

ロボットマニピュレータによる道具操作のための  
3次元形状類似度を用いた深層模倣学習  
(Deep Imitation Learning Using 3D Shape Similarity for  
Robotic Tool Manipulation)

2022 年 1 月

博士（工学）

笹 竹 晴萌

豊橋技術科学大学

2022 年 1 月 7 日

機械工学専攻	学籍番号	第 121826 号	指導教員	内山 直樹
氏名	笹竹 晴萌			佐藤 海二

## 論文内容の要旨 (博士)

博士学位論文名	ロボットマニピュレータによる道具操作のための3次元形状類似度を用いた深層模倣学習
---------	--

(要旨 1,200 字程度)

近年、日本では少子高齢化が問題となっている。2040年には労働生産人口比率は54%まで減少すると予測されている。これにより人件費が増加し、モノやサービスの値段も上がると考えられている。この少子化による労働力不足を補うために早急な改善方法としてロボットによる労働の代替が望まれている。大規模な工場では自動化が行われているが、小規模な工場や製造業以外の職種ではロボットアームによる自動化は進んでいない。その一因は、ロボットアームを動作させるためには動作計画の教示が必要なためである。教示にはロボットの専門的な知識が必要であり、ツールが変わるたびに教示が必要となる。そこで、本研究ではロボットが人からツールの使用方法を直接模倣するシステムを提案する。これにより、専門のエンジニアでなくても、簡単に動作計画を教示することが可能となる。

本研究では、ロボットアームによる道具の使用法の高速な模倣学習システムの提案および実証実験を行った。提案システムは道具の形状と物理的特性が似ている場合には、それらの道具の使用法も類似するという仮定に基づいている。また、動作の模倣には深層学習を利用した。そのため、深層学習の重みパラメータは道具の使用法を表している。したがって、本研究における仮定は、道具どうしが似ている場合には、深層学習で学習される重みパラメータも近い値をとると言い換えることができる。この仮定を利用して、深層学習の重みパラメータとして表される道具の使用法と、その道具の特徴量を記録しておき、新しい道具が与えられたときに、記録にある道具と与えられた道具の類似度を計算し、最も類似度が高かった道具の学習済み重みパラメータを新しい深層学習の初期パラメータとして読み込む。これにより使用法の差だけを学習すれば済むようになるため、高速に学習が可能になると考えられる。

本研究では特に使用法を学習する道具として箒に着目した。まず、本研究では箒どうしが似ていることを数値的に計算するための手法を提案した。この手法は箒の3次元的特徴と物理的な特徴から箒間の類似度を計算可能である。また、教師データの作成には直感的に人の動作をロボットアームに教示することが可能なシステムを作成した。深層学習には順伝播型のアーキテクチャを用いた。環境の状態を入力とし、次の時刻におけるロボットアームの手先速度を推定する回帰問題として模倣をとらえ、学習を行った。実験では似ている箒の使用法を読み込むことによる学習回数の低減を検証した。また、実際にゴミを掃いて清掃能力の検証を行い、提案手法の有効性を確認した。

Date of Submission (January 7, 2022) :

Department of Mechanical Engineering	Student ID Number D121826	Supervisors  Naoki Uchiyama  Kaiji Sato
Applicant's name Harumo Sasatake		

**Abstract (Doctor)**

Title of Thesis	Deep Imitation Learning Using 3D Shape Similarity for Robotic Tool Manipulation
-----------------	---

Approx. 800 words

Japan has been facing the problem of a declining birthrate and an aging society, and it is predicted that the ratio of the working population to the total population will decrease to 54% by 2040. As a result, the labor costs are expected to increase, and the prices of goods and services will rise. To compensate for that, the use of robots to replace labor is desired. Large scale factories have been already automated, but small-scale factories or non-manufacturing occupations have not yet been automated with robot arms. One of the reasons for this is that teaching of motion plans is required to operate the robot arm. Teaching requires specialized knowledge of robotics, and it is necessary every time a tool is changed. In this study, A system in which a robot directly imitates the use of a tool from a person is proposed. This makes it possible to teach motion planning easily to non-expert engineers.

In this study, a fast imitation learning system for a robot arm to learn the usage of a tool is proposed. This system is based on the assumption that if the shape and physical properties of tools are similar, then the usage of those tools will also be similar. Deep learning is used to imitate the behavior. Therefore, the weight parameters of the deep learning are considered to represent the usage of the tools. So, the assumption made in this study is that if the tools are similar, the weight parameters learned by deep learning will also have similar one. Using this assumption, a part of learning process can be shortcut for the new tool. If similar tool is known, the learned weight parameters of the tool with the highest similarity as the initial value is load.

In this study, especially the broom is focused on as target to learn. Firstly, a method to numerically calculate the similarity between two brooms is proposed. This method is based on the 3D features and the physical features of the brooms. Secondly, A system that can intuitively teach human actions to the robot arm is proposed to create the training data for deep learning. Using the state of the environment as an input, deep learning system estimates the appropriate velocity of the robot arm tip at the next time. In the experiments, the reduction in the number of learning iteration is verified by loading the usage of similar brooms. In addition, the robot's ability by actually sweeping garbage is also verified and the effectiveness of proposed method is experimentally confirmed.

