚と力覚を組み合わせたマルチモーダルな認識を生かした研究が行われている [36, 37]。マルチモーダルな認識において、視覚と力覚の優先度を考慮するため、それぞれの信頼度で重みづけを行う研究 [38] がなされている。

ロボット自身の経験を元に自律的に計画する場合は、強化学習を用いる。強化学習の分類方法の一つとして、モデルベースとモデルフリーがあげられる。モデルベース強化学習は、環境モデルを使用する。利点は、サンプル効率が向上することである。欠点は、正確なモデルの作成や、推定が困難であることや、学習したモデルのみ最適され、現実世界とモデルが乖離する可能性があることである。一方、モデルフリー強化学習では、環境モデルを使用しない。サンプル効率は悪いが、実装や調整が簡易である。マニピュレーションにおいては、モデルのパラメータ同定などの制御面で、モデルベースの手法が主流である。例えば、適応制御やモデル予測制御など、不確実なモデルのパラメータを推定する手法が研究されている。S. Levine 氏

らの End-to-end training of deep visuo-motor policies [39] では、視覚情報から強化学習と融合させた最適制御を行う。現代制御論と機械学習の融合により、ロボットの視覚で複雑な操作を実現させた。具体的には、制約付き最適化 (Guided Policy Search) モデルで達成した。これは、まず知覚学習として、視覚情報から深層学習で最適方策を見つける。ただし、この方策は、制御上実現可能か不明である。そこで、現代制御理論 LQR による最適制御により、移動目標への軌道 p を逆軌道問題で解く。この二つを Guided Policy Search (GPS) を用いることにより、知覚学習 π を現代制御論 p のいずれか一方を用いて制御するよりも、タスクの成功率が向上した。モデルフリーの強化学習は、手の中でボールを操りタスクが実現されているが [40]、他の多くのタスクにおいては、実機で失敗を含む試行を繰り返すことは困難である。また、局所最適な行動に陥り過学習をする場合や環境の変化に弱く再現率の低さが問題とされている。そのため、実世界のロボット操作への応用は限定的である。

2.3 ロボットにおける教示認識と適応的操作

2.2 節では、ロボットにおける認識から操作計画を立てて実行する方法を網羅的に概観した。4.1.2 節では、その中でも教示を含み、ロボットの視覚と力覚から、ロボットが適応的な操作をすることが可能なアーキテクチャについて掘り下げる。認識において、多次元の情報を扱うため、特に深層学習を用いた手法にアプローチする。そのアーキテクチャは大きく2種類ある。1つ目は第2.3.1節「認識から回帰的に操作入力を出力するシステム」で、2つ目は第2.3.2節「認識と操作入力から誤差逆伝播により操作入力を修正するシステム」である。それぞれのネットワークの形式を2.3.1節と2.3.2節で述べる。

2.3.1 認識から回帰的に操作入力を出力するシステム

モデル化と制御系の設計

状態量から制御量を出力するネットワークは、入力と出力に任意のデータを置くことができる。ニューラルネットワークを f 、ロボットの状態量を x 、ロボットの制

御入力を u と置くと，

$$u_{predict} = f(x) \quad (2.1)$$

と書ける．ここで，入力に x には u が含まれていることもある．ネットワークの訓練時は，次のように予測した制御入力と実際の制御入力の誤差を学習する．

$$L = Loss(u_{predict}, u_{actual}) \quad (2.2)$$

$Loss$ は，最小二乗法や Binary Cross Entropy のような誤差関数である．推論時は，訓練済みのネットワークの重みを固定して式 2.1 を適用する．

状態入力から操作入力を回帰的に出力するネットワークの考察

まず，利点としては，モデルの設計において物理学的な意味を考えることなくニューラルネットワークを構築できるということである．状態方程式を立式する代わりに，ニューラルネットワークの学習によって，状態方程式のようなモデルを獲得するとされている．つまり，厳密な式を立てずとも直観的に作成でき，初学者にも扱いやすい．また，状態量として，ロボットの姿勢や速度だけではなく画像やセンサ情報も含めることができる．さらに，入力や出力を容易に変更ができる．例えば，入力状態量を初めは画像情報のみとしていたが，途中でロボットの関節角度情報を追加したいとなった際とする．状態方程式を考える必要がないので，単にネットワークの層の形状についてプログラムを変更するだけで対応できる．

欠点は，訓練学習に時間を要することである．入力と出力には，基本的に物理的な立式が困難な2つを配置するケースが多く，回帰的に入力と出力を結びつける．そのため，入力と出力の関係性を学習するには，正解のデータセットを用意する必要がある．また，適用するタスクが簡単なものでないと，学習が困難である場合がある．例えば，ハンガーをかける動作軌道や，箱のふたを閉める動作軌道を出力することは，先行研究でも行われている．しかし，どの程度複雑な動作に応用できるか疑問である．

状態量の次元は，大きくなるにつれて学習が困難になる．例えば，画像をニューラルネットワークの入力とする場合，出力がロボットの関節角度のみであれば，数百枚の画像で学習できることが後述の関連研究で述べられている．しかし，状態量

として画像と圧力分布センサなどの入力を比較すると、画像の次元の方が圧倒的に大きい。画像とその他のセンサ情報をニューラルネットワークで結合して学習すると、画像の次元にセンサ情報が負けて、学習が失敗する場合がある。そこで、画像を AutoEncoder[41] で事前に学習し、その特徴量を別のニューラルネットワークに組みこみ、動作学習を行っている研究が盛んに行われている。

最も単純な例として、Neural End-to-End Self-learning of Visuomotor Skills by Environment Interaction を紹介する [42]。RGB 画像を入力して、ニューラルネットワークで畳み込み、ロボットの関節角度を出力している。これを毎時刻行うことで、物体を把持することに成功している。ただし、この把持タスクは、物体にリーチングして掴むという単純なものであり、扱う物体の形状が変わってもうまく把持ができるのか不明である。画像を状態量として用いる場合に、事前に AutoEncoder[41] で学習して、圧縮した特徴量を他のセンサ情報と共に別のネットワークに組み込んでロボットの操作量を出力する研究が盛んに行われている。例えば、紐を結ぶタスク [43] や、雑巾がけをするタスク [44] が取り組まれている。紐を結ぶタスクにおいては、紐を結ぶ最中の画像を CAE という AutoEncoder にエンコード&デコードをして、その特徴量を $f_t : 30[dim]$ で得る。次に、ロボットアームの関節角度 m_t と近接センサの値 s_t を画像の特徴量と合わせる。それを LSTM ブロックに入力・出力して、時系列の動作を学習する。LSTM は、再帰型のニューラルネット (RNN) を応用して、長期的・短期的な記憶を考慮した時系列のデータを学習する、近年盛んに用いられるネットワークである [45]。雑巾がけのタスクは、紐を結ぶタスクと著しく似ているネットワーク構造で学習する。紐を結ぶタスクでは近接センサを用いていたが、拭くタスクでは、タクトイルセンサ (圧力分布センサ) の情報を状態量として学習している。解析的な観点からネットワークの構造を改善して、タスクの成功率を向上させる研究もなされている [46]。

2.3.2 認識と操作入力から誤差逆伝播により操作入力を修正するシステム

前章では、状態量 (制御量も含む場合がある) から回帰的に制御量を出力していた。このネットワークを発展させ、制御入力の制約を与えやすいネットワークを紹介する。

モデル化と制御器の設計

入力を状態量と制御量とし，出力を次の状態量の予測値とする．

$$x_{predict}^{t+1} = f(x_{actual}^t, u_{actual}^t) \quad (2.3)$$

入力の x^t, u^t は，一時刻のデータのみでなく，一定時間のデータを入力してもよい．

訓練時は次の Loss 関数で行う． $x_{predict}, x_{actual}$ についても入力と同様，一時刻のデータの誤差のみでなく，時間平均の予測・実測データの誤差をとってもよい．

$$L = Loss(x_{predict}, x_{actual}) \quad (2.4)$$

推論時は，初期入力値を誤差逆伝播により修正して制御入力とする．

$$u^{t+1} \leftarrow u^t + \gamma \frac{\partial L}{\partial u^t} \quad (2.5)$$

$$s.t. 0 \leq u^{t+1} \leq \frac{\pi}{2} \quad (2.6)$$

u に関する制約は，様々な場合が考えられる．上式では簡単のため， u に関する不等式制約を設けたが，二次計画法などによる最適化問題に帰着することもできる．

操作入力と状態量から次の状態量を予測し，誤差逆転により制御入力を修正するネットワークの考察

初期制御量を与えて修正する形式のため，入力制御量に制約を与えることができる．制約とは，入力における入力トルクや，速度や位置に関してである．ある程度軌道がわかっているならばモデル予測制御の形式のように扱うことができる．入力の制約を与えられるという点で，モデル予測制御と似ている．モデル予測制御は，既知の制御モデルに基づいて，逐次的に最適化問題を解くことで制御入力を決定する方法である．モデルは線形と仮定して，制約条件が凸最適化アルゴリズムで解けるようなものであれば，解きやすい．しかし，現実的には非線形のモデルが多く，テーラー展開を行って線形と仮定する等工夫する必要がある．ニューラルネットのモデルを用いれば，線形モデルと同様に扱える．

注意点は，初期値に依存しやすく局所解に陥ることがある点である．また，制御入力を出力するために，周期毎に誤差逆伝播をする必要がある．状態変数の次元が

大きくない場合や、高性能のコンピュータを用いることが可能な場合はよいが、制御周期が早くリアルタイム性を要する場合は、時間遅れが生じる場合がある。

関連研究としては、まず、Emd-net が挙げられる [47, 48]。EMD-net は、Encode-Manipulate-Decode network の略称で、状態量をエンコードするモジュール、操作量に関するモジュール、次の状態をデコードすることで生成するモジュールから成る。この論文では、Emd-net を用いて布を畳むタスクを行っている。状態量は、視覚情報から得られる3次元の布の voxel 値を用いている。また、操作量は6DoFのアームの先端位置としている。初めに、布の voxel 値をエンコードして、操作量をニューラルネットワークに加えてからデコードすることで、次のステップの状態量の予測を行っている。その予測と実際の布の voxel を誤差を比較して、制御量を調整している。その結果、操作軌道が最適になるように修正されて、目標となる布の折り方を実現することができた。成功率をを縁の重なり度合いで評価した結果、平均76.5%であった。

この研究では、柔軟物というモデル化しにくい対象物の操作について、ニューラルネットワークで学習させることで、操作を加えたときの柔軟物の形状の変化を予測することに成功している。また、操作量についても、布を把持する点から放す点までの軌道を修正することができる。

課題点は、誤差逆伝播による操作量の修正の評価である。論文中では、布の目標と実際の状態の一致率を評価しているので、修正された操作量が有効であったと間接的に結論付けられる。しかし、多様な動作が考える中で、同一のネットワークの誤差逆伝播で、毎度最適な動作に修正されるとは限らない場合がある。

2.4 本研究のアプローチ

本研究は、教示を含む認識を行うことと、適応的な操作を実現するため、2.3.2節のアーキテクチャを採用する。訓練時における認識方法は、2.3.1節と2.3.2節は同様だが、実行時に訓練時と実行環境が変化した場合に、制御入力条件や目標値が変更された場合に柔軟できる点で、2.3.2節は後述する本研究のタスクに適すると考えられる。この「学習型」アーキテクチャを中心に、「生活支援ロボット」を用いた「教示認識」に基づく「適応的操作」を実現する。

2.4.1 生活支援ロボットの活用

本研究で使用するロボットは、生活支援ロボットであり、産業用ロボットとは異なる。ロボットは、等身大の移動台車付き双腕ヒューマノイドロボットであり、人が家で生活する場所に移動して、対象物を操作することができる。詳細は、第5章で述べる。

2.4.2 教示認識の設計

視覚に基づく認識

本研究で用いる視覚情報は、RGB画像と深度画像である。本研究では、得られた画像から特徴量を抽出し、動作計画に生かす。例えば、物体の縁を検出する場合(第3章)や、対象物の大きさと位置、姿勢を検出する場合(第4章)がある。

力覚に基づく認識

本研究で用いる力覚情報は、双腕ロボットの関節におけるトルク推定値である。本研究では、動作計画においてトルクが必ずしも正確な値である必要はない。推定トルクは、ロボットのハードウェアにおけるたわみや負荷の大きさに応じて誤差が生じる。しかしながら、第4章ではこの誤差を含めて学習をし、操作計画に生かすことが可能である。

教示認識

本研究では、人が教示を行いながら、ロボットが視覚と力覚を用いた認識を行う。視覚情報における特徴量抽出は、認識器の性能を担保することができ、より人間の意図に沿ったロボットの動作に繋がると期待される。力覚情報においては、ロボットが自発的に認識するだけでなく、人間がロボットの操作軌道を腕を介して修正したことを認識する。このように学習型制御の訓練時において、ロボットの認識器に人間の特徴量設計がなされる場合や、オンラインに人から制約や動作を教えられて動作計画に生かすような認識器を、教示認識と呼ぶこととする。教示認識を学習することは、視覚と力覚情報に基づいた自己認識モジュールの生成に繋がる。

2.4.3 教示認識から適応的操作の生成

教示を含んだ認識から操作計画を行う。本研究では、認識から直接操作を出力するのではなく、オンラインで与えられた制約や目標値によって操作量を変化させる、2.3.2節のアーキテクチャに基づいて生成する。制約や目標値は必ずしも訓練時に与えられる必要がなく、実行時において訓練にない指示を与えられる。したがって、教示認識から自己認識モジュールが生成された後に、実行環境における条件に応じて適応的な操作が可能となる。

2.5 本研究で取り組むタスク

本研究では、第6章食器類の片付けタスクを行う。そのタスクの中でも、食器類の把持と洗浄において、教示認識と適応的操作を生かす。その他の操作は、モデルベースの操作を行う。

2.5.1 使用済み食器類の片付けタスクの全体像

人間の食事が終わった机の上に食器類が散乱している。ロボットがそれらを掴んで運び、洗浄して水切り籠に置く。

2.5.2 汚れた食器類の把持とトレイ上に配置

使用済み食器類を、他の物体に当たらないように、且つ汚れている部分を掴まないような条件で、最適な位置と姿勢で把持を行う。把持において第3章の学習システムが適用する。把持後はトレイに載せて運搬の準備を行う。

2.5.3 食器類を載せたトレイのシンクへの運搬

食器類を載せたトレイを両手で把持しながらシンクに移動し、シンク台に置く。トレイの把持においては、第3章のシステムを適用するが、移動や置き動作は予め設計されたモデルベースである。

2.5.4 汚れた食器類の水濯ぎと擦り動作による洗浄と水切り籠に配置

使用済み食器類を濯ぎ，汚れている部分に対してスポンジで擦り，もう一度濯いでから水切り籠に配置する。「濯ぎ」と「擦り」において第4章の学習システムを適用する．蛇口のハンドルを押して水を出す操作や水切り籠に置く操作は，モデルベースである．

第3章

視覚情報に基づく把持箇所に関する制約のある食器類の把持学習

3.1 はじめに

本章では、把持箇所の制約を考慮した物体把持について説明する。把持は、物体を操作する基本的な動作である。私たちは、幼少期から物体を見て実際に掴む経験を積み、次第に直観的に掴み方を決められるようになる。私たちは、物体のどの点を掴むのか、手をどの程度傾げるのかということ深く考えず、無意識的に手の動かす。同様にロボットも、人が逐次掴み方を教えずに、視覚情報から自らの試行経験を通して把持能力を獲得していくことが期待される。多くの物体は、把持可能な部分が複数点あるが、中には掴むべきでない箇所もある。この章では、人間がプランナーをモデル化するのではなく、食器を一瞥して把持試行を繰り返すことで、ロボットが制約のある把持点と姿勢を決定できることを検証する。

3.1.1 関連研究

ロボットが認識から把持計画を立てて評価を行う研究は、従来より盛んに行われてきた。OpenRAVE や MoveIt Grasps [49, 50] は、把持のためのオープンソースのプラットフォームとして開発された。

把持点や姿勢の決定法については、対象物体の基準形状からの変形量に対して求める手法 [51, 52] より局所的な幾何情報を元に求める手法 [53, 54] が提案されてきた。最近では、深層学習を用いて、目に見える特徴からより抽象化された潜在的な表現に基づく手法も提案されている [55, 56, 57]。