# Deep Imitation Learning Using 3D Shape Similarity for Robotic Tool Manipulation

Harumo Sasatake

*Department of Mechanical Engineering, Toyohashi University of Technology*

## **ABSTRACT**

In recent years, the declining birthrate and aging population have become a problem in Japan. As a result, the ratio of the working population to the total population is expected to decrease to 54% by 2040. As the working population decreases, labor costs will increase and the prices of products and services will rise. To make up for the labor shortage, the government is considering accepting foreign workers and improving the employment rate of women and the retired people. However, it will take time for these government policies to effect come out. Therefore, the substitution of labor by robots is desired as an immediate solution. While large factories have been automated, small factories and non-manufacturing industry such as a nursing home have not been automated with robot arms. One of the reasons for this is that teaching of motion plans is required to operate the robot arm. It requires specific knowledge for robotics. In particular, in the non-manufacturing industry, there are few robotics engineers, so it is difficult to use the robot arm. In addition, the robot arm can extend its functions by attaching tools to its end-effector to deal with them tasks. Each tool require a different motion plan. So the engineer is required whenever the tool is changed. Therefore, a method that the non-engineer can teach the robot the motion plan is desired

In this study, A system that the robot directly imitates the usage of a tool from a



human is proposed. It allows the users to teach the motion plan easily even if they are not the robotic engineer and it will be able to remove the barrier using robots. In this study, the fast imitation learning system is proposed and demonstrated for a robot arm to learn usage of the tool. The proposed system is based on the assumption that if the shape and physical properties of tools are similar, then the usage of those tools will also be similar. Deep learning is used to imitate the human behavior. The weight parameters of the deep learning are considered to represent the usage of the tools, so the above assumption in this research can be defined as follows: if the tools are similar, the weight parameters of deep learning can also get similar values. Using this assumption, when a new tool is given, the similarity between the broom in the database and the given broom is calculated, and the learned weight parameters of the tool with the highest similarity are loaded as the initial parameters for the new deep learning. Using this method, reducing the number of training iteration is attempted by learning only the differences in usage of these tools.

In this study, particularly, the broom is focused on. So this method calculates the similarity between two brooms based on the three-dimensional features and the physical features, without using large-scale machine learning. In addition, a virtual reality system is used as a motion capture system to create the training data. The operator operates the industrial robot remotely, measures its movements and the situation of the environment using image processing and these measured data are used for training data. For deep learning, a forward propagation architecture is used, the situation of the environment is input and velocity of robot arm tip. In the experiments, the reduction in the number of learning iteration is verified with proposed method and also the cleaning ability by actually sweeping garbage is verified.

# 目次

<b>第1章 緒言</b>	<b>1</b>
1.1 研究背景	1
1.2 先行研究	6
1.2.1 自動清掃に関する研究	6
1.2.2 ロボットによる動作の模倣に関する研究	9
1.3 残された課題と本論文の目的	11
1.4 本論文の構成	13
<b>第2章 道具の使用方法の模倣学習システム</b>	<b>15</b>
2.1 はじめに	15
2.2 模倣学習の高速化のためのコンセプト	15
2.3 道具の使用方法を高速に学習するシステムの概要	17
2.4 まとめ	20
<b>第3章 模倣学習システムの構築</b>	<b>21</b>
3.1 はじめに	21
3.2 実験に用いるハードウェア	22
3.2.1 7軸ロボットアーム	22
3.2.2 実験に使用する筭	25
3.3 実験に用いるソフトウェア	28
3.3.1 システムの概要	28

3.3.2	ロボットアーム手先速度制御システム . . . . .	29
3.3.3	計測システム . . . . .	30
	VRシステムを用いたロボット制御システムの構築 . . . . .	30
	RGBカメラを用いた清掃対象物計測システム . . . . .	32
3.3.4	学習システム . . . . .	36
	教師データ作成システム . . . . .	36
	深層模倣学習システム . . . . .	38
3.4	まとめ . . . . .	39
<b>第4章</b>	<b>筭の類似度の評価システム</b>	<b>41</b>
4.1	はじめに . . . . .	41
4.2	類似度評価システムの概要 . . . . .	42
4.3	筭の毛先反力からの類似度要素の取得 . . . . .	43
4.4	筭の点群からの類似度要素の計算 . . . . .	45
4.4.1	慣性モーメントの計算 . . . . .	48
4.4.2	有向バウンディングボックスの計算 . . . . .	49
4.5	筭毛先の角度からの類似度要素の計算 . . . . .	50
4.6	筭の類似度の計算結果 . . . . .	51
4.7	まとめ . . . . .	52
<b>第5章</b>	<b>実験</b>	<b>54</b>
5.1	はじめに . . . . .	54
5.2	使用方法の学習における時間短縮実験 . . . . .	55
5.3	長自在筭を用いた清掃実験 . . . . .	58
5.4	短スポンジを用いた清掃実験 . . . . .	59

5.5	実用的な対象物を用いた清掃実証実験 . . . . .	60
5.6	まとめ . . . . .	61
5.7	考察 . . . . .	69
5.7.1	類似度計算アルゴリズムに対する考察 . . . . .	69
5.7.2	学習回数の短縮に対する考察 . . . . .	69
第 6 章	結言と今後の展望	72
	参考文献	77
	謝辞	89

# 第1章 緒言

## 1.1 研究背景

少子高齢化とは社会の少子化と高齢化が同時に進行することであり、出生率の低下と平均寿命の増大が原因である<sup>[1]~[3]</sup>。高齢者の数と人口に占める割合により高齢化社会・高齢社会・超高齢社会の3段階に分類され、2020年現在、日本の高齢化率は28.7%であり、超高齢社会に分類される。日本では、1980年代から出生率の低下が続いており、その結果として現在では少子高齢化が起こっている。この傾向は今後も継続すると予測されており、2050年には人口は約一億人になる見込まれている。少子高齢化に伴って引き起こされる問題として、労働人口比率の減少、消費の減少による経済の縮小、高齢者の増加による社会保険料などの負担増加がある。特に生産労働人口比率は2017年には60.0%であり、20年後の2040年には54%まで減少すると予測されている<sup>[4]</sup>。また、2030年に出生率が2.07に回復し、高齢者が現在よりも5年多く働き、女性の進出がスウェーデン並みになったとしても2060年までに生産労働人口は5500万人まで減少する。このことから労働人口の減少は避けられず、健康寿命の延伸により医療サービスを受ける患者数を減らしたり、少ない人数で回していく医療福祉の改革が必要となっている<sup>[5]~[7]</sup>。

生産労働人口比率が減少することにより、労働を行える人数が減少するため、労働力が貴重となり人件費が上昇する。それを商品やサービスの価格に転嫁することにより物価が上がり、必要な人が適切なサービスを受けられなくなる可能性がある。特に病院や老人ホームにおいて2025年には約37.7万人の介護人材が不足すると考えられている<sup>[8]</sup>。既に以前から人手不足は統計に表れており、2019年の時点で有効

求人倍率の平均は 1.59 であり、また失業率は 2009 年から下がり続けて 2.2% となっている。今後もこの基調は続くと考えられている<sup>[9]</sup>。特に日本は労働人口の減少が顕著である。2000 年と 2015 年の労働人口を比較するとアメリカは 113.5%、イギリスは 108.8%、ドイツは 94.9% となっているが、日本は 89.8% となっており、最も減少が大きい国となっている<sup>[10]</sup>。

労働人口の減少によって引き起こされる問題は 5 つであるとされている<sup>[11]~[16]</sup>。1 つ目は経済規模の縮小である。働くよりも支える人のほうが多くなり、そのため経済の成長率が減少し、それに伴って生活の質が低下することが懸念されている。2 つ目は地方自治体の減少と首都圏の高齢化である。出生率が特に低い首都圏に人口が流入し、高齢化に拍車がかかるようになる。同時に、首都圏以外の 4 分の 1 の地方自治体で行政機能をこれまで通りに維持していくことが困難になる恐れがある。3 つ目は社会保障制度と財政を維持できなくなることである。高齢者 1 人を支える現役世代の人数は 1960 年では 11.2 人であったが、少子高齢化により 1980 年には 7.4 人となり、2014 年では 2.4 人となっている。2060 年には 1.6 人となることが予想されている。4 つ目は子供を持つ余裕がなくなることである。2010 年の調査では理想の子供の人数は 2.42 人であったが、実際は 1.71 人であった。5 つ目は地域からサービス産業の撤退が進み、生活に必要な商品やサービスを入手できなくなることである。すでに地方ではバスや鉄道の本数が減ったり、路線自体がなくなったなどの問題が起こっている。

少子高齢化による労働力不足を補うために外国人労働者の受け入れや女性と高齢者の就業率の改善が考えられている<sup>[17]</sup>。ただし、外国人労働者の受け入れによって根本的に労働力の確保の効果に関しては限定的との見方もあり、社会の不安定化を招くとの見方もある<sup>[18]~[20]</sup>。女性は 20 歳台後半から 30 歳台の出産・育児期に就業率が減少するということが分かっており、就業と出産・育児の両立が難しいことから就業を断念しているということが示されている<sup>[21]</sup>。そのため就業と出産・育児の両

立支援を進める必要があり、保育所などの充実を政府は推し進めている。また、高齢者に関して、政府は2021年に65歳から70歳へ定年引上げおよび70歳までの継続雇用制度など努力義務を企業に課す法律を制定した<sup>[22]</sup>。しかしながら、政策による労働人口の増加は時間がかかる。そのため早急な改善方法としてロボットによる労働の代替が望まれている<sup>[23]~[25]</sup>。以下では工場の自動化と清掃に関して、本研究が及ぼすインパクトを述べる。