そのような研究により、物体把持の精度は著しく向上した。しかし、把持可能な点が複数ある物体に対して、本来は一点に定まらないはずだが、盲目的に一つに決定している。また、それらは、対象物に対して一対一で把持点と姿勢が出力され、環境制約や入力制約を考慮できない場合がある。

そこで本稿では、複数解が存在するときに初期値に近い解が選ばれる学習 [47, 58, 59, 60] に倣った把持学習システムを構築する。このシステムの出力は、把持点と姿勢ではなく、視覚情報からの把持成功確率であり [61]、入力を修正することで把持点と姿勢を得る。また、把持点や姿勢は、初期値の範囲に制限を設けることでそれに近い解が得られる。さらに、実機の試行で環境との接触を繰り返すことにより、自身のハードウェア、特にグリッパの形状をネットワークにエンコーディングしてい

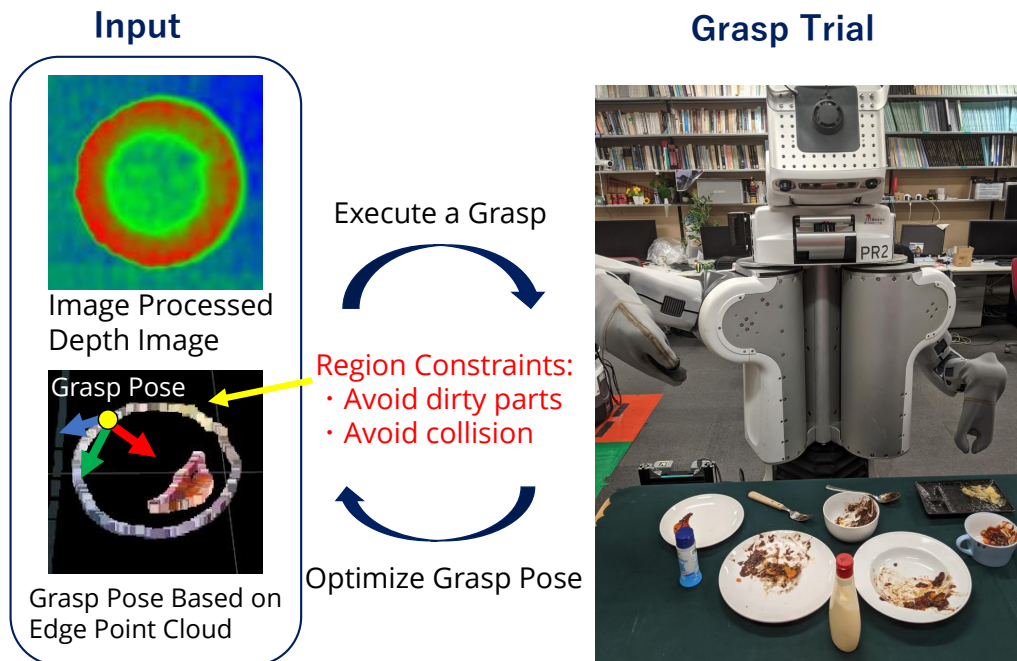


Fig. 3.1: PR2 grasp trial based on depth image and object edge point.

く、提案システムを用いて、ロボットは、視覚情報と自らの経験データセットを自動で収集し、シミュレータを使わずに少ない試行回数で効率よく把持能力を獲得していく [62]。そして、ロボットがこの把持計画を学習することで、未知の食器類を掴めるようになり、また掴む点の場合に応じて狭められるようになることを目標とする。

3.1.2 本研究における食器類の把持システムの特徴

本研究の主な貢献は2点である。1. 把持点および姿勢の制約の柔軟性。2. 食器の把持点と姿勢の効率的な自己教師付き学習。第一の貢献は、複数の把持点を持つ食器類の把持点と姿勢を、制約下で決定することができる点である。把持の冗長性、すなわち掴める点が複数ある中で、汚れや障害物を回避して把持点を決定する。本手法では、物体の状態や環境に依存して、入力値により柔軟に把持点と姿勢を制限することが可能である。第二の貢献では、提案学習システムは、把持の試行を繰り返すことで自動的にデータセットを収集することができる。このため、把持位置や把持姿勢のアノテーションを行う必要がなく、自発的により良い把持位置を獲得する

ことができる。また、正解データだけでなく、失敗データも教師データとして利用
できるため、全ての試行結果を有効に活用できる。提案手法を用いることで、学習
後はロボットが自ら把持位置や姿勢を修正し、未視認物体の把持精度を向上させる
ことができる。

3.2 視覚認識からの把持成功確率の推論とその逆伝播による把持点と姿勢の選択

深度画像と点群から把持点と姿勢を決定し、把持成功確率を出力するニューラル
ネットワークである Vision-based Grasp Probability Network (VGP-Net) を提案する。
このネットワークを用いることで、入力された把持姿勢をより高い把持成功確率の
把持姿勢に修正する。

3.2.1 把持学習ネットワーク構成

学習ネットワークは次の式で表される。

$$p_{predict} = f(s, u) \quad (3.1)$$

s はある時刻の深度画像で、 u は把持点と姿勢、 $p_{predict}$ は把持成功確率で、 f は提案
ネットワークである。 t を把持試行の成功判定ラベルとすると、ランダムな把持実験
から (s, u, t) のデータを取得し、これを用いて f を学習し、 f を用いて把持入力 u を
最適化する。 s は深度画像に画像処理を施したカラー画像である。この画像はニュー
ラルネットによって圧縮され低次元の特徴ベクトルに変換される。 u は、対象物体
の把持点とグリッパの姿勢を表す。特徴ベクトル化された画像と把持点と姿勢ベク
トルは、合わせてニューラルネットに組み込まれる。ネットワークの出力が把持成
功確率の予測値 $p_{predict}$ で、 $0 \leq p \leq 1$ を満たす。把持成功とは、物体を掴んで持ち
上げられることとする。各データの詳細は 3.2.2 項で述べる。

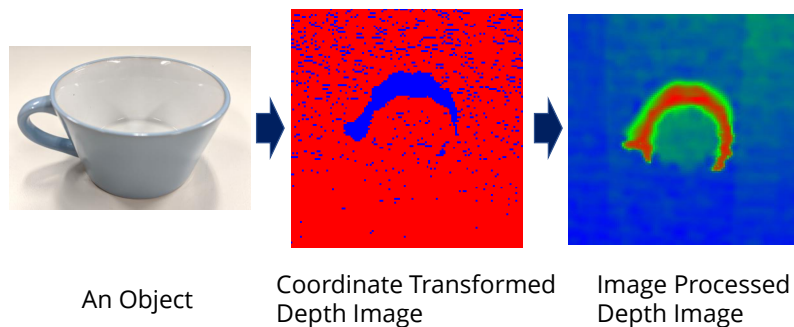


Fig. 3.2: Depth image processing: First, transform coordinate viewed from above. Next, apply morphological filtering to get 3 channels.




Fig. 3.3: Extract edge from target object point cloud and randomly select one point as a grasp point.

3.2.2 教師あり学習用のデータセットの自動収集

把持学習のため、深度画像、把持点と姿勢、把持成功失敗判定フラグを収集する。まず、把持前にカメラから深度画像を取得する。深度画像 s における深度値は、物体を真上から見た座標系に変換する。これにより、同一の物体に対しておよそ等しい深度画像を得ることができる。深度画像のノイズを削減するため、モルフォロジー変換 [63] を施す。モルフォロジー変換は二値画像のノイズ除去や平滑化に有効である。Fig.3.2 は、一連の画像処理過程の様子である。モルフォロジー変換後、1チャンネルである画像を3チャンネルのヒートマップに拡張する。これは、3.2.6 項で述べる学習済み ResNet の入力次元に適合するためである。こうして、ロボットが把持前に、生画像 s から画像処理を施した s' を自動的に取得する。

次に、把持点を決定する。ここで把持点とは、グリッパー先端の爪当たりを指す。把持点や姿勢の決定に当たり、対象物体の点群全てについて探索すると効率が悪い。

そこで、本研究では Fig.3.3 のように物体の縁の点群に着目した。物体のエッジを抽出する手順は以下の通りである。1. RGBD カメラからの点群の取得。2. 点群の集合から机の平面を認識する。3. 机上の点群をユークリッドクラスタリングすることにより、物体を分割する。4. 対象物体のエッジ点群を抽出する。

把持姿勢は、3次元ベクトルで構成される。把持姿勢 ϕ, θ, ψ は、把持点に対して $0 \leq \phi, \theta, \psi \leq \frac{\pi}{2}$ からランダムに選択される。把持姿勢は、グローバル座標系ではなく、ローカル座標系 {Object} とする。これは、グローバル座標系における物体の掴みやすさではなく、ローカル座標系に着目するためである。各軸は、把持点から対象物体の中心に向く方向を $\frac{\pi}{4}$ とする。このようにして、把持点と姿勢は合わせて次のように6次元で表される。 $u = (x, \theta)^T = (x, y, z, \phi, \theta, \psi)^T$ 。

最後に、把持成功判定ラベルデータ t を得る。得られた把持点と姿勢で、対象物を把持して持ち上げる。一連の動作について予め逆運動学を解き、解けない場合は別の把持点と姿勢を選択して、再度逆運動学を解く。それでも逆運動学を解けない場合は、失敗として $t = 0$ を与える。持ち上げる間にグリッパ幅が0より大きい場合は、把持成功とみなして $t = 1$ を与え、グリッパ幅が0である場合は $t = 0$ を与えた。このように、ロボットが自らの試行でデータセット (s', u_{rand}, t) を自動で収集する。

3.2.3 収集データからのネットワークの学習

実際のロボットを使ってデータセットを収集するのは時間がかかるため、学習データを拡張した。画像と把持点はランダムにシフトし、ガウシアンノイズを付加する。これは、把持点が多少ずれても物体を把持できる場合が多いためである。人も物体を把持する際、手の角度を正確に決めずに何気なく把持しているだろう。このようにして、 (s^{prime}, u_{rand}, t) から100倍に拡張されたデータセット $(s_{aug}, u_{aug}, t_{aug})$ を取得する。

これらのデータセットを用いて、バッチサイズを $C_{batch}^{train} = 8$ 、エポック数を $C_{epoch}^{train} = 100$ として、Fig.3.4 のようにモデル f を訓練する。

$$p_{predict} = f(s_{aug}, u_{aug}) \quad (3.2)$$

$$L = BCE(t - p_{predict}) \quad (3.3)$$

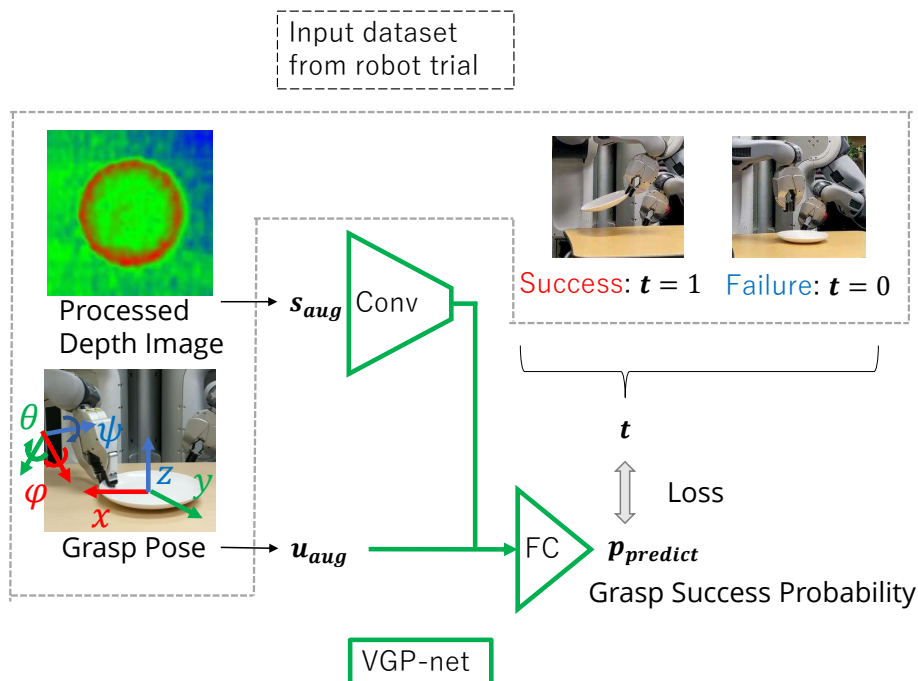


Fig. 3.4: Training phase: Collect the datasets, augment them, and calculate the loss with $p_{predict}$.

ここで、 t は 0 または 1 の把持成功判定ラベルで、BCE は二値クロスエントロピー損失を表す。損失関数の最適化手法は Adam を用いる。

3.2.4 ネットワークの逆伝播による把持点と姿勢の最適化

Fig.3.5 のように、訓練されたネットワーク f を用いて把持点と姿勢の最適化を行う。Algorithm 2 のような手順で行う。

まず、訓練時と同様に、深度画像と把持点を取得する。把持点は、全てのエッジ点群から選択するだけでなく、制限領域内からも選択可能である。得られた処理済み深度画像と把持点および姿勢値をネットワークに代入することで、把持成功確率を出力する。損失関数は、予測把持成功確率と正解ラベルである $t = 1$ との誤差をとる。つまり、成功に近づくように把持点と姿勢が修正される。グリッパの姿勢は、机に平行な平面から垂直方向に $\frac{\pi}{2}$ の間に限定する。

推論把持点は、物体のエッジ以外の点を選択されることがあり、その点では把持を失敗する可能性が高い。そこで、推論把持点に最も近いエッジ点を実際の把持点の候

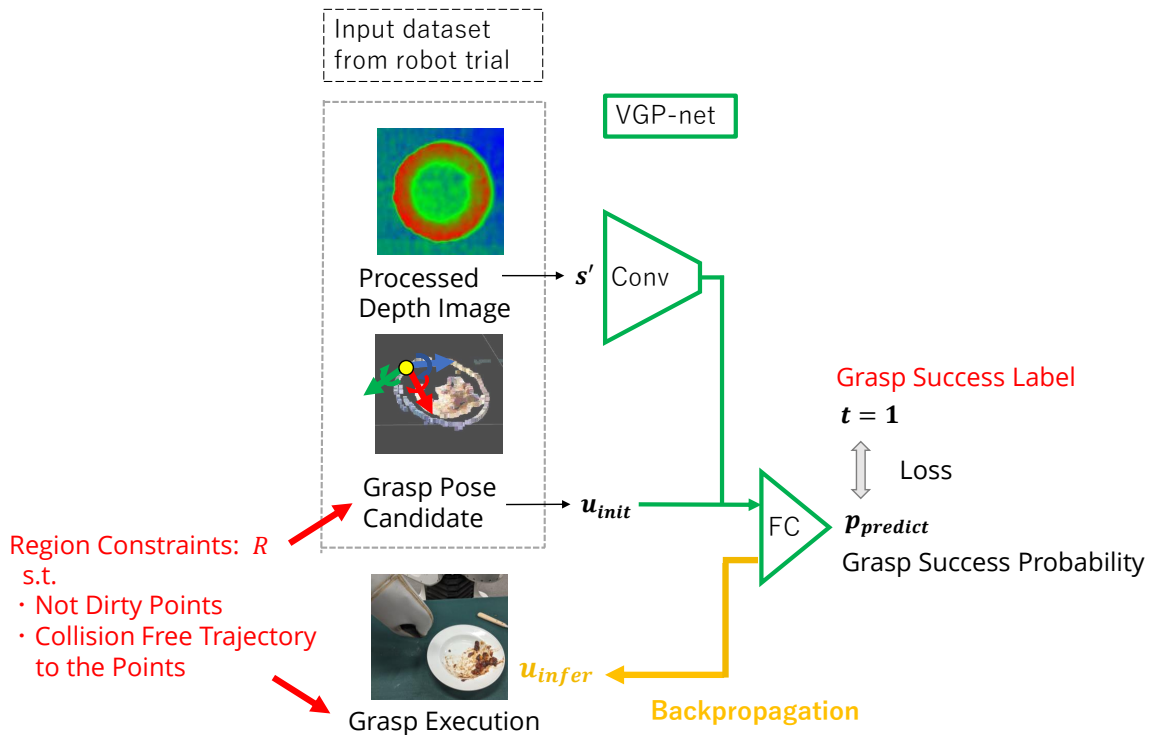


Fig. 3.5: Optimization phase: grasp pose to be u_{infer} using backpropagation of the network.