まず、ロボットが人の作業を代替することによって社会に及ぼす影響について述べる。ロボットによる人間の作業の代替は以前から行われており、それについて様々な調査が行われている。Daronらは1993年から2007年にかけてアメリカで調査を行い、ロボットによる自動化が労働需要と賃金に与える景況を調査した<sup>[26]</sup>。その結果人口1000人当たりロボットが1台増えることにより雇用人口比率が0.2%、賃金が0.37%減少することが分かった。一方、Graetzらの調査ではロボットの導入が労働生産性を増加させた一方、総労働時間への影響は見られなかった<sup>[27]</sup>。さらにAutorらは労働者が行うタスクを非ルーチンタスクとルーチンタスクに分類し、その分類によって結果が異なることを明らかにした<sup>[28]</sup>。結果はルーチンタスクの雇用は減少し、同時に非ルーチンタスクの雇用が増加するというものであった。上述の3つは海外の研究であったが、足立らは日本における産業用ロボットの導入が雇用に与えた影響を分析した<sup>[29]</sup>。その結果、ロボット導入数と全体の雇用には関係が見られなかったものの、製造業に限定して分析すると正の相関が見られた。さらに学歴別に分析すると、製造業の短大・専門学校卒および4年生大学卒業以上の労働者について正の、非製造業の短大・専門学校卒の労働者について負の相関があることが分かった。このように日本において、特に製造業にロボットを導入することにより効果があり、人間の雇用を奪わないことが分かっているが、ロボットの普及には利便性と安全性の向上、低コスト化などの課題がある<sup>[30]</sup>。

次に、工場におけるロボットによる自動化について述べる。作業の自動化は以前

から大企業の工場を中心に行われており、ファクトリーオートメーション (FA) と呼ばれる。これは人間が行ってきた加工・組み立て・搬送・検査などの作業を産業用ロボットに置き換えることである。FA の歴史は古く、1962 年にユニメーション社により産業用ロボットが実用化されると、製品を移動させるなどの単純な繰り返し動作は人間からロボットに置き換えられていった<sup>[31]</sup>。ただし、それ以前にも人間の寸法や能力に合わないものはすでに自動化されていた。このころ残されていたのは一辺の大きさが 1~1000mm 程度で、1~50kg 程度の部品の組み立て・搬送であり、それ以上の大きさの部品はクレーンを使っていた<sup>[32]</sup>。1970 年になると数値制御 (NC) による工作機械が普及し、加工も自動化されることとなった。1980 年代にサーボモータ、センサ、CPU の性能が向上し、産業用ロボットの実装技術が確立され、特に自動車産業の溶接に使用されることが多かった。また、樹脂成型機からの取り出しにも使用されていた。1990 年代になるとアーク溶接の多層盛りやウィービングなどの独特の施工、パレタイジング等に利用されるようになった。また、これらをプログラミングしやすいようにインターフェースの改良がおこなわれた。2000 年代には海外での生産が中心となったため、国内では自動セル生産などの次世代の製造業へ応用が検討されるようになった。また、他のシステムと組み合わせて生産システムを構築するシステムソリューションが重視されるようになった。2006 年にはドイツによりインダストリー 4.0 が提唱された。さらに今後は IoT により工場内のすべてのものがインターネットに接続され、人や機械の稼働状況から最適な工場の運営が可能になると考えられている<sup>[33]~[35]</sup>。

しかし、現在、自動化が行われているのは大規模な工場のみである<sup>[36]</sup>。これは製品を大量に製造するため、膨大な回数の繰り返し動作が存在しており、1つの作業を自動化するだけで、人件費や時間の短縮などのコストカットが可能となることが理由である。また別の理由としては、ロボットを動かすためには動作計画を入力する教示という作業が必要であり、教示には専門の知識を持った技術者が必要となる。



小規模の工場では教示専門の技術者を雇うことは難しいため、教示や周辺機器を制御するシステムの開発を専門とするシステムインテグレータの会社に依頼することになる<sup>[37]</sup>。製造ラインやロボットに接続するツールを変更するたびに、教示は必要となり、コストが増加する。そのため、小規模な工場では自動化を積極的に進めることは難しい。そこで、本研究ではロボットが人からツールの使用方法を直接模倣するシステムを提案する。専門の技術者でなくても、簡単に動作計画を教示することが可能となり、これにより今まではシステムインテグレータの会社に依頼せざるを得なかった工場でもロボットの使用に関する障壁が低くなると考えられる。

そもそも、工場以外における自動化はほとんど進んでいないのが現状である。販売されているロボットとして警備ロボット・家庭用自動掃除ロボット・自動配膳ロボットなどが挙げられるが、家庭用自動掃除ロボット以外は普及していない<sup>[38] [39]</sup>。販売されていないロボットに関しても、救助ロボット・手術ロボット・歩行アシストロボットなどが存在するが普及しているとは言い難い<sup>[40]~[43]</sup>。また、家庭用自動掃除ロボットに関しても、使用できる環境に制限があり、清掃の完全自動化には至っていない。例えば、ホコリ以上の大きさや重さのゴミに関しては吸い込めない、もしくはケーブルを巻き込んで動作を停止してしまうなどの現象が報告されている<sup>[44]</sup>。また、床に水がこぼれている場合に関しても、水を吸い込み、中に水が入ってしまい故障することがある。このような掃除できるゴミの質量・体積・性質に関して制限がある。つまり、屋外での落ち葉掃除や、水が周囲にある環境では使用することが出来ない。また、食堂の床の食べこぼしの掃除に関しても、ローラーを利用した掃除方法は衛生的でなく、また、まき散らしてしまう恐れがある。そもそも人間が掃除に使用している道具を使用すればこのような問題は起きないため、人間が使用している掃除道具を使用して掃除を行うことが出来れば、掃除の自動化に関する問題は解決されると考えられる。そこで、本研究では、掃除をロボットに学習させる課題として設定する。具体的には、人間が使用している掃除道具の使用方法をロボッ

トに学習させる．これにより，今まで家庭用自動掃除ロボットでは掃除できなかった環境でも自動化が可能となり，かつ，人間の掃除道具をそのまま使用することが出来るので，ロボットのツールの設計が難しい非製造業の企業においても清掃ロボットを使用することが可能となる．

本研究では，課題として清掃を選択したが，提案するシステムは清掃作業のみならず，ロボットがツールを使用する作業であれば応用することが可能であると考えられる．そのため，今までロボットの導入が進んでいなかった企業においても，ロボットが普及し，作業が自動化されることにより，本研究が少子高齢化による労働者不足解決の一助になると考えている．

## 1.2 先行研究

### 1.2.1 自動清掃に関する研究

ロボットによる掃除の研究は，様々な取り組みがなされている．まず，屋外の広い場所の清掃を対象とした研究を説明する．Gambo らは建物の外壁を清掃するための低コストな操縦型ロボットを作成した<sup>[45]</sup>．Jardat らはよりシンプルな機構により壁面へ吸着できる機構を提案し，小型・軽量・低コストな自動で清掃を行うロボットを作成した<sup>[46]</sup>．太陽電池パネルに蓄積する塵やホコリは，太陽光を遮り，太陽電池の出力低下につながる事が知られている．そのため，Nasari らは太陽電池パネルを自動で清掃するための移動清掃ロボットを開発した<sup>[47]</sup>．

また，人が入りにくかったり，入ると危険な場所を清掃するためのロボットも研究されている．Zahugi らは海に流出した石油の回収を行うための水上ロボットシステムを提案している．このシステムは複数のロボットで構成され石油をフェンスで囲むことにより，石油の回収が可能であった<sup>[48]</sup>．また，Sanpeng らは石油貯蔵タンク内でのスラッジの洗浄作業を行うことが出来るロボットの研究を行った<sup>[49]</sup>．この

ロボットは小さな隙間から投入可能で高温の水を噴射することにより，人に代わり洗浄作業を行うことが可能であった．人が入れなかった配管内の洗浄作業を行うためのロボットも研究されている．Lee らは駆動輪とばね機構を使うことで垂直のエアコンダクトも登れるロボットを作成した<sup>[50]</sup>．また，清掃のための自律移動の研究もおこなわれている．薩見らはトイレ用の床清掃ロボットの開発および実証実験を行った．このロボットは吸引装置とモップを搭載しており，掃除の際に家庭用掃除機より騒音を抑えることが出来た．また，操作性の検証も行われた<sup>[51]</sup>．また同様に実用性に重きを置いた床清掃ロボットは青山らによっても研究された．この研究では清掃能力だけでなく，安全性を検証するためにダミー人形による衝突実験も行われ，低コスト化に関しても研究が行われた<sup>[52]</sup>．船田らは水中の空き缶を回収するために，陸上・水中共に走行可能なロボットを開発した．2 輪駆動でカメラを搭載し水中で空き缶を観察し，電磁石により，ロボット前部に搭載されている回収ボックスに入れることが可能であった<sup>[53]</sup>．小山らは浄水場内の緩速ろ過池を掃除するロボットを開発した．この掃除ロボットによりろ過池の水を抜かずに掃除することと水面が凍っていても掃除することが可能となった<sup>[54]</sup>．また，角道らは階段を掃除を自動化するために，階段昇降が可能なロボットを開発した．L 字型の脚を用いた階段昇降機構および2 輪から構成される全方向に移動可能な機構を備えており，また，階段の端までの距離を PSD センサで測定することが可能であった<sup>[55]</sup>．Ye らは家庭用清掃ロボットのスケジュールに関する研究を行った．ガウス混合分布により室内のゴミの堆積具合を予測することで，最適な清掃タイミングと清掃経路を計算した<sup>[56]</sup>．Le らは腐食した船の船体をウォータージェットを利用して掃除するためのロボットの動作計画を自己合成型のディープコンボリューショナルネットワークに基づくヒートマップを利用して経路を作成し，強化学習によって行動させることによりエネルギーと水の使用量を減少させる研究を行った<sup>[57]</sup>．また，小型清掃ロボットには取り除けるゴミの大きさに制限があるため，取り除けない物体は避ける必要がある．