補とする。このとき、グリッパの姿勢は、推論把持姿勢と同じとする。得られた推論点からの最近傍点と姿勢を、既に得られた処理済み深度画像と共に訓練済みのネットワークに入力する。これを、 C_{iter} 回繰り返す。一連の把持動作の逆運動学を解いて、解けない場合は把持点の選択からやり直す。このやり直しは、 C_{test} 回まで許され、それでも解けない場合は、人が物体の位置を修正する。最終的な $u_{nearest}$ を u_{exec} として、その把持点と姿勢で物体にアプローチする。以降の実験では、 $C_{test} = 10$, $C_{iter} = 10$, $\gamma = 0.1$ とする。

Algorithm 1 Grasp point and posture optimization

s' : image processed depth image
 u_{init} : input grasp point and posture
 u_{infer} : inferred grasp point and posture

Require:

s : depth image
 E : edge point cloud

Ensure:

u_{exec} : grasp point and posture to be executed

```

1: while  $i = 1, \dots, C_{test}$  do
2:   Obtain  $s$  and  $E$ 
3:   Convert  $s$  to  $s'$ 
4:   Choose  $u_{init}$  from the input point clouds  $R$  which are constrained region in  $E$ ,
5:   for  $i = 1, \dots, C_{iter}$  do
6:      $p_{predict} \leftarrow f(s', u_{init})$ 
7:      $L \leftarrow BCE(1 - p_{predict})$ 
8:      $g \leftarrow \frac{\partial L}{\partial u_{init}}$ 
9:      $u_{infer} \leftarrow u_{init} - \gamma g$ 
10:     $s.t. 0 \leq \theta_{infer} \leq \frac{\pi}{2}$ 
11:     $\mathbf{x}_{nearest} \leftarrow \mathbf{x}_{infer}$ 
12:     $s.t. \mathbf{x}_{nearest} \in E$ 
13:     $u_{nearest} \leftarrow (\mathbf{x}_{nearest}, \theta_{infer})$ 
14:  end for
15:  if IK is solved then
16:    break
17:  end if
18: end while
19:  $u_{exec} \leftarrow u_{nearest}$ 
20: return  $u_{exec}$ 

```


3.2.5 把持点と姿勢における制約の考慮

3.2.6 ニューラルネットワークの詳細

ニューラルネットの入力要素の一つである s は、サイズ $128 \times 128 \times 3$ の画像である。画像サイズが大きいと学習パラメータの数も増大するため、学習に時間がかかる。そこで、画像を圧縮するネットワークとして、学習済みの 18 層の ResNet [64] を用いる。ResNet は最終層だけ除き、画像は 512 次元のベクトルに圧縮される。512 次元のベクトルを全結合層に接続して、 $8 + u$ 次元に圧縮し、さらに 1 次元に圧縮する。ここで、 u は把持点と姿勢の入力次元を表す。全結合層の一つ目の活性化層は Relu で、最終層は Sigmoid 層である。損失関数の最適化には、Adam [65] を用いる。3.2.3 項での訓練時は、ResNet の最終層以外の層のパラメータはフリーズして、ファインチューニングする。

第4章

動作教示を伴う視覚に基づく食器類 の濯ぎと擦り操作学習

4.1 はじめに

本章では，人間がロボットの腕を持って直接教示し，ロボットが視覚と力覚情報から対象物とロボット自身の状態，及び操作量の推定を行うことで，ロボットが対象物の操作を獲得していく方法を述べる．獲得する自己認識モデルに基づき，形状や性質が未知の対象物に対して，適応的な操作が可能となる．また，自己認識モデルを用いた推定値と目標値の差を逆伝播することで，目標値に近づく操作量を生成できる．この自己認識モデルを，食器類の濯ぎと擦り操作に適用し，その有用性を明らかにする．

特に食器類の洗浄において，汚れをスポンジで擦って水濯ぐ場面に着目する．ロボットは両手に防水手袋を装備し，片手で食器を把持し，もう片手でスポンジを持って擦る．スポンジで擦る際は，できるだけ強い力で擦ることで汚れが落ちる．しかし，力を入れすぎると系が不安定になって食器類を落とす可能性があるため，程よい力で擦ることが望まれる．水で濯ぐ際は，水が食器上で飛び散らぬような角度にすることが望まれる．2つの操作は適切な制御目標値が不明なため，操作軌道を教示によって獲得する．

4.1.1 関連研究

食器類の洗浄に関する研究は，認識から操作計画，操作制御の統合である．岡田らは，等身大ヒューマノイドロボットを用いて，対象物の認識を行い，フィードフォワードに操作軌道を生成した [14]．また，近接センサを取り付けてより対象物の特徴を捉えて操作計画に生かされた [66]．

食器を洗う際にはいくつか注意する点が存在する．まず，対象物の形状や表面性状によって動作軌道を適応する必要がある．対象物のダイナミクスが未知の場合に適応的に操作する研究は，深層学習を用いたものがみられる [67]．視覚だけでなく，力覚を用いて対象物になじんで擦り操作を実現する研究がなされている [44]．

また，操作中に危険とを感じる場面がある．例えば，濯ぎ操作中に水が食器上で跳ねてロボットが濡れる場合や，強い力で擦りすぎて皿を落としそうになる場合がある．把持した物体を落とぬように，ハンドを柔らかくすることで安定的に把持する研究がなされているが [68, 19, 69]，現在の生活支援ロボットは，ソフトハンドを有




Fig. 4.1: Scrubbing and rinsing dishes after human taught implicit constraints.

している場合はあまり多くない。本研究で用いる生活支援ロボットである PR2 も、平行グリッパを備えている。危険な動作を察知する方法は、異常検知 [70] を用いる方法や、動作予測による方法がある。例えば、自動運転では確実な自己を避けるために、各手法が比較検討されている。[71] がある。危険な場面において、操作を切り替えるために、視覚や力覚情報から状態の危険性を予測して、モデルベース型と学習型のコントローラを切り替える研究が行われている。[72, 43] この研究では、危険を察知した後にロボットは初期姿勢に戻る。しかしながら、姿勢を戻してもう一度動作を生成した場合、同様の状態に再び出会って先のフェーズへ進まない可能性がある。例えば、食器の縁部分を擦る場合、接触の有無の前後で力覚を含む状態が大きく変化し、危険でないのに危険と判断してしまい、縁部分を擦り方が甘くなるだろう。また、初期姿勢に戻る過程において、より危険が増大する可能性すらある。したがって、危険を判断した場合でも、危険を避けながら可能な限り動作を連続さ

せることが期待される．危険な場合にとるべき行動が陽に判明する場合は動作計画ができ [73, 74]，例えば，多脚ロボットのクライミングにおいて，ロボット脚と壁から滑り落ちないような制約を満たしながら，動作計画をする研究がある [75]．実環境では，危険な場合にとるべき行動が陽に判明しない場合もあり，データドリブンで動作を出力がなされる研究がなされている．状態が変化した際に適応的に動作を修正する研究は， [76, 77, 78]．

4.1.2 本研究における食器類の洗浄システムの特徴

本研究では，初見の食器類に対して，その形状と性質を自己認識モデルから推定し，操作目標値に近づくような制御を行う．自己認識モデルは，述べたモジュールを元に，時系列の認識データを用いて，現在の状態から未来を推論する．ここで認識データは，視覚情報と力覚情報を用いる．自己認識モデルの形成に当たり，人間が助けが必要と感じた場合にロボットの操作を一部教示する．人間の操作は暗示的な目的意識が含まれており，ロボットはそれを無意識に学習していく．学習後は，自己認識モデルから次の操作量を予測し，目標値との誤差を減ずることで最適な操作を実現する．

4.2 動作教示を伴う視覚認識からの自己認識モデルの推論とその逆伝播による適応的操作量の修正

4.2.1 認識からの自己認識モデルの構成

学習ネットワークは次の式で表される．

$$s_{t+1}, u_{t+1}, p_{t+1} = g(s_t, u_t, p_t) \quad (4.1)$$

s は，ロボットの状態と対象物の状態を表し，ロボットの両腕の関節トルク推定値と対象物の位置姿勢を含める． u はロボットの両腕の関節角度である． $p^{predict}$ は安全度を表し， $0 \leq p \leq 1$ を満たす．1 に近づくほど安全となる． g は提案ネットワークである．ランダムな操作実験から (s, u, p) のデータを取得し，これを用いて g を学習し， g を用いて制御入力 u を最適化する．各データの詳細は 3.2.2 項で述べる．

4.2.2 食器類の水濯ぎと擦り動作のデータセットの収集

初期軌道生成

はじめに，対象物相対のエンドエフェクタの軌道を生成する，まず，ロボットの認識から，対象物のバウンディングボックスを取得する．バウンディングボックスの位置と姿勢とサイズの計10次元は状態 s に含める．エンドエフェクタの初期軌道は，バウンディングボックスのサイズに応じてランダムに生成される．

水濯ぎ動作においては，右手に食器を把持し，左手が蛇口を操作して水の出し止めを行う．ここで，左手の操作は，蛇口相対の固定軌道とする．右手のみランダムな軌道を生成して，学習させる．

擦り動作においては，右手に食器を把持した状態で，左手にスポンジを持って擦る．ここで，右手の操作は静止させる．左手のみランダムな軌道を生成して，学習データとする．ランダムな軌道は，対象物表面上で左右の対辺上の点をランダムに選択し，その点を結ぶことで軌道を生成する．

人の教示による操作修正

次にロボットが，生成された初期軌道に対して逆運動学を連続的に解く．解の関節角度を目標値に操作を実行する．ロボットの実行中に，人はロボットの腕を持って操作軌道を教示によって修正する．使用するロボットは関節が柔らかく，人との柔軟な接触ができるため，このような教示が可能であると第5章で述べる．なお，人が初期軌道は適切であると判断した際は，教示しない．人間が教示している際もロボットは初期軌道に対して操作を実行し続ける．

水濯ぎ動作においては，人は，ロボットの食器を持つ右手に関して，食器表面上で水を飛ばしそうになる際，また隅々まで濯げていない際に割り込み，右手の角度を修正して落水に当たる皿の面を調整する場合や，右手を揺動させて食器全体に水が行きわたるように教示する，

擦り動作においては，ロボットがスポンジを食器に押し付けるように擦っていることができているか，食器を落としそうになるなど危険な動作になっていないか，人が判断する．ロボットが上述の動作を実行できていないと判断した場合は，人が直接スポンジを持つロボットの左腕を動かし教示する．

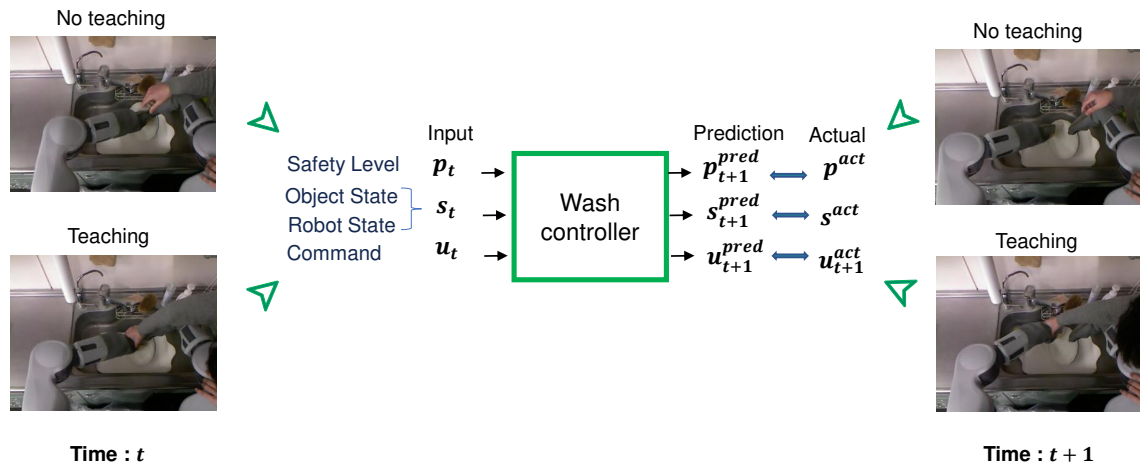


Fig. 4.2: Training phase: Collect the datasets consisted of robot states, object states and robot angle vector. Calculate the loss with predicted data and the actual data.

データの収集

ロボットのランダム実行区間に際して、状態 s は両腕各 7 自由度関節トルク推定値と対象物位置姿勢のデータの 24 次元、制御入力として両腕各 7 自由度関節実角度の実行値計 14 次元を $2Hz$ ごとに取得する。濯ぎと擦り動作それぞれにおいて、人が介入している区間とそうでない区間に分類する。両腕の関節トルク推定値の時系列の変分に対して、閾値を以って自動で分類する。人が介入しているときを危険とみなして $t = 0$ 、介入していないときを安全とみなして $t = 1$ とラベル付けを毎ステップ行う。ただし、自動ラベル付けは誤った判断をなされる場合があるため、人がラベリングし直す。

さらに、人が介入するフェーズにおける、 s の一要素であるロボットの関節トルク推定値は、ロボットの状態としてみなし難い。そこで、そのフェーズにおける関節トルク推定値は 0 とする。

4.2.3 食器類の水濯ぎと擦り動作の訓練

4.2.1 項のネットワークを用いて、動作学習を行う。まず、データを拡張する。軌道関節角度に関して、ガウシアンノイズを加えて少量データを拡張し、データのノ

イズにも頑健に対応する．また，関節トルク推定値は，推定値であるため誤差が大きいため，3フレームの移動平均をとる．

これらのデータセットを用いて，バッチサイズを $C_{batch}^{train} = 4$ ，エポック数を $C_{epoch}^{train} = 100000$ として，のようにモデル g を訓練する．

$$s_{2:T}^{predict}, u_{2:T}^{predict}, p_{2:T}^{predict} \leftarrow g(s_{1:T-1}, u_{1:T-1}, p_{1:T-1}) \quad (4.2)$$

$$L = MSE(s_{2:T}^{actual}, s_{2:T}^{predict}) + MSE(u_{2:T}^{actual}, u_{2:T}^{predict}) + BCE(t_{2:T}^{actual}, p_{2:T}^{predict}) \quad (4.3)$$

ここで， t は0または1の安全判定ラベルで，0が人が介入し1は介入していない． T は操作シーケンス長で，濯ぎと擦り操作の各動作において異なり，30から100フレームほどである．MSEは平均二乗誤差を表し，BCEはBinary Cross Entropy 誤差を表す．損失関数の最適化手法はAdamを用いる．ネットワークを学習する際は，シーケンス長をそろえる必要があるため，データセットの最大フレーム長に全てのデータをパディングする．誤差をとる際は，パディング部分を無視することで，学習には影響を及ぼさないようにする．

4.2.4 ネットワークの逆伝播による水濯ぎと擦り動作軌道の最適化

訓練済みのネットワークを g を用いて軌道の最適化を行う．はじめに，実行初期値として，現在時刻 t における (s, u) と $p = 1$ を与え， (s_1, u_1, p_1) をネットワークに入力する．ネットワークから， $s_2^{predict}, u_2^{predict}, p_2^{predict}$ が出力され，目標値との誤差をとる．

s の要素である，食器類の状態 s_{obj} に関しては，操作によって大きく動かないことを目標とするため， s_{obj}^{ref} を操作初期時刻における食器類の状態とする．

u の軌道については，濯ぎ操作においては目標値は存在しない．擦り操作においては目標値を汚れ箇所に対する逆運動学を解いた関節角度とする．目標値の汚れ箇所は，OpneCVのRGB Canny Edge Detectionにより，色の差異が大きな点を抽出し，対象物体の縁の内側においてその点の分布をクラスタリングをし，一番大きなクラスタにおける点群の重心とする．また，逆運動学の解は2つあるが，現在の姿勢に近い解を選択し，これを u^{ref} とする．

p の安全度に関しては，その値を $0 \leq p^{predict} < 0.3$, $0.3 \leq p^{predict} < 0.6$, $0.6 \leq p^{predict} \leq 1.0$ で場わけをして p^{ref} を定めた． $0 \leq p^{predict} < 0.3$ の場合，ロボットが

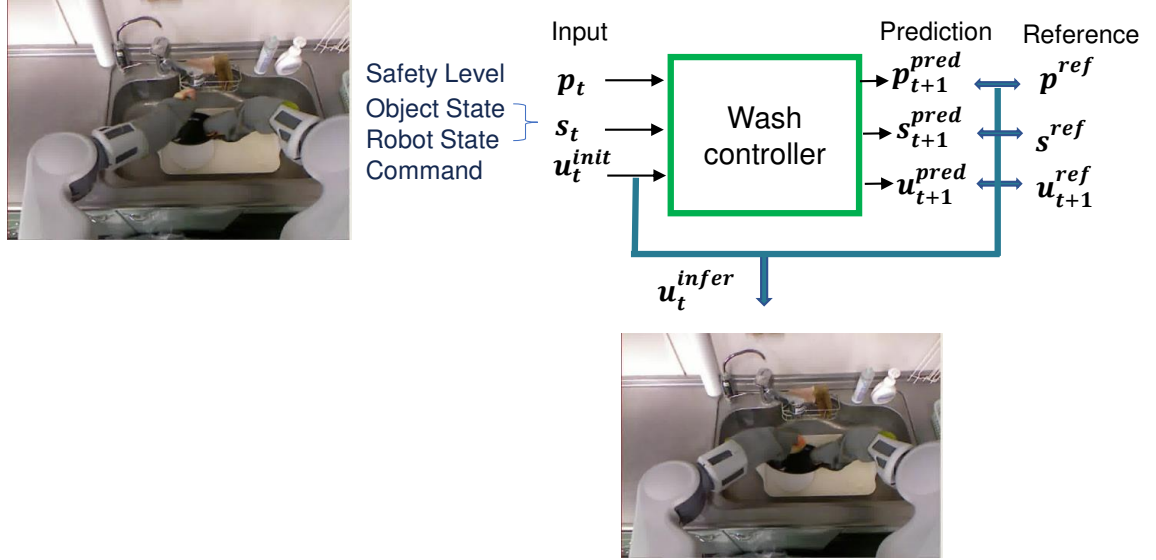


Fig. 4.3: Optimization phase: modifying the angle vectors of the arms with reference using backpropagation of the network.