そこで青木らはゴミを認識する手法の研究を行った<sup>[58]</sup>。鹿嶋らはゴミを識別するために、ロボットを移動させ、各種センサを装着したロボットにより対象物に接近・センシングを繰り返し、段階的に解析することにより対象物を識別する手法を提案した<sup>[59]</sup>。また、回収できないゴミを避けるのではなく、ロボットアームを搭載することにより回収可能にする研究が平田らによって行われた<sup>[60]</sup>。福田らは清掃の経路作成に天井の蛍光灯の位置情報を利用して自己位置を推定する手法を提案した<sup>[61]</sup>。

また、人の使用している道具をマニピュレータに装着し、掃除を行わせる研究について述べる。Langsfeld らは、双腕ロボットアームが掃除道具を使用し、柔軟物体上の汚れをふき取る研究を行った<sup>[62]</sup> <sup>[63]</sup>。ここでは、柔軟物体の特性を段階的に推定することにより、清掃効率を上げるシステムが提案された。Hess らは車や椅子などの3次元表面を研磨するための最適な経路を、大規模な巡回セールスマン問題としてとらえることにより生成する手法を提案した<sup>[64]</sup>。清掃を行うロボットの研究において、特に Elliott らの研究を参考にした<sup>[65]</sup>。Elliott らは机上に置かれた大粒の砂を、手帚把持したロボットアームにより、所望の位置へ移動させる手法を提案した (Fig.1.1)。この研究では、機械学習の一つであるランダムフォレストを利用し、手帚による砂の変形を予測するシステムを作成した。具体的には、机上の砂の状態を  $20 \times 30$  の格子状に離散化し、各格子は砂がどれくらいの確率で格子内に存在しているかを示す値を保有していた。また、ロボットの行動として、手先の平行移動も  $9 \times 9$  の格子状に離散化されて表現されており、この2つの格子を入力として、予測システムは行動後の砂の状態を予測できた。この予測システムと木探索と組み合わせることにより、手帚の移動距離と行動回数を最小にするように、砂を所望の位置へ移動させる一連の動作を生成し、ロボットに生成した行動を実行させた。

しかし、これらの研究は、人間のスキルを模倣するのではなく、実験環境下での最適な行動を計画するものであり、ロボットは1つの掃除道具のみに対応し、他の道具を使用するためには計算を再度行う必要があった。

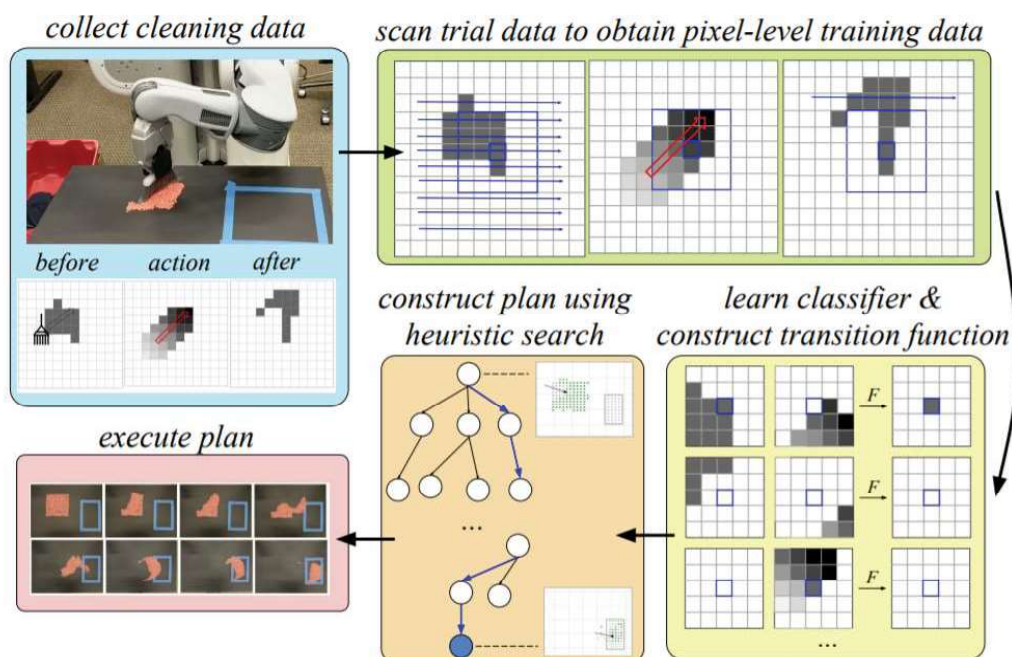


Fig. 1.1 Related research: Planning for dirt rearrangement <sup>[65]</sup>

### 1.2.2 ロボットによる動作の模倣に関する研究

多くの問題において、人がすでに最適な動作を知っている場合がある．そのため、人の動作をロボットに模倣させることにより、適切な行動を選択することが可能となる．内田らと宇田川らは、モーションキャプチャにより教師データセットを作成し、ニューラルネットに学習させることによりロボットに歩容動作を獲得させる研究を行った<sup>[66]</sup> <sup>[67]</sup>．また、坪内らは、柔軟関節を有する人型ロボットに人の動作を模倣させるために、視覚フィードバックから自己モデルを獲得し、神経力学モデルを利用することで、動作プリミティブを自己組織化するシステムを提案した<sup>[68]</sup>．望月らは、人間の神経発達過程と同様の過程をロボットに実装し、発達の学習を行わせる神経回路モデルの提案し、実ロボットに描画能力を獲得させた．またそのモデルによりロボットは時計回りの円を上手に描くことが可能であり、その能力は幼児と

似たような発達具合をたどった<sup>[69] [70]</sup>.

また、未知の道具の使用方法を予想する研究は、ロボットを通して人間の発達の経緯を明らかにしようとする発達認知ロボティクスの分野において積極的に行われている<sup>[71]~[73]</sup>. Stoytchev らは T 字や I 字などの原始的な形状の道具を使用して、対象物を目的の方向へ移動させるシステムを作成した<sup>[74]</sup>. このシステムはロボットアームの動作と対象物の動きの相関関係をデータベースに記録しておき、対象物の移動方向を指定すると、ロボットアームの動作を作成することができた. Sinapov らはそのシステムを改善し、対象物と道具の接触面の分類に k-NN を用いることで、対象物と道具の接触面のモデルを一般化、収集したデータをほかの道具にも応用できるようにした<sup>[75]</sup>. Tikhonoff らは熊手と鍬を利用して、ロボットの動作範囲外のぬいぐるみを手前に引き寄せる動作計画を生成するシステムを提案した<sup>[76]</sup>. このシステムは道具の画像と点群を利用するものであり、対象物を所望の方向へ移動させるための道具の種類の選択と把持の仕方を推測可能であった. これらの研究で使用される道具の形状はいずれも単純であり、またロボットの実行可能な行動も数種類に制限されていたため、実際の課題を解決するには至らなかった.

近年では、深層学習がロボットに人間の動作を模倣させる手法として利用されている<sup>[77]~[80]</sup>. オートエンコーダにより得られた少数の状態空間表現を利用して強化学習を行う手法やカメラから得られた画像を直接的にロボットアームの手先動作に変換する手法などの研究が行われている<sup>[81] [82]</sup>. また、深層学習にはほかの教師あり学習と比較して、非常に多くの教師データが必要であり、その問題を解決するためにバーチャルリアリティシステムを利用して、ロボットを操作し、模倣に必要な教師データを作成するという手法が存在する<sup>[83]~[86]</sup>. 教師データの作成において、特に参考にした Zhang らの研究について説明する<sup>[87]</sup>. Zhang らはバーチャルリアリティシステムを用いて、ロボットを動かし、ロボットのカメラ画像を人間の視覚にフィードバックすることにより、深層模倣学習用の教師データを作成した. そ

の様子を Fig.1.2 に示す．それまで，模倣学習用の教師データを作成するためには，ティーチングペンダントやジョイスティック，もしくはモーションキャプチャを利用して間接的にロボットアームを動かすか，ロボットを人の手で直接動かし，その時のロボットと環境の変化を同時に記録するというものが一般的であった．ティーチングペンダントやジョイスティックを利用した操作は直感的ではなく，スムーズにロボットを動作させられないといった欠点があった．一方，ロボットを人の手で直接動作させる方法は，人の手が環境の変化を記録するためのカメラに映り込み，教師データにノイズを発生させる原因となることが問題となっていた．さらにモーションキャプチャは購入費用が高額であることから，利用できる環境が限られていた．そこで，Zhang らは安価で，3次元空間を計測可能なバーチャルリアリティシステムをモーションキャプチャのように使用することにより，それらの問題を解決した．バーチャルリアリティシステムを使用して作成した教師データをもとに，深層模倣学習を行い，ロボットにブロックの押し込みや，ボールを把持して移動させるなどの動作をロボットに学習させた．

### 1.3 残された課題と本論文の目的

これらの深層学習を用いた模倣には，学習に時間を要するという問題があり，その解決が本研究の目的である．深層学習の学習に時間がかかる原因は，重みパラメータを漸近的に最適な値へ近づけていくためである．深層学習は教師データの入出力関係を，重みパラメータを変更することによって，学習していくものである．しかし，更新回数は入出力間の複雑性に大きく依存し，対象とする問題が複雑であればあるほど，学習が完了するまでに時間を要する．

本研究では，道具の使用方法を人が道具を使用する行動から直接模倣することを試みる．動作の対象として，特に清掃に焦点を当てる．深層模倣学習には多くの計算時間が必要であるという課題を，バーチャルリアリティシステムを用いた教師



Fig. 1.2 Related research: Creating of teaching data with virtual reality teleoperation<sup>[87]</sup>

データの作成手法の利用と深層学習の初期重みパラメータの推定により解決を試みる．本研究では，複数の種類の筭や，清掃対象物に関して清掃能力を実験により検証する．また，どのくらい学習時間が短縮されるかについても同様に検証を行う．

本研究の新規性は3つある．1つ目は道具の3次元形状および物理特性から，深層学習の初期値を推定するアルゴリズムである．また，2つ目はシステム構成であり，3つ目はシステムを実際の清掃対象物に応用したことである．