自力で復帰不可能な状態であるとし、操作を中断して食器類をシンクに置き、初期姿勢からやり直す。 $0.3 \leq p^{predict} < 0.6$ の場合、ロボットが自力で復帰可能である状態として、 $p^{ref} = 1$ とする。 $0.6 \leq p^{predict} \leq 1.0$ の場合、安全な状態であるとして p^{ref} を定めない。

時刻 t から、次式のように時刻 $t + 1$ における状態を推定する。

$$s_{t+1}^{predict}, u_{t+1}^{predict}, p_{t+1}^{predict} = g(s_{2:t}, u_{2:t}, p_{2:t}) \quad (4.4)$$

$$(4.5)$$

なお、ロボットの状態 s_{robot} 、すなわち、ロボットの関節トルク推定値においては、訓練時に人が介入した際は $s_{robot} = 0$ を与えた。そのため、次式のようにフィルタリングをした値を入力値とする。

$$s_{robot,t}^{filtered} \leftarrow s_{robot,t} \times p_t \quad (4.6)$$

入力値 u_t^{init} に関して誤差逆伝播を行うことで、入力値を u_t^{infer} に最適化する。誤

差は次のように算出する．

$$L_{sobj,t} = MSE(s_{obj,2:t+1}^{predict}, s_{obj}^{ref}) \quad (4.7)$$

$$L_{u,t} = MSE(u_{2:t+1}^{predict}, u^{ref}) \quad (4.8)$$

$$L_{p,t} = BCE(p_{2:t+1}^{predict}, p^{ref}) \quad (4.9)$$

MSE は平均二乗誤差で，BCE は Binary Cross Entropy 誤差である．誤差逆伝播による最適化は， $C_{iter} = 10$ 繰り返し，最適化された制御入力は，関節角度の指令値として実行する．誤差逆伝播における，学習係数 γ の値は，全て 0.01 とする

4.2.5 ニューラルネットワークの詳細

ニューラルネットは，Long Short-Term Memory (LSTM) [45] を用いた．LSTM は，再帰性のニューラルネットワーク RNN の一種で，長期的な依存関係を学習するのに適している．ネットワークの入力と出力と隠れ層の次元は 39 次元とする．最適化手法 Adam の学習率は 0.0001, beta1 は 0.9 で beta2 は 0.999 とする．

Algorithm 2 Dynamics Estimation and Action Execution

s : object and robot state

u : robot angle vector

p : safety level

Require:

s_t : object and robot state at time t

u_t : robot angle vector at time t

Ensure:

u_t^{exec} : angle vector to be executed

- 1: Obtain $p_1 = 1$
 - 2: **for** $i = 2, \dots, C_{test}$ **do**
 - 3: Obtain s_t and u_t
 - 4: Store (s_t, u_t, p_t)
 - 5: **for** $i = 1, \dots, C_{iter}$ **do**
 - 6: $s_{t,i}^{robot,filtered} \leftarrow s_{t,i}^{robot} p_{t,i}$
 - 7: $s_{t,i+1}^{predict}, u_{t,i+1}^{predict}, p_{t,i+1}^{predict} \leftarrow g(s_{t,i}^{obj}, s_{t,i}^{robot,filtered}, u_{t,i}, p_{t,i})$
 - 8: $L_{t,i}^{obj} = MSE(s_{2:t,i+1}^{obj,predict}, s_{obj}^{ref})$
 - 9: $L_{u,t,i} = MSE(u_{2:t,i+1}^{predict}, u^{ref})$
 - 10: $L_{p,t,i} = BCE(p_{2:t,i+1}^{predict}, p^{ref})$
 - 11: $g_{s,t,i}^{obj} \leftarrow \frac{\partial L_{obj,t,i}^{obj}}{\partial u_{t,i}}$
 - 12: $g_{u,t,i} \leftarrow \frac{\partial L_{u,t,i}}{\partial u_{t,i}}$
 - 13: $g_{p,t,i} \leftarrow \frac{\partial L_{p,t,i}}{\partial u_{t,i}}$
 - 14: $u_{t,i+1} \leftarrow u_{t,i} - \gamma_s^{obj} g_{s,t,i}^{obj} - \gamma_u g_{u,t,i} - \gamma_p g_{p,t,i}$
 - 15: $s.t. u^{min_{threshold}} \leq u_{t,i+1} \leq u^{max_{threshold}}$
 - 16: **end for**
 - 17: **return** $u_t^{exec} \leftarrow u_{t,C_{iter}}$
 - 18: **end for**
-

第5章

生活支援タスクを行うロボットシステムの構成

5.1 はじめに

本章では、本研究で使用したロボットのハードウェア及びソフトウェアシステムについて説明する。特に、本研究におけるロボットの認識と操作機能の基盤となる構成要素について述べる。

本研究では、生活支援ロボットのPR2 [79]を用いる。PR2は、Willow Garage Inc. が制作した、移動台車付き等身大双腕ロボットである。同社は、後述のROSやOpenCVなどのソフトウェアプラットフォームと共にPR2を開発した。Willow Garage Inc. は2014年に倒産したが、以後はClearpath Robotics Inc. [80]がPR2の管理をしている。本研究で使用するPR2は、JSKの先輩方がハードウェア及びソフトウェアにおいて改造したものである。例えば、古田の博士論文の第二章 [81]にその詳細が書かれている。

5.2 台車移動型双腕ロボットPR2のハードウェア

5.2.1 ハードウェアシステムの全体像

Fig.5.1は、PR2のハードウェア仕様を表す [82]。PR2は、腰部の直動可動リンクで高さ1330mmから1645mmとなる。関節自由度は、移動台車部分以外で20ある。具体的には、胴体に1自由度、頭部に2自由度、双腕部に各7自由度、ハンドに1自由度、距離センサ駆動台座に1自由度である。

5.2.2 視覚

視覚情報を得るために、PR2にはカメラやレーザー距離センサが備え付けられている。カメラは、PR2の頭上に取り付けられているKinectカメラ [83]を用いる。Kinectカメラで操作対象物体やその周囲のRGB画像やdepth画像を取得した後、点群を構成する他、画像処理を行う。本稿では、視覚情報を元に把持や擦り動作を実現する。

レーザー距離センサは、Hokuyo社製のTop-URG(UTM-30LX)であり、PR2の台座部に備え付けられている。PR2は移動時に、このレーザー距離センサを用いて環境を認識し、自己位置推定を行う。




Fig. 5.1: Hardware overview of PR2 robot.




Fig. 5.2: Whole view of PR2 (left), Kinect camera (upper right) and water proof glove (lower right)

5.2.3 腕部

PR2の双腕はグripperを含めて8自由度で耐荷重は各1.8kgである。双腕は、バックドライバリティを有し、負荷トルクに応じて関節角度を変化させる。この機能は、他の双腕ロボットの duAro [84] や YuMi [85]、移動台車付きの Justin [86] にはない。これにより、環境接触時に環境や自身への物理的なダメージを軽減することができる。環境へのダメージが比較的少ないことで、第3章のような把持学習において、環境接触を含む試行錯誤が可能である。また、人との接触も比較的 안전한ため、第4章のようなロボットの動作中に人が介入する場合に適している。

PR2の腕部のモータ周りには、トルクセンサが備えられていない。トルクの推定は、モータの指令電流を測定し、モータのデータシートに記載されているトルク定数の値をトランスミッションのモデルを用いて行う。トランスミッションのモデルは、100%の効率を仮定している。トルク推定と指令値の精度は、ドライブトレインの摩擦によって変化する。

5.2.4 エンドエフェクタ

エンドエフェクタは、面が平行に開閉するグripperである。グripperは、腕部からスリップリングを介して接続されている。スリップリングは、手首が無限回転するための繋ぎ部品である。

本稿では、PR2ロボットのエンドエフェクタに防水グローブを装着して、食器類の把持や洗浄を行う。グローブは、岡田らが開発した丈夫なウェットスーツ素材である [87]。過去には、HRP2-JSK を用いて食器洗い動作を実現させている [14]。この素材を用いて、ロボット専用のスーツを作ることもできる [88]

また、グローブの素材は摩擦係数が小さいため、把持部分に滑り止めゴムテープを張り付ける。こうして、物体を把持したときにグリップ力を向上させる。

5.2.5 体内通信システム

PR2の Kinect 以外のカメラとモーターは、Ethernet ケーブルで接続され、EtherCAT [89] のプロトコルを介して通信している。EtherCAT (Ethernet Control Automation

Technology) は、Beckhoff Automation が開発し、ETG (EtherCAT Technology Group) [90] を中心とするオープンなイーサネットである。EtherCAT が EtherNet と比較して主に異なる点は、後者は TCP/IP プロトコルで、前者は独自の Industrial Ethernet プロトコルが中心である点である。後者は、ハンドシェイク方式であるが、前者はマスターから出たパケットが順番にフォロワーを通過して、再びマスターに戻る。これにより、EtherCAT はオンザフライで高速な処理が可能になる。

PR2 のリアルタイムプロセスは、EtherCAT の通信で担保されている。通信が途切れるとパケットドロップによりリアルタイムループが落ちる。JSK の所有する PR2 のうち pr1040 機は、筆者の在籍した期間にリアルタイムループが落ちる現象が多発した。例えば、PR2 のキャスターや手首におけるスリップリングの老朽化や、Ethernet ケーブルの接続不良により通信が途絶え、リアルタイムループが落ちた。特にスリップリングは、手首においては、マニピュレーション時に負荷がかかりやすく、キャスターにおいては、移動時に全体重を支えながら大きな負荷がかかり摩耗する。その都度、JSK の PR2 ユーザーや先生方の多大なる努力より修理が施されてきた。

5.3 認識と操作のための基盤ソフトウェアプラットフォーム

5.3.1 ROS

オープンソースの ROS (Robot Operation System) は、オープンソースソフトウェアで、ロボットとソフトウェアアプリケーションを繋ぐ [91]。様々なバージョンがあるが、本稿では OS に Ubuntu 18.04 を用いており、それに対応する ROS1 melodic バージョンを使用する。なお、アプリケーション作成のために Python のバージョンは、ROS1 melodic で推奨されている Python2 系を使用する。

5.3.2 OpenCV

OpenCV [92] は、オープンソースのコンピュータビジョン向けのライブラリである。本稿では、Kinect カメラで取得した画像を処理するために用いる。具体的には、3.2 節においては、depth 画像におけるバイナリやグレースケール、RGB 変換や、




Fig. 5.3: The example of OpenCV library. The middle picture shows the binary image of the dish, and the right picture shows the hough circle detection.

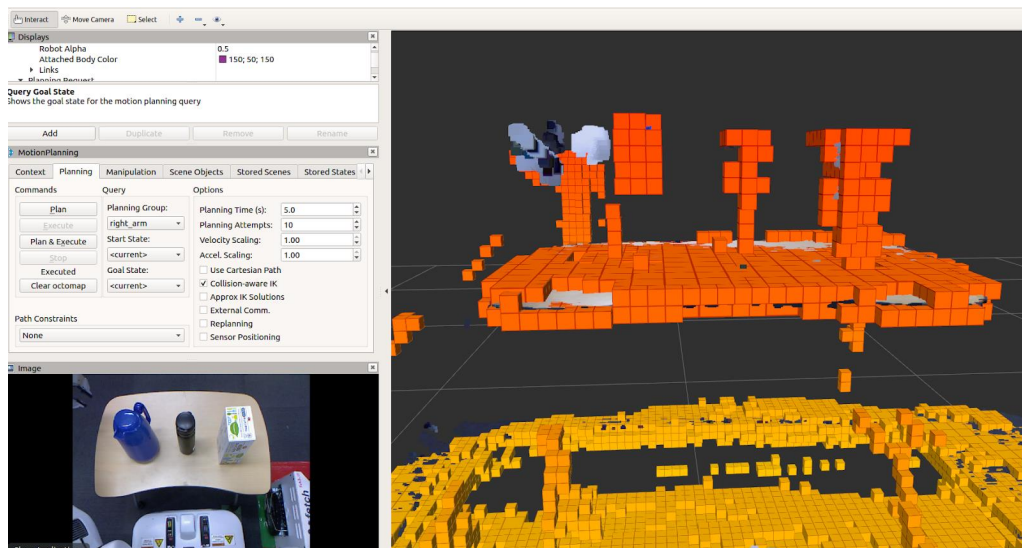


Fig. 5.4: 3D recognition using octomap in MoveIt Grasps, which can be applied to the collision avoidance.

morphology 変換やエッジや円検出などである。Fig.5.3 は、皿回りのバイナリ画像と Hough 変換による円検出である。

5.3.3 MoveIt Grasps

MoveIt Grasps は、MoveIt [93] のライブラリの一つで、物体の把持点や姿勢を生成する。MoveIt Grasps は、可動範囲でフィルタリングしたり動作計画の機能を提供する。摩擦円錐などの把持ダイナミクスは考慮しておらず、各自に開発が委ねられている。

本稿では、6.2 節で行う食器類の把持実験におけるロボットの動作計画の一部で用

いる．エンドエフェクタが把持対象物体に接近する際に，Fig.5.4 のように，MoveIt Grasps の機能で他の物体を認識して避けながら接近する．

第6章

使用済み食器類の片付けにおける統合 実験




Fig. 6.1: Experimental setup. Grasp pose is relative to the {Object} coordinate system.

6.1 はじめに

本章では、使用済み食器類の片付けタスクの実行を行う。はじめに、把持と洗浄部分について切り出して、第3章と第4章に基づいた学習と推論を行う。様々な形状の食器に対して実験を行うことで、システムの汎用性について検証する。また、汚れや水といったオンラインの制約を満たしながら、操作を修正していく適応性について検証する。最後に、把持と洗浄を含む使用済み食器類の片付けタスクを通して行うことで、提案システムの有用性について検証する。

6.2 汚れた食器類の把持実験

6.2.1 実験準備

Fig.6.6のように、座標系を設定した。学習時は、Fig.6.2左側の6種類の食器類を計180回試行した。データセットは、3.2.3項のように100倍に拡張して18000データセットを得た、このデータセットを用いて、Fig.6.3の上図のように把持訓練を行った。注目すべき失敗試行としては、まず、スプーンや平皿は、グリッパの厚みで掴めない場合があった。また、物体を掴みかけて滑り落ちる場合があった。把持最適化の実験時は、Fig.6.2の中央と右側の未訓練の食器類を用いた。



Fig. 6.2: Tableware for training (left). Avoiding obstacles and approaching the rim dish (middle, right). After reaching the object, the robot adjusts its gripper pose.



Fig. 6.3: Grasp test based on visual information only. There were times when grasping failed due to the thickness (left, middle) and slippage (right) of the gripper.

6.2.2 自動アノテーションによる把持訓練

6.2.3 未知食器類の適応的把持

Fig.6.3 下側の写真は、最適化された把持点と姿勢で把持した様子である。平皿やリム皿の場合、グリッパーの角度が横方向に調整された。スープカップやお椀のように縁が上向きの場合は、上方向に調整された。カトラリーについては、上からの把持がよく見られた。カトラリーとは、箸やシルバーの総称である。Table 6.1 は、把持実験の成功率を示す。カトラリーは厚さが薄くロボットのグリッパーから滑りやすいため、一見すると適当な把持位置や姿勢でも失敗するケースが多く、成功率は

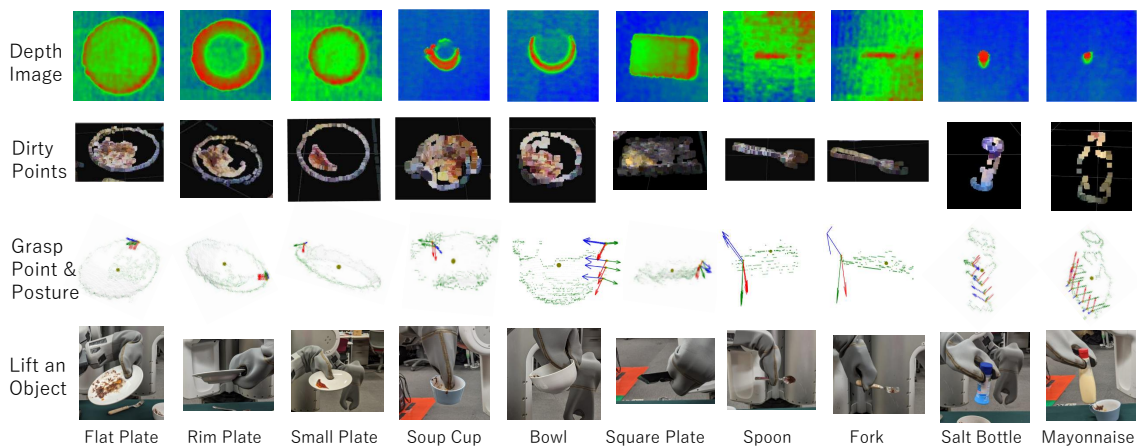


Fig. 6.4: Tested Tableware. First, the robot gets depth image and an edge point cloud of the object, which is as far away from dirty parts as possible. Then the robot modifies the grasp point and posture with VGP-Net. Finally, the robot grasps the object and lifts it up. The second figures from the top show the modification process of the grasp point and posture (arrow) on the overall point cloud (green) The olive point is the object's center point.

50% に満たなかった．縁が上を向いているものは，100% 把持が成功した．平皿やリム皿も高い確率で把持成功したが，横方向から近づいても滑って掴めない場合があり，成功率は95%であった．

Fig.?? は，推論点の最近傍点からの把持姿勢ベクトルの最適化の推移を表す．オレンジ色の点と矢印が C_{iter} 回の最適化途中で，赤色が最終的な最適化結果である．把持姿勢は，初期姿勢を中心に徐々に更新された．把持点に関しては，ほとんど位置が変化しなかった．平皿とリム皿の把持姿勢は横向き，スープ鉢とスプーンの把持姿勢は下向きとなった．この角度は，皿食器においては縁の角度に沿っている．スプーンにおいては，横方向から把持する場合はグリッパの厚みで机に接触するが，上からであれば厚みに関係なくなる．

トレーを両手で把持した．まず，一方のグリッパで片手の際と同じように対象物を把持する．同時に，もう一方のグリッパで，物体の中心に対して対称的な位置を把持する．双腕のグリッパを用いて，任意の縁を把持することができる．しかし，トレーの長辺の中心辺りを把持すると，トレーが不安定な姿勢になる場合がある．

Table 6.1: Grasping trials of unknown objects before and after training.

		Trial number	Average success rate
Flat Plate	No train	20	20 %
	Trained	20	95 %
Rim Plate	No train	20	15 %
	Trained	20	95 %
Soup Cup	No train	20	80 %
	Trained	20	100 %
Soup Bowl	No train	20	80 %
	Trained	20	100 %
Spoon	No train	50	4 %
	Trained	50	44 %
Chop-stick	No train	50	2 %
	Trained	50	46 %
Total	No train	180	33.5 %
	Trained	180	80.0 %




Fig. 6.5: Dual arm grasping. The robot crosses its hands without any input constraint (left). On the other hand, with constraint, it is more likely to grab the handle of the tray (right).

Table 6.2: Dual arm grasp trials of unknown trays before and after training, with and without input restriction.

		Average success rate without input restriction	Average success rate with input restriction
Tray 1	No train	0%	20%
	Trained	20%	80%
Tray 2	No train	0%	20%
	Trained	30%	90%
Total	No train	0%	20%
	Trained	25%	85%

また，Fig.6.5 左のように，ロボットが腕を交差させて掴もうとする場合がある．食器類の多くは把持点を複数有するが，推奨される把持点が存在する場合がある．例

例えば、トレーは縁の各所で把持可能だが、長方形のトレーを両手で安定して把持する場合には、各辺の短辺上で把持することが望ましい。この問題を解決するため、対象物のある領域内の点群をネットワークの入力とした。トレ-の場合、短辺周辺の点群を初期入力とすると、そこから誤差逆伝播で付近の把持点と姿勢に修正される。Table 6.2 は、学習前後の入力制約の有無で比較したトレー把持の成功確率を示す。Tray 1 が Fig.6.2 中央で、Tray 2 が Fig.6.2 右側のトレーである。それぞれの試行は $C_{test} = 10$ 回ずつ行った。入力点群をトレーの短辺周辺に絞ると、ロボットは、Fig.6.5 右のようにトレーの取手部分を掴むようになり、把持の成功確率が向上した。

6.2.4 考察

入力制約の柔軟性

把持のための入力に制約を与えない場合、ランダムなエッジが把持された。汚れた部品を掴まないように、また、他の食器にアームをぶつけないように入力点を制約することで、入力制約による学習をしなくても、把持に成功した。これは、入力点に対する制約を柔軟に変更できる提案ネットワークの強みを生かした結果である。

また、把持点の制約は他の物体にも適用可能である。例えば、私たちが右手でお皿をつかむとき、お皿の右側をつかむこととなります。皿の右側面の点群が入力として与えられると、ロボットは掴みやすい点を選択することができる。もう一つの例は、つかむ場所に意味的な制約がある場合である。例えば、トレイは端にある取っ手を掴めばいい。マグカップは、カップの中に手を入れずに、取っ手を掴めば掴むことができる。食器だけでなく、例えば、花びらではなく茎をつかむこともできます。これらは、把持点・姿勢の推論に制約を加えることで、ケースバイケースで対応することができる。学習データや学習方法を変更する必要はない。これは、画像と点群から確定的な把持計画作成を行う手法では不可能である。

本手法では、皿のように複数の把持点を持つ物体に対して、初期値に依存した解を与えることで、把持姿勢の冗長性に対処している。解は複数存在するが、入力点群に制約を加えることで、解の範囲、つまり把持の冗長性の程度を変えることができる。

試行によるグリッパーの姿勢の調整

実験結果から，コップやボウルなど縁が上向きの食器は，ランダム把持でも高い確率でうまく把持でき，学習後は一度も失敗しなかった．この結果から，提案手法はこれらを把持するためのシステムとして適切であると考えられる．また，カトラリーについては，学習後に上部から把持するように修正したが，成功率は他の物体に比べて低かった．カトラリーの把持訓練では，横から掴もうとしてグリッパーの厚みで机に触れ，目標値から外れることが多々あった．この失敗経験をもとに，ロボットは上からつかむように改良された．つまり，ロボットはハードウェアと環境の関係を考慮することを学習したのである．このようなロボット自身の身体性は，環境との相互作用によってのみ獲得される．これは従来の認識から行動を決定的にする2.3.1節のような研究では実現できない．

6.3 汚れた食器類の水濯ぎと擦り洗い実験

6.3節では，食器洗い操作のうち，第4章の学習モジュールを用いて，水濯ぎと擦り洗いを実現する．実機による視覚と操作教示によるデータの収集してネットワークの訓練を行い，3タイプの食器類に対して適応的な操作を実現する．食器類の操作実験を行う前に，6.3.1項で，食器擦り洗いではないトイプロブレムで第4章のネットワークを用いた実験を行いその有用性を明らかにした後，実際に食器類に対して第4章を適用する．

6.3.1 予備実験

提案学習ネットワークの機能を確認するため，トイプロブレムで予備実験を行った．第??章のネットワークでは，ロボットの腕の関節角度指令値や，ロボットと対象物の状態，状態の安全度をデータセットとして用いた．ロボットを使用しないトイプロブレムで，制御量と状態量と安全度を以って，ネットワークの有用性を評価する．




Fig. 6.6: Toy problem for danger avoidance

実験設定とデータセットの収集及び訓練

本項におけるトイプロブレムは、エージェントが障害物をよけてゴールまで移動するゲームである。エージェントは、行動指針 π に基づいて動く。 π の初期値に従うと、エージェントは、スタートからゴールまで直線的にゴールに移動する。道中では、障害物がランダムに動きつつもエージェントに近づき、エージェントに触れるとゲーム失敗となる。そこで、人は障害物に触れる前に、エージェントを動かすことができる。エージェントがゴールにたどり着いたらゲーム成功となる。

このゲームでは、エージェントと障害物のグローバル座標を状態 s とし、行動指針 p_i を制御入力 u とする。また、人がエージェント操作で介入したフェーズは $p = 0$ を与える。 128×128 サイズの迷路環境を用意し、点 $(0, 0)$ をスタート地点とし、点 $(128, 128)$ をゴール地点とする。各ステップごとに、 (s, u, p) を集め、ゲームが成功した場合のみをトイプロブレムの学習データとした。この成功したゲームを 150 セット集める。

訓練時は、Eq 4.3 に沿って学習する。

エージェントの行動における最適化結果

まず、誤差逆伝播をせずに、 (s_t, u_t, p_t) から推論した u_{t+1} をそのまま用いてエージェントを移動させる。結果は、Fig.6.7 のようにエージェントは、障害物を避けようと迂回する動きがみられるが、小回りであった。また、迂回が足りずに障害物と衝突する場合があった。

s に関して誤差逆伝播をした場合は、 π はゴールまでの動きが加速したが、よりぶつかりやすくなる。

p に関して誤差逆伝播をした場合は、Fig.6.8 のように障害物を大きく迂回する動きがみられる。

s と p のいずれに関しても誤差逆伝播を行うと、より素早く迂回する動きがみられる。

以上の結果から、 $p > \delta_p$ を満たす場合は、安全状態のため s の誤差逆伝播を行いと考えられる。また、 $p \leq \delta_p$ を満たす場合は、危険状態とみなして p に関する誤差逆伝播を行うとよいと考えられる。 δ_p はタスクに応じて決定することとする。




Fig. 6.7: Path planning without backpropagation. The agent made a small circle around the obstacle.




Fig. 6.8: Path planning with danger recognition The agent made a big circle around the obstacle.



Fig. 6.9: The left picture is the dishes for washing training. The dishes are including various size and shape of plate, fork and spoon. The right picture is the robot training of manipulation taught by human.

6.3.2 食器類の洗浄における準備

6.3.1 項で，第4章のネットワークの有用性を明らかにした．本項では，生活支援ロボット実機を用いてシステムを評価する．

実験準備

訓練時に使用する食器類は，Fig.6.9の左の9種類とする．様々な形の食器やスプーンやフォークを対象とすることで，多様な食器類に対してネットワークが汎化することを期待する．

6.3.3 食器類の擦りと濯ぎにおける操作教示

まず，ロボットの手先における，対象物相対の初期動作軌道を作成する．動作軌道は次のような流れに沿う．1. 右手に食器を，左手にスポンジを把持した状態からスタートする．2. 左手で水道のハンドルを押し上げて水を出す．3. 右手で食器を揺動させながら濯ぐ．4. 左手で水道のハンドルを押し下げて水を止める．5. 左手で食器の位置とサイズに合わせてジグザグ方向に擦る．6. 手順2から手順4を再度行う．このように，食器類を把持した状態から，スポンジで擦って濯ぐまでの時系列データを収集する．ロボットが動作を実行している間は，Fig.6.9右のように，人がロボットの隣に立つ．ロボットの動作が人の意図していない場合は，都度人がロボットの手先を持って動かすことで，ロボットの動作を修正する．

ここで、学習対象の動作は、濯ぎにおいては食器を持つ手の動作で、擦りにおいてはスポンジで擦る手である。濯ぎにおける蛇口の操作は学習するより蛇口相対でのモデルベースの動作計画を実行した方が成功すると、事前の実験から判明したためである。また、擦り時におけるスポンジを持たず、食器を把持する手は、固定した方が擦り操作が安定すると判明したからである。

試行実行中は、対象物の情報とロボット自身の情報を 2Hz 間隔でサンプリングをする。データの中には、処理時間が間に合わず 2Hz で同期できないものあり、その場合は前フレームのデータを使用した。一連の試行は9つの各食器類において $C_{train} = 10$ 回行い、合計90回行った。

次に、収集したデータセットの分析を行う。具体的には、あるデータフレームにおいて、人間が介入したか否かを判定してラベル付けをする。これは、人間が介入した際は、ロボットの関節角度の目標値と実際のエンコーダ値との差分から判断する。関節角度誤差の二乗平均平方根 (RMS) が閾値 $\delta_{threshold}$ を超えた際は、人が介入したとしてラベル $t = 1$ を付与し、そうでない場合は $t = 0$ を付与する。関節トルク推定値は誤差変動が激しいため、開始から3フレーム目以降は、過去3フレームずつで移動平均をとる。

得られたデータは、擦り区間と濯ぎ区間に仕分ける。それぞれの区間のデータの集合を4.2.3項のネットワークに入れて学習する。すなわち、擦り操作におけるネットワークと、濯ぎ操作におけるネットワークをそれぞれ学習する。

6.3.4 食器類の擦りと濯ぎにおける適応的操作

推論時は、食器を把持して持ち上げた直後の対象物とロボットのデータを初期とし、6.3.3で訓練したネットワークに入力する。4.2.4項のように、ネットワークの出力と目標値との誤差を逆伝播をし、修正された関節角度を実行する。軌道における目標値は、Fig.6.10の右図のようにRGB Canny Edge法を用いて汚れ点を検出し、汚れた点群のクラスタの中心とした。

濯ぎ操作の結果は、Fig.6.11において、右手のみ学習したことに留意すると、食器を揺動する動作がみられた。このとき、食器を静かに動かして滑らかに水を滴らせた。擦り操作の結果は、Fig.6.12において、左手のみ学習したことに留意すると、



Fig. 6.10: The picture on the left shows the point with dirt on it, which is the target value for the trajectory. The picture on the right shows the dirt detection by image processing.



Fig. 6.11: The optimization result of rinsing dish. The robot is rinsing while swaying its arms.



Fig. 6.12: The optimization result of scrubbing dish. The robot scrubbed with moderate force while reaching the dirty point.

食器上の汚れの位置に関して左手を振動させる動作がみられた。

操作時における、安全度 p を時系列に可視化した結果が Fig.6.13 である。濯ぎと擦り動作において、およそ 0.3 から 0.6 の間で推移した。この区間においては、安全度 p が 1 に近づくように入力関節角度に関して逆伝播されるため、新しい動作区



Fig. 6.13: The experimental result of the safety level of the manipulation. The rinsing and scrubbing phases increase the level of safety from its beginning.