1つ目の新規性の詳細を述べる．道具の3次元形状と物理特性から深層学習のパラメータの初期値を推定することが新しいと考えられる．提案するアルゴリズムを使用することで重みパラメータの更新回数が少なくて済むようになり，未知の道具の使用方法を短時間で学習可能となると考えられる．その結果，将来的に清掃現場などで使用方法をロボットが学習する場合に，学習に要する時間を削減することが可能となると考えられる．

2つ目の新規性の詳細を述べる．清掃を対象とした研究において，力覚センサや



VRシステムなどを用いたシステム構成が新しいと考えられる。人の腕はロボットアームと比べて大きい加速度を瞬間的に出せたり、複雑な動作が可能であったり、力を検知することが可能であるなどの差が存在する。人が道具を使用している場面から直接教師データを作成すると、結果としてロボットアームでは実現できない行動が深層学習によって獲得される可能性がある。そこで、ロボットアームを操縦するシステムの構成を考え、それを利用して教師データを作成することにより、ロボットアームが可能な行動のみで構成された教師データを作成することが可能になると考えられる。また、力を検知するための力覚センサをシステムに組み込むなどして清掃に適したシステムを構築した。

3つ目の新規性の詳細を述べる。提案したシステムを利用してベンチマークとなる立方体の木材だけでなく、実際の清掃対象となりうる工芸用の石や工業用の珪砂などに対して清掃実験を行い、提案システムの応用について明らかにした。

## 1.4 本論文の構成

本論文の構成を以下に述べる。第1章では研究背景について述べ、本研究が社会に与えるインパクトについて述べた。また、先行研究と残された課題について述べた後、本論文で研究する範囲について説明した。第2章では深層模倣学習を高速化するための仮定と、それを実現するためのシステムを提案する。第3章では、実験環境やロボットアーム制御のためのシステム、実験環境認識のためのシステムなど、実験で使用するシステムについて述べる。第4章では、道具の類似度を計算するための手法について述べ、実際に複数の箒を対象にして類似度を計算する。第5章では、実証実験とその結果について述べる。3種類の細粒の掃きタスクの学習、および実際の学習のための教師データ作成についてもこの章で述べる。最後に、第6章では、結言と今後の展望について述べる。Fig.1.3に各章の位置づけと概要を示す。

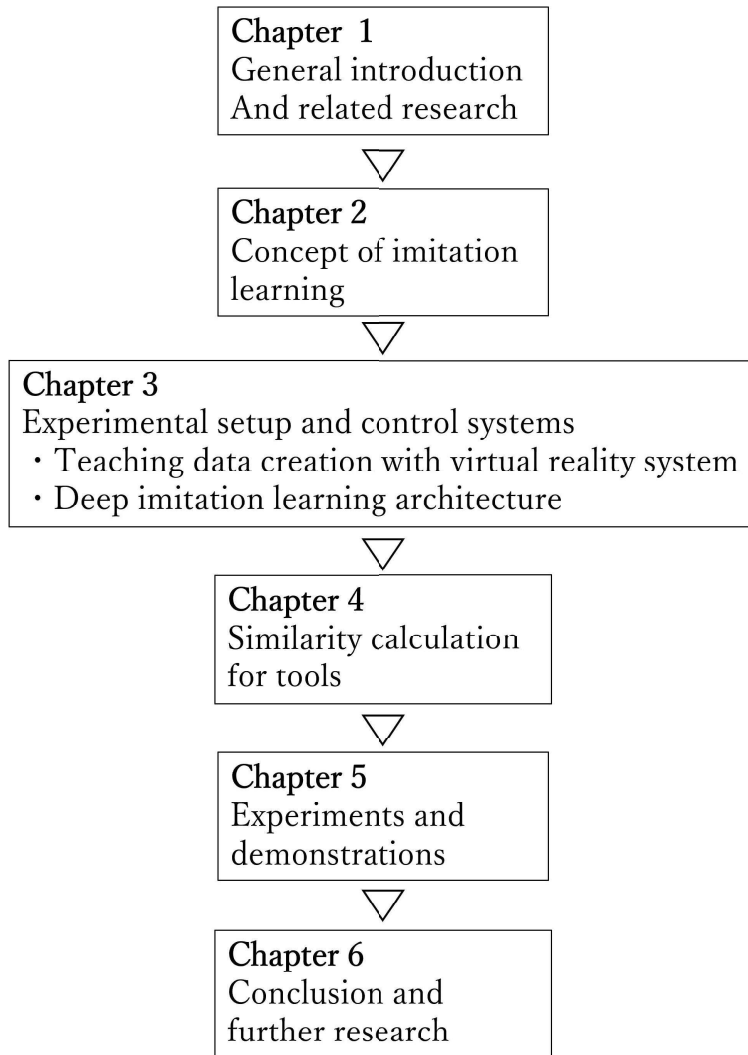


Fig. 1.3 Outline of this disseration

# 第2章 道具の使用方法の模倣学習システム

## 2.1 はじめに

この章では、深層模倣学習を高速化するための仮定と、それを実現するためのシステムの概要の説明を行う。説明の流れは、本研究の目的である深層学習の計算時間を短縮するためのアイデアを説明する。このアイデアは道具の形状と深層学習の学習パラメータの間にある