間に入ると一度安全度が低下するものの、各操作区間内においてより安全に更新された。

操作時における、関節角度の負荷推定値を可視化した結果が Fig.6.14 である。濯ぎ操作区間においては、各関節において大きな変動はみられなかった。擦り操作区間においては、左手は、擦り始めに forearm roll が、擦り終わりに elbow flex に負荷が生じた。右手は、擦り動作中に連続し安定した負荷が forearm roll 関節に生じた。

各関節部位の対応は、Fig.6.15 の通りであり、負荷が生じたのは前腕であるとわかる。

6.3.5 考察

濯ぎと擦り操作における実行結果より、安全度を考慮しながら、濯ぎ操作や程よい力加減の擦り操作が実現できたと考えられる。特に、擦り操作における力覚は陽に与えておらず、訓練時に教示によって獲得したと考えられる。すなわち、ロボットは視覚情報と操作教示の訓練は有効で、第4章で提案したシステムの有用性が明らかとなった。

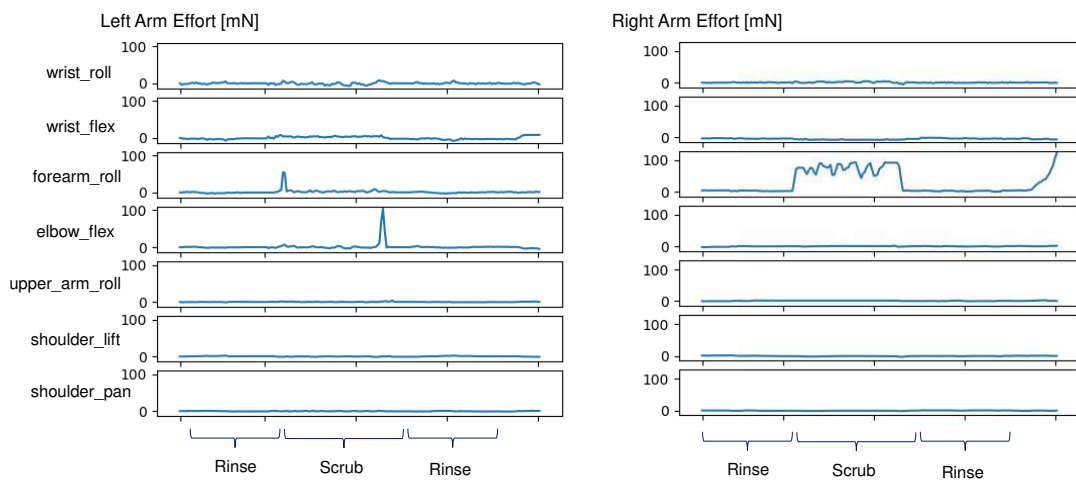


Fig. 6.14: The experimental result of the joint angle effort. In the rinsing phase, there is no significant change in the effort, but in the scrubbing phase, there is a load on the right upper arm.




Fig. 6.15: PR2 joint angle

課題点は、視覚認識の誤差により食器類を誤認識すると安全度考慮でも対応できないほどの操作が実行される場合があった。操作量に関してより厳しい制約を設け

る必要性があると考えられる。

6.4 生活支援ロボットにおける食器類の後片づけにおける統合実験

6.2 節と 6.3 節では、食器類の把持と洗浄において、視覚情報や操作教示に基づいて、適応的な操作を実現できた。本節では統合実験として、使用済み食器類の把持しトレーに置き、トレーを両手で把持してシンクまで運搬して置き、スポンジで擦り、水で濯ぎ、水切り籠に置くタスクを行う。

6.4.1 使用済み食器類の把持

使用済み食器類の把持においては、汚れ箇所を避けた点に関して、他の食器類に腕が当たらぬように把持をした。図のように、汚れ箇所が手前にある場合は奥側から把持し、逆も然りであった。フォークの把持においては、真上から把持した。また、マヨネーズは回収しないため、手前にあるマヨネーズに当たらぬような姿勢で把持を実行した。

把持後は移動してトレーに置いた。最後に、食器類を載せたトレーを両手で把持した。この両手把持も食器類の片手把持と同様の手法を用いて、入力点群範囲すなわち把持点領域を制約することにより、取手を把持した。

6.4.2 使用済み食器類の運搬

使用済み食器類を載せたトレーを持ち上げて、シンク台の中に置く。食器類を載せたトレーの持ち上げ後は安定せず、落下した場合があった。そのため、デモとしての運搬は取りやめた。今後は、グリップとグローブの形状や表面を工夫するか、トレーの取手部分の改良により、安定してトレーを把持して運搬できるようになることを期待する。

6.4.3 使用済み食器類の洗浄と設置

使用済み食器類の洗浄においては、まずフォークは、濯ぎは成功したが擦りは押し当てに失敗した。このとき、安全度は0.3から0.6の範囲であった。楕円型の皿と平皿は、濯ぎと擦り共に安定した操作であったが、汚れ残しが存在した。

洗浄済みの食器類は、シンク横の水切り籠に置いた。置き方は、シンクから遠い順番、すなわち右側から順である。水切り籠を認識した位置に対して、濯ぎ後の食器を置いた。水切り籠の中に、それぞれの食器を収めることに成功した。

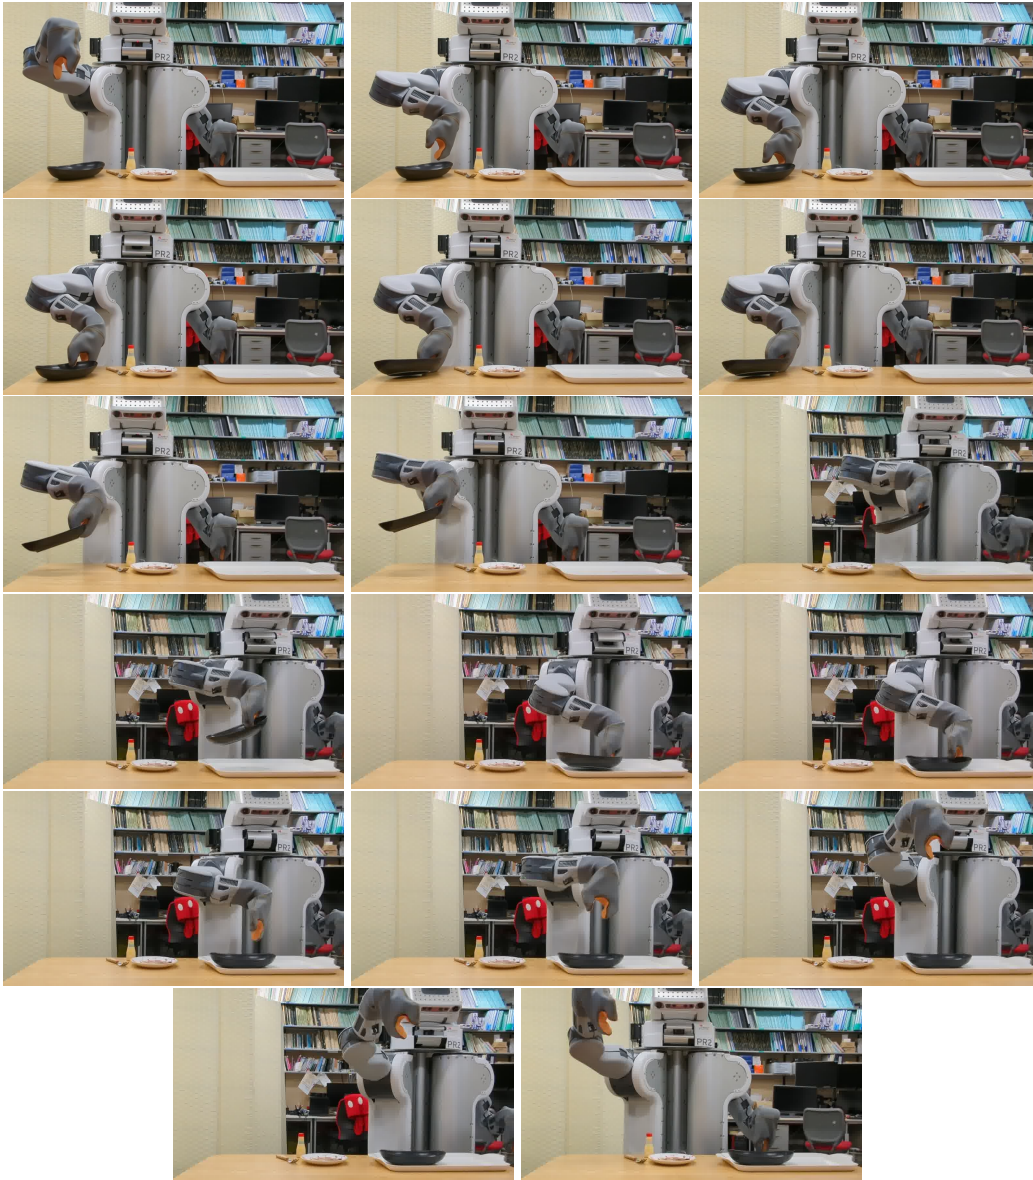


Fig. 6.16: Grasp and put a semi-bowl-shaped dish. The robot avoided the dirt on the right side of it.

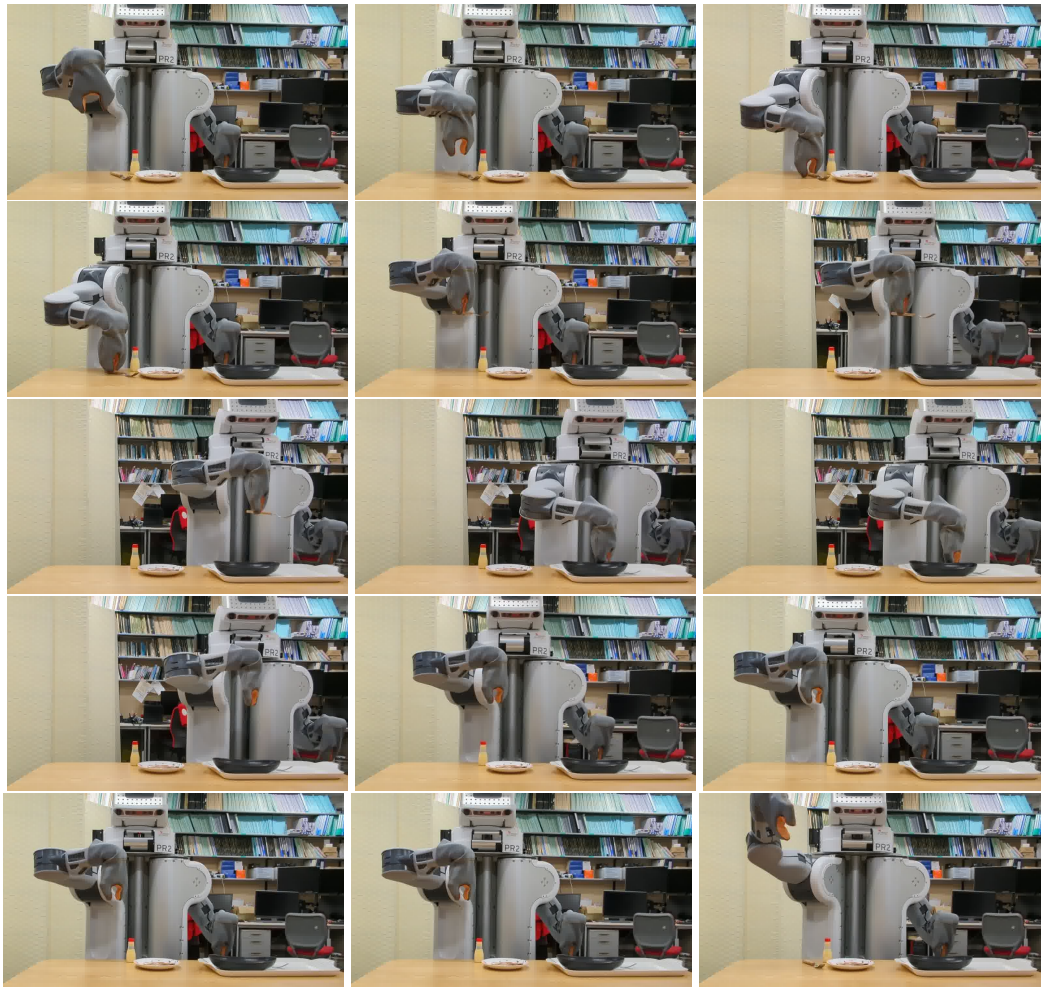


Fig. 6.17: Grasp and put a fork from above.



Fig. 6.18: Grasp and put a plate, avoiding the dirt on the front side.



Fig. 6.19: Grasp a tray with dual hand.



Fig. 6.20: The PR2 drops the tray. Since the tray is instability and the PR2 slips it.




Fig. 6.21: Wash and put a fork



Fig. 6.22: Wash and put a bowl-shaped dish



Fig. 6.23: Wash and put a plate.

第7章

結論

7.1 本研究の総括

本研究では、生活支援ロボットにおいて教示を含めた認識に基づき適応的な操作を実現した。生活支援ロボットが使用済み食器類の片付けを行うタスクにおいて、提案手法を把持と洗浄において適用し、その有用性を実施した。教示を含んだ認識情報の学習に基づいて、形状や性質が未知である食器類に対して適応的な操作を実現した。把持においては、周囲環境により姿勢に制限のある中で、汚れを避けた把持を実現した。洗浄においては、程よい力で食器をスポンジで擦り、水を飛び散らさぬよう濯ぎ、意図せぬ状況下での操作修正を実現した。

7.2 本研究の成果

使用済み食器類の片付けタスクにおいて、食器類の把持から運搬、水濯ぎと擦り洗い、水切り籠に置く動作を実現した。そのタスクの中で、把持と水濯ぎと擦り洗いの局面では、モデルベース型の動作生成ではなく、適応的な学習型動作生成の優位性を示した。これは、深層学習を用いることで、未知の形状や表面性状の食器類を扱うことを可能にし、誤差逆伝播型の操作生成によって、食器類の汚れや操作危険度に応じた動作生成が可能となったからである。

使用済み食器類の把持においては、視覚情報と把持経験に基づいて、適応的に把持点と姿勢を修正するシステムを提案した。食器類は複数の把持点を有するため、把持点とグリッパの姿勢について冗長である。冗長性を生かして、把持点領域に制約がある場合に、適応的に把持点と姿勢を選択することを明らかにした。具体的には、深度画像と物体端部の点群の入力から、把持成功確率を出力するネットワークを考案した。ネットワークの学習後、誤差逆伝播により、入力把持点と姿勢が修正された。把持点と姿勢は初期値に依存しており、入力制約条件を柔軟に反映可能であった。したがって、制約が陽に与えられない場合には、初期値付近で掴みやすい把持点と姿勢が選択された。また、入力点群に制約を加えることで、把持範囲を狭めて物体の所望の部位を把持した。その結果、汚れた食器類の把持において、汚れを避けた点において、腕が障害物と接触しない最適な把持点と姿勢を選択することを実証した。

使用済み食器類の洗浄においては、視覚情報と力覚情報に基づいて、適応的に擦り動作と水濯ぎ動作を行うシステムを提案した。擦り動作においては、食器類の形状に応じて、動作軌道や擦り力加減が変化する。濯ぎ動作においては、蛇口から出る水の食器上で跳ねを抑え、食器全体に水がかかるような角度や動作を生成する必要がある。これらは目標値が明確ではないため、教示によって制御器を訓練した。実行時においては、擦り動作では、汚れ箇所に応じて軌道目標点を与え、食器が擦り動作中も静止することを目標として、動作を修正した。また、擦り動作と水濯ぎ動作において、教示時に人間が介入した状況を記憶し、実行時にその状況に近づくとつれて注意して動作を修正した。復帰不可能な危険状態と判断した場合は、操作を中止して食器をシンクに置いた。その結果、汚れた食器類に対して、程よい力で擦り、水を飛ばさぬように濯ぎ、より効果的で安全な操作を実証した。

7.3 本研究の結論

本研究では、生活支援ロボットが、オンラインで与えられる制約下において、未知の形状や性質の対象物における操作を行うことを目標として、ロボットにおける視覚や操作教示による認識に基づいて、制約を可能な限り満たしながら最適な操作を実行するシステムを提案し、操作における推論の最適化に適用して、その有効性を評価した。また、食器類の片付けタスクの中で、食器類の把持や洗浄動作において、教示認識に基づく適応的操作システムを構築し、生活支援ロボットを用いた、多様な状況下で多様な食器類に関して操作を実現した。以上のことから、本研究により、視覚認識と操作教示による学習型操作生成器におけるオンラインの操作修正法を提案し、実環境における自律的・適応的な多様な操作を行うシステムの構成法が明らかにされたと結論づけられる。

7.4 本研究の課題と展望

シンボリックなプランナーと動作シーケンスプランナーをもつ階層的な操作生成

本研究では、食器を片付けるタスクにおいて、部分的に学習型の操作生成モジュールを用いた。全ての動作シーケンスについて、一つのネットワークで学習するの

は、本研究では成し遂げられていない。そこで、状態量から直接制御量を出力するのではなく、一度タスクの記号的・意味的な理解をした後に、制御量を出力する研究が提案されている。下位プランナーは先に紹介したニューラルネットワークの制御器を用いることができる。上位プランナーは、入力に画像やセンサ情報を入れ、出力に記号や単語に回帰する。

例えば、一連のデモンストレーションビデオから、下位プランナー間の依存関係と遷移を学習する深層ニューラルネットワークを用いる研究がなされている [94, 95]。各下位プランナーをアクションシンボルとして表現し、これらのシンボルが画像から直接学習され予測される。シンボルを学習することで、下位プランナー間の最も頻繁な遷移や関連する依存関係に関する追加情報を得ることができ、長い時間軸でタスクを構成することが可能になる。上位プランナーで動画 (画像) から Predicted Future Symbol が出力され、下位プランナーでそのシンボルに基づいたロボットの angle vector の調整をしている。この結果、ブロック積みや、戸棚を開閉して物体を片付けるタスクが成功した。評価関数の設計を変えれば、様々な形状の棒を使ってボールを目標位置に動かすタスクも実現できる [96]。いずれの研究も、前章までの単一のネットワークでは実現できなかった、動作の順序を含めた長期的なタスクを成功させている。シンプルなネットワークの構造や評価関数でありながら、複雑な動作を生成できていることは、大変興味深い。ビデオからだけでなく、ロボットの関節角度情報を含むマルチモーダルな階層的な学習にも応用できる [97]。

操作生成モジュールにおけるモデルベース型と学習型について

ニューラルネットを用いた制御器の研究は、従来のロボティクスの知識がなくとも、ネットワークの構成と入出力のデータの準備のみで、立式が可能となっている。そこで、制御理論的な安定性の解析が不十分である場合があり、何となく動作が生成できてしまったという場合も考えられる。また、結びびや布畳み、片付けなどの複雑なタスクを実現しているように見えるが、確実に成功できるような動作が実現しているわけではない。従来から行われている、運動力学を考慮したモデルベースの制御器の設計の方が正確に動作を行える場合もある。

今後は、モデルベースの制御器と、本稿で紹介した適応的なモデルフリーのネットワークを組み合わせに期待したい。例えば、まず、運動学的な拘束条件の中で、線

形な状態方程式を立てる．非線形項に関しては，様々な近似方法が提案されているが，紹介してきたニューラルネットワークの項を加算することができるだろう．特に，画像やセンサ入力は本質的に状態方程式を立式できないので，ニューラルネットワークを用いることになるであろう．モデルベースな制御器と，適応的なニューラルネットワークによる制御器を組み合わせることで，より複雑なタスクの実現できると考えられる．例えば，接触状態遷移を伴うタスクである．ニューラルネットワークを用いた適応的な制御器を用いると，何となく物体に接触をしながら操作をすることができるだろう．一方，モデルベースの制御器を用いると，正確に物体を操作できるが，力の加え加減やエンドエフェクタの位置の制御に留まる．ニューラルネットワークを用いて，画像やセンサ情報をマルチモーダルに読み込み，モデルベースの制御器により安定的に目標状態への追従できないのであろうかと考えている．

謝辭

本稿は、筆者が東京大学大学院情報理工学系研究科知能機械情報学専攻修士課程在学中に、情報システム工学研究室（JSK）において、岡田慧教授及び稲葉雅幸のご指導のもとで執筆した修士論文です。

稲葉先生は、研究会でJSKやロボティクス分野の歴史を振り返って、自分の研究に寄与する事例や最近の話題を提供して頂き視野が広がりました。研究哲学を掘り下げ、自分の研究を何度も省みる機会を頂き、より良い研究に改良できました。時には厳しく、時には研究会で「三種の神器ならぬ三種の食器って知ってる？平皿お椀コップ」と冗談を仰り、時には優しく気遣って頂き、正にJSKにおける父のような存在でした。

岡田先生は、私が学部時にJSKを志望するか検討している段階から、快く研究相談をして下さり、大変お世話になりました。気さくで親しみやすい一方、私と研究思想の齟齬が生じて、「君とはパレスチナ協定を結んでいるから」と、距離を置いた時期も懐かしく思います。修士で研究を進めるうちに、岡田先生の重要視するタスクベースの研究の重要性に気づいてきました。研究戦略やコーディングのレビューまで、あらゆる場面ですぐにサポートして頂ける岡田先生は、正にJSKにおける母のような存在でした。

北川さんには、私がJSKに初めて踏み入れてすぐに研究室案内をして頂き、じっくりと研究相談頂き、凄まじい速さでデバッグして頂くなど、感謝しきれないほどお世話になり、正にJSKにおける菩薩のような存在でした。同時に、私がロボットを壊して放置したり、タスクの対応が遅かったりと、大変ご迷惑をお掛けしたことを反省しております。北川さんは、研究のみならず実社会の問題に対する洞察力が深く、いつも尊敬の念を抱いております。今後も、githubなどを通して北川さんの動向を拝見致します。

河原塚さんは、隣の居室にいらっしゃりましたが、研究相談から雑多な話まで気軽に話してきて、研究室に来るモチベーションになっていました。特に私の研究内容については、河原塚さんから頂いたアドバイスのお陰様で、ここまで続けることができました。河原塚さんの豊富なアイデアにはいつも驚かされ、正にJSKにおけるエジソンでした。これからも論文を拝見させて頂きたいと思います。

矢ノ倉さんには、私が研究室に入ってすぐに研究相談に乗って頂き、ソフトウェア開発においても大変お世話になりました。素早い質問の返信と的確なアドバイス

は、非常に有難かったです。また、JSKの中でも公正な視点をお持ちの人格者で尊敬しておりました。正に、JSKにおけるスティーブジョブズのような存在でした。

長谷川さんには、根深いデバッグに根気強く付き合ってもらい、研究相談では隔々まで検討して下さいました。把持理論や摩擦粘性という理論的にも実験的にも挑戦的な課題にひたむきに立ち向かう姿は、まさにJSKにおけるガンジーのようで尊敬していました。

石田さんには、何度も研究相談やデバッグを手伝ってもらい、大変お世話になりました。石田さんは、鋭い指摘をなさることが多く、都度自分の研究を省みるよい機会になりました。石田さんは昼夜問わず熱心に研究し、研究以外の様々な活動に取り組んでおり、私はいつも刺激を受けました。

山口さんには、いつも正論で的確を射た明晰なアドバイスを頂きました。後輩指導に手厚く、包み隠すことなくフランクに話せ、とても信頼していました。人当たりの良い一方、1人の際は集中して次々にタスクをこなす両面をお持ちで、清々しく合理的だと思いました。

新城さんは、私が研究室に入ってすぐに初めてハングアウトでデバッグをして頂いたのをはじめ、ソフトウェアとハードウェア両方の豊富な知識量と技術力を以って、手助けして頂きました。物事の定義を重視する姿勢は、徹底したエンジニアリング力に結び付いているのだと思いました。

平岡さんは、論文やソースコードを隔々まで読み込み、奥深い研究思想と高度な実装力を備えて、一つずつ完全に理解しようとする姿勢に尊敬していました。平岡さんの修論は、読み応えがあり深く考えさせるものであり、博士過程の研究がどのように発展していくのか、期待しております。

同期の河村君には、学部3年生の時に新山先生の研究インターンで出会ってから、入試情報やJSKの情報を共有してもらってお世話になりました。今私がJSKにいるのは、河村君の人望の高さに惹かれたからです。しかしながら、実際研究室で会う機会が少なかったため、今後また社会で出会えることを期待したいです。

73B1の利光君は、実は学部時代からソフトクリームロボとTwitterをフォローをしていたので、会えて嬉しかったのと共に、手が良く動いて研究の成果を上げていく姿にいつも尊敬していました。博士課程頑張ってください。

楠山や上竹や深澤や國田や中尾は、同期で話す機会が少なかったですが、社会で

は似た業界にいると思われるので、また情報共有できたらと思います。

73B2 の金沢君種本さん大日方君は、研究室に入るタイミングとしては実質同期で、私は初め、3 人の euslisp のコードを勝手に覗き見て実装を学んだり、具体的な研究の進め方を参考にしたりしていました。3 人仲良く来年も研究室を盛り上げてほしいです。

73B2 の市倉さん塚本君海士部君に対しては、私はサポート側のはずでしたが、私の知識技術力不足により、寧ろ私が勉強させてもらいました。ありがとうございました。

他の部屋の先生方や皆様方にも、お話しさせて頂いた他、技術的に世話頂き、ありがとうございました。

また、こうして恙なく大学院生活を送れるよういつもサポートして下さる、学校の運営に関わる皆様、地域の皆様のご支援に感謝致します。そして何よりも、遠くからいつもサポートして頂いている家族には本当に感謝しております。

最後に、研究でお世話になった全てのロボット、とりわけ PR2 ロボットは、修士におけるパートナーとして共に歩んできた思い出が蘇ってきます。PR2 には、時に重い処理や誤った指令値を送るなど、私の不注意で迷惑をかけたことを反省すると共に、PR2 の修理を通して智能機械を学ぶ貴重な経験をさせて頂いたことに感謝致します。

沢山の方々の支えによって、この論文が完成しましたことを深く感謝致します。

2021 年 1 月 27 日 若林 隼平

参考文献

-
- [1] Fanuc. <https://www.fanuc.co.jp>.
- [2] ABB. <https://www.abb.com>.
- [3] Kuka. <https://www.kuka.com>.
- [4] Masahiro Fujita. Aibo: Toward the era of digital creatures. *The International Journal of Robotics Research*, Vol. 20, No. 10, pp. 781–794, 2001.
- [5] Lovot. <https://lovot.life/>.
- [6] 総務省. 令和3年版情報通信白書, 2021. <https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r03/pdf/index.html>.
- [7] irobot japan press release, 2021. https://www.irobot-jp.com/press/pdf/20210217_3.pdf.
- [8] 梶田秀司, 森澤光晴, 中岡慎一郎, 阪口健, 金子健二, 金広文男ほか. Darpa ロボティクスチャレンジ決勝戦でのロボットシステム開発と教訓. *日本ロボット学会誌*, Vol. 34, No. 6, pp. 360–365, 2016.
- [9] Nikolaus Correll, Kostas E Bekris, Dmitry Berenson, Oliver Brock, Albert Causo, Kris Hauser, Kei Okada, Alberto Rodriguez, Joseph M Romano, and Peter R Wurman. First Amazon Picking Challenge. *IEEE Transactions on Automation Science and Engineering*, Vol. 15, No. 1, pp. 172–188, 2018.
- [10] C. Hernandez, M. Bharatheesha, W. Ko, H. Gaiser, J. Tan, K. van Deurzen, M. de Vries, B. Van Mil, J. van Egmond, R. Burger, M. Morariu, J. Ju, X. Germann, R. Ensing, J. van Frankenhuyzen, and M. Wisse. Team Delft’s Robot Winner of the Amazon Picking Challenge 2016. *CoRR*, Vol. abs/1610.05514, , 2016.
- [11] World robot summit. <https://wrs.nedo.go.jp>.
- [12] Toyota Motor Corporation. *HSR manual*. 2018.
- [13] 五十棲隆勝, 赤地一彦, 平田勝, 金子健二, 梶田秀司, 比留川博久. ヒューマノイドロボット hrp-2 の開発. *日本ロボット学会誌*, Vol. 22, No. 8, pp. 1004–1012, 2004.

- [14] Kei Okada, Mitsuharu Kojima, Yuichi Sagawa, Toshiyuki Ichino, Kenji Sato, and Masayuki Inaba. Vision based behavior verification system of humanoid robot for daily environment tasks. *Proceedings of the 2006 6th IEEE-RAS International Conference on Humanoid Robots, HUMANOIDS*, Vol. 00, pp. 7–12, 2006.
- [15] 藤本純也, 佐藤顕治, 本郷一生, 伊東信之, 岡田慧, 水内郁夫, 稲葉雅幸. 多種食器の操作を実現するグリッパ拡張型多感覚ハンドの開発. 日本機械学会ロボティクス・メカトロニクス講演会'10 講演論文集, pp. 2A1–E17, 2010.
- [16] 藤本純也, 佐藤顕治, 水内郁夫, 岡田慧, 稲葉雅幸. 皿の片付け作業を実現するためのハンド上でのグラスプレスマニピュレーション. 日本機械学会ロボティクス・メカトロニクス講演会'10 講演論文集, pp. 2A1–E18, 2010.
- [17] 藤本純也, 伊藤司, 水内郁夫, 岡田慧, 稲葉雅幸. 食器の重なりに対応したアプローチ計画と局所手探り探索に基づく食器のピックアップ. 日本機械学会ロボティクス・メカトロニクス講演会'10 講演論文集, pp. 2P1–C22, 2010.
- [18] コネクティッドロボティクス株式会社. <https://connected-robotics.com/>.
- [19] Introducing TRI Manipulation for Human-Assist Robots - Youtube. <https://www.youtube.com/watch?v=LgaFkWCtSGU>.
- [20] スマイルロボティクス株式会社. <https://www.smilerobotics.com/>.
- [21] Akihiko Yamaguchi and Christopher G Atkeson. Advanced Robotics Recent progress in tactile sensing and sensors for robotic manipulation: can we turn tactile sensing into vision? Recent progress in tactile sensing and sensors for robotic manipulation: can we turn tactile sensing into vision? 1. *ADVANCED ROBOTICS*, Vol. 33, No. 14, pp. 661–673, 2019.
- [22] Tetsuya Narita, Satoko Nagakari, William Conus, Toshimitsu Tsuboi, and Kenichiro Nagasaka. Theoretical Derivation and Realization of Adaptive Grasping Based on Rotational Incipient Slip Detection. *Proceedings - IEEE International Conference on Robotics and Automation*, pp. 531–537, 2020.

- [23] Satoshi Funabashi, Shun Ogasa, Tomoki Isobe, Tetsuya Ogata, Alexander Schmitz, Tito Pradhono Tomo, and Shigeki Sugano. *Variable In-Hand Manipulations for Tactile-Driven Robot Hand via CNN-LSTM*.
- [24] Francois R. Hogan, Jose Ballester, Siyuan Dong, and Alberto Rodriguez. Tactile Dexterity: Manipulation Primitives with Tactile Feedback. In *Proceedings - IEEE International Conference on Robotics and Automation*, pp. 8863–8869. Institute of Electrical and Electronics Engineers Inc., may 2020.
- [25] Yasuo KUNIYOSHI, Hirochika INOUE, and Masayuki INABA. Teaching by Showing: Generating Robot Command Sequences Based on Real Time Visual Recognition of Human Pick and Place Actions. *Journal of the Robotics Society of Japan*, Vol. 9, No. 3, pp. 295–303, 1991.
- [26] Yasuo Kuniyoshi and Hirochika Inoue. Qualitative recognition of ongoing human action sequences. *International Joint Conference on Artificial Intelligence*, pp. 1600–1609, 1993.
- [27] Yasuo Kuniyoshi, Masayuki Inaba, and Hirochika Inoue. Learning by Watching: Extracting Reusable Task Knowledge from Visual Observation of Human Performance. *IEEE Transactions on Robotics and Automation*, Vol. 10, No. 6, pp. 799–822, 1994.
- [28] R. Caccavale, M. Saveriano, G. A. Fontanelli, F. Ficuciello, D. Lee, and A. Finzi. Imitation learning and attentional supervision of dual-arm structured tasks. In *7th Joint IEEE International Conference on Development and Learning and on Epigenetic Robotics, ICDL-EpiRob 2017*, Vol. 2018-Janua, 2018.
- [29] Claudia Perez-D’Arpino and Julie A. Shah. C-LEARN: Learning geometric constraints from demonstrations for multi-step manipulation in shared autonomy. *Proceedings - IEEE International Conference on Robotics and Automation*, No. d, pp. 4058–4065, 2017.
- [30] Masaki Murooka, Ryohei Ueda, Shunichi Nozawa, Yohei Kakiuchi, Kei Okada, and Masayuki Inaba. Global planning of whole-body manipulation by humanoid

- robot based on transition graph of object motion and contact switching. *Advanced Robotics*, Vol. 31, No. 6, pp. 322–340, 2017.
- [31] 室岡雅樹. 操作応答の知覚による物理的整合性推論に基づくヒューマノイドの試行獲得型マニピュレーション. 東京大学大学院情報理工学系研究科知能機械情報学専攻 博士論文, 2018.
- [32] Ajay Kumar Tanwani and Sylvain Calinon. A generative model for intention recognition and manipulation assistance in teleoperation. *IEEE International Conference on Intelligent Robots and Systems*, Vol. 2017-Septe, pp. 43–50, 2017.
- [33] Takayuki Osa, Gerhard Neumann, Joni Pajarinen, J. Andrew Bagnell, Pieter Abbeel, and Jan Peters. An algorithmic perspective on imitation learning. *arXiv*, Vol. 7, No. 1, pp. 1–179, 2018.
- [34] Tianhe Yu, Chelsea Finn, Annie Xie, Sudeep Dasari, Tianhao Zhang, Pieter Abbeel, and Sergey Levine. One-Shot Imitation from Observing Humans via Domain-Adaptive Meta-Learning. *arXiv*, 2018.
- [35] Dmytro Pavlichenko, Diego Rodriguez, Max Schwarz, Christian Lenz, Arul Selvam Periyasamy, and Sven Behnke. Autonomous Dual-Arm Manipulation of Familiar Objects. In *IEEE-RAS International Conference on Humanoid Robots*, Vol. 2018-Novem, pp. 1136–1142. IEEE Computer Society, jan 2019.
- [36] Kuniaki Noda, Hiroaki Arie, Yuki Suga, and Tetsuya Ogata. Multimodal integration learning of robot behavior using deep neural networks. *Robotics and Autonomous Systems*, Vol. 62, No. 6, pp. 721–736, jun 2014.
- [37] Michelle A. Lee, Yuke Zhu, Yuke Zhu, Peter Zachares, Matthew Tan, Krishnan Srinivasan, Silvio Savarese, Li Fei-Fei, Animesh Garg, Animesh Garg, and Jeannette Bohg. Making Sense of Vision and Touch: Learning Multimodal Representations for Contact-Rich Tasks. *IEEE Transactions on Robotics*, Vol. 36, No. 3, pp. 582–596, 2020.

- [38] Tomoki Anzai and Kuniyuki Takahashi. Deep gated multi-modal learning: In-hand object pose changes estimation using tactile and image data. *IEEE International Conference on Intelligent Robots and Systems*, pp. 9361–9368, 2020.
- [39] Sergey Levine, Chelsea Finn, Trevor Darrell, and Pieter Abbeel. End-to-end training of deep visuomotor policies, 2016.
- [40] Sandy H. Huang, Martina Zambelli, Jackie Kay, Murilo F. Martins, Yuval Tassa, Patrick M. Pilarski, and Raia Hadsell. Learning Gentle Object Manipulation with Curiosity-Driven Deep Reinforcement Learning. mar 2019.
- [41] A J Holden, D J Robbins, W J Stewart, D R Smith, S Schultz, M Wegener, S Linden, C Hormann, C Enkrich, C M Soukoulis, D Schurig, A J Taylor, C Highstrete, M Lee, R D Averitt, P Markos, D Mcpeake, S A Ramakrishna, J B Pendry, V M Shalaev, M Maksimchuk, D Umstadter, W Chen, Y R Shen, and J V Moloney. Reducing the Dimensionality of Data with Neural Networks. Vol. 313, No. July, pp. 504–507, 2006.
- [42] Matthias Kerzel and Stefan Wermter. Neural end-to-end self-learning of visuomotor skills by environment interaction. *Lecture Notes in Computer Science (including sub-series Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Vol. 10613 LNCS, No. December 2019, pp. 27–34, 2017.
- [43] Kanata Suzuki, Momomi Kanamura, Yuki Suga, Hiroki Mori, and Tetsuya Ogata. In-air Knotting of Rope using Dual-Arm Robot based on Deep Learning. Vol. 4, No. c, 2021.
- [44] Namiko Saito, Danyang Wang, Tetsuya Ogata, Hiroki Mori, and Shigeki Sugano. *Wiping 3D-objects using Deep Learning Model based on Image/Force/Joint Information*.
- [45] Sepp Hochreiter. Long Short-Term Memory. Vol. 1780, pp. 1735–1780, 1997.
- [46] Andy Zeng, Pete Florence, Jonathan Tompson, Stefan Welker, Jonathan Chien, Maria Attarian, Travis Armstrong, Ivan Krasin, Dan Duong, Vikas Sindhwani, and Johnny

- Lee. Transporter Networks: Rearranging the Visual World for Robotic Manipulation. No. CoRL, 2020.
- [47] Daisuke Tanaka, Solvi Arnold, and Kimitoshi Yamazaki. EMD net: An encode-manipulate-decode network for cloth manipulation. *IEEE Robotics and Automation Letters*, Vol. 3, No. 3, pp. 1771–1778, 2018.
- [48] Daisuke Tanaka, Solvi Arnold, and Kimitoshi Yamazaki. Disruption-Resistant Deformable Object Manipulation on basis of Online Shape Estimation and Prediction-Driven Trajectory Correction. 2021.
- [49] David Coleman, Ioan Sutan, Sachin Chitta, and Nikolaus Correll. Reducing the Barrier to Entry of Complex Robotic Software: a MoveIt! Case Study. *arXiv*, pp. 1–14, 2014.
- [50] Rosen Diankov and James Kuffner. OpenRAVE : A Planning Architecture for Autonomous Robotics. *Robotics*, No. July, pp. –34, 2008.
- [51] Hsien Chung Lin, Te Tang, Yongxiang Fan, and Masayoshi Tomizuka. A Framework for Robot Grasp Transferring with Non-rigid Transformation. *IEEE International Conference on Intelligent Robots and Systems*, pp. 2941–2948, 2018.
- [52] Diego Rodriguez and Sven Behnke. Transferring category-based functional grasping skills by latent space non-rigid registration. *IEEE Robotics and Automation Letters*, No. May, 2018.
- [53] Marcus Gualtieri, Andreas Ten Pas, Kate Saenko, and Robert Platt. High precision grasp pose detection in dense clutter. *IEEE International Conference on Intelligent Robots and Systems*, Vol. 2016-Novem, pp. 598–605, 2016.
- [54] Andreas ten Pas, Marcus Gualtieri, Kate Saenko, and Robert Platt. Grasp Pose Detection in Point Clouds. *International Journal of Robotics Research*, Vol. 36, No. 13-14, pp. 1455–1473, 2017.

- [55] Arsalan Mousavian, Clemens Eppner, and Dieter Fox. 6-DOF GraspNet: Variational grasp generation for object manipulation. *Proceedings of the IEEE International Conference on Computer Vision*, Vol. 2019-Octob, No. Iccv, pp. 2901–2910, 2019.
- [56] Peter R. Florence, Lucas Manuelli, and Russ Tedrake. Dense object nets: Learning dense visual object descriptors by and for robotic manipulation. *arXiv*, pp. 1–12, 2018.
- [57] Peter Florence, Lucas Manuelli, and Russ Tedrake. Self-Supervised Correspondence in Visuomotor Policy Learning. *IEEE Robotics and Automation Letters*, 2020.
- [58] Kento Kawaharazuka, Kei Tsuzuki, Moritaka Onitsuka, Yuki Asano, Kei Okada, Koji Kawasaki, and Masayuki Inaba. Musculoskeletal AutoEncoder: A Unified Online Acquisition Method of Intersensory Networks for State Estimation, Control, and Simulation of Musculoskeletal Humanoids. *IEEE Robotics and Automation Letters*, Vol. 5, No. 2, pp. 2411–2418, 2020.
- [59] Kento Kawaharazuka, Toru Ogawa, and Cota Nabeshima. Tool Shape Optimization through Backpropagation of Neural Network. *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 0–6, 2020.
- [60] Takayuki Murooka, Kei Okada, and Masayuki Inaba. Diabolo Orientation Stabilization by Learning Predictive Model for Unstable Unknown-Dynamics Juggling Manipulation. *Proceedings of the 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 9174–9181, 2020.
- [61] Adrian S. Bauer, Peter Schmaus, Freek Stulp, and Daniel Leidner. Probabilistic Effect Prediction through Semantic Augmentation and Physical Simulation. *Proceedings - IEEE International Conference on Robotics and Automation*, pp. 9278–9284, 2020.
- [62] Shingo Kitagawa, Kentaro Wada, Shun Hasegawa, Kei Okada, and Masayuki Inaba. Few-experiential learning system of robotic picking task with selective dual-arm grasping. *Advanced Robotics*, Vol. 34, No. 18, pp. 1171–1189, 2020.

- [63] Jean Serra. *Image Analysis and Mathematical Morphology*. Academic Press, Inc., USA, 1983.
- [64] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778, 2016.
- [65] Diederik P. Kingma and Jimmy Lei Ba. Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, pp. 1–15, 2015.
- [66] Junya Fujimoto, Ikuo Mizuuchi, Yoshinao Sodeyama, Kunihiko Yamamoto, Naoya Muramatsu, Shigeki Ohta, Toshinori Hirose, Kazuo Hongo, Kei Okada, and Masayuki Inaba. Picking up dishes based on active groping with multisensory robot hand. *Proceedings - IEEE International Workshop on Robot and Human Interactive Communication*, pp. 220–225, 2009.
- [67] Kento Kawaharazuka, Toru Ogawa, Juntaro Tamura, and Cota Nabeshima. Dynamic manipulation of flexible objects with torque sequence using a deep neural network. *International Conference on Robotics and Automation*, pp. 2139–2145, 2019.
- [68] Zhongkui Wang, Takao Hirata, Takanori Sato, Tomoharu Mori, Masaru Kawakami, Hidemitsu Furukawa, and Sadao Kawamura. A Soft Robotic Hand Based on Bellows Actuators for Dishwashing Automation. *IEEE Robotics and Automation Letters*, Vol. 6, No. 2, pp. 2139–2146, 2021.
- [69] Toshinori Hirose, Yohei Kakiuchi, Kei Okada, and Masayuki Inaba. Design of Soft Flexible Wire-driven Finger Mechanism for Contact Pressure Distribution. *IEEE International Conference on Intelligent Robots and Systems*, pp. 4699–4705, 2019.
- [70] Terative Energy, Based Projection On, Normal Data, Manifold For, and Anomaly Localization. I Terative Energy - Based Projection on a Normal Data. pp. 1–17, 2019.

- [71] Sajjad Mozaffari, Omar Y. Al-Jarrah, Mehrdad Dianati, Paul Jennings, and Alexandros Mouzakitis. Deep Learning-Based Vehicle Behavior Prediction for Autonomous Driving Applications: A Review. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 23, No. 1, pp. 33–47, 2020.
- [72] Kanata Suzuki, Hiroki Mori, and Tetsuya Ogata. Motion switching with sensory and instruction signals by designing dynamical systems using deep neural network. *IEEE Robotics and Automation Letters*, Vol. 3, No. 4, pp. 3481–3488, 2018.
- [73] Simon Zimmermann, Ghazal Hakimifard, Miguel Zamora, Roi Poranne, and Stelian Coros. A Multi-Level Optimization Framework for Simultaneous Grasping and Motion Planning, 2020.
- [74] Siddharth Srivastava, Eugene Fang, Lorenzo Riano, Rohan Chitnis, Stuart Russell, and Pieter Abbeel. Combined task and motion planning through an extensible planner-independent interface layer. *Proceedings - IEEE International Conference on Robotics and Automation*, pp. 639–646, 2014.
- [75] Yuki Shirai, Xuan Lin, Yusuke Tanaka, Ankur Mehta, and Dennis Hong. Risk-Aware Motion Planning for a Limbed Robot with Stochastic Gripping Forces Using Nonlinear Programming. *arXiv*, Vol. 5, No. 4, pp. 4994–5001, 2020.
- [76] Kento Kawaharazuka, Kei Tsuzuki, Moritaka Onitsuka, Yuki Asano, Kei Okada, Koji Kawasaki, and Masayuki Inaba. Object Recognition, Dynamic Contact Simulation, Detection, and Control of the Flexible Musculoskeletal Hand Using a Recurrent Neural Network with Parametric Bias. *IEEE Robotics and Automation Letters*, Vol. 5, No. 3, pp. 4580–4587, 2020.
- [77] Kento Kawaharazuka, Kei Tsuzuki, Moritaka Onitsuka, Yuki Asano, Kei Okada, Koji Kawasaki, and Masayuki Inaba. Stable Tool-Use with Flexible Musculoskeletal Hands by Learning the Predictive Model of Sensor State Transition. *Proceedings - IEEE International Conference on Robotics and Automation*, pp. 4572–4578, 2020.

- [78] Kento Kawaharazuka, Naoki Hiraoka, Yuya Koga, Manabu Nishiura, Yusuke Omura, Yuki Asano, Kei Okada, Koji Kawasaki, and Masayuki Inaba. Online Learning of Danger Avoidance for Complex Structures of Musculoskeletal Humanoids and Its Applications. pp. 349–355, 2021.
- [79] Pr2. <https://support.clearpathrobotics.com/hc/en-us/categories/200217239-PR2>.
- [80] Clearpath robotics. <https://www.clearpathrobotics.com/>.
- [81] 古田悠貴. 長期経験に基づくタスク具体化機能を備えた日常生活支援ロボットシステムの構成法. 東京大学大学院情報理工学系研究科知能機械情報学専攻 博士論文, 2018.
- [82] Willow garage. pr2 user manual, 2012. https://www.clearpathrobotics.com/assets/downloads/pr2/pr2_manual_r321.pdf.
- [83] Zhengyou Zhang. Microsoft kinect sensor and its effect. *IEEE Multimedia*, Vol. 19, No. 2, pp. 4–10, 2012.
- [84] Kawasaki Heavy Industries. Dual Arm SCARA Robot - Kawasaki Robotics. <https://robotics.kawasaki.com/en1/products/robots/dual-arm-scara/>, 2019.
- [85] ABB. ABB’s Dual-Arm Collaborative Robot - Industrial Robots From ABB Robotics. <https://new.abb.com/products/robotics/industrial-robots/yumi>, 2019.
- [86] Rollin’ Justin. <http://www.dlr.de/rm/en/desktopdefault.aspx/tabid-5471>.
- [87] Kei Okkada. Development of Waterproof Glove for Humanoid Robots. Vol. 050, No. 1, pp. 3–4.
- [88] Yuta Kojio, Shunichi Nozawa, Fumihito Sugai, Yohei Kakiuchi, Kei Okada, and Masayuki Inaba. Development of Waterproof Suit for Life-sized Humanoid and

- Walking Control in Water using Online Buoyancy Estimation and Footstep Modification. *Journal of the Robotics Society of Japan*, Vol. 37, No. 5, pp. 427–437, 2019.
- [89] Dirk Jansen and Holger Buttner. Real-time ethernet: the ethercat solution. *Computing and Control Engineering*, Vol. 15, No. 1, pp. 16–21, 2004.
- [90] Ethercat technology group. <https://www.ethercat.org/default.html>.
- [91] Morgan Quigley, Ken Conley, Brian Gerkey, Josh Faust, Tully Foote, Jeremy Leibs, Rob Wheeler, and Andrew Y Ng. Ros: an open-source robot operating system. In *ICRA workshop on open source software*. Kobe, Japan, 2009.
- [92] G. Bradski. The OpenCV Library. *Dr. Dobb's Journal of Software Tools*, 2000.
- [93] Ioan a. sucu and sachin chitta, □ moveit! □ [online] available: <http://moveit.ros.org>.
- [94] Sören Pirk, Karol Hausman, Alexander Toshev, and Mohi Khansari. Modeling Long-horizon Tasks as Sequential Interaction Landscapes. *arXiv*, No. CoRL, pp. 1–14, 2020.
- [95] He Wang, Sören Pirk, Ersin Yumer, Vladimir G. Kim, Ozan Sener, Srinath Sridhar, and Leonidas J. Guibas. Learning a Generative Model for Multi-Step Human-Object Interactions from Videos. *Computer Graphics Forum*, Vol. 38, No. 2, pp. 367–378, 2019.
- [96] Danny Driess, Jung-su Ha, Russ Tedrake, and Marc Toussaint. Learning Geometric Reasoning and Control for Long-Horizon Tasks from Visual Input. *Proceedings - IEEE International Conference on Robotics and Automation*, 2021.
- [97] Kei Kase, Chris Paxton, Hammad Mazhar, Tetsuya Ogata, and Dieter Fox. Transferable Task Execution from Pixels through Deep Planning Domain Learning. mar 2020.

以上

1p～ 110p 完

修士論文

令和4年1月27日提出

知能機械情報学専攻
48-206554 若林 隼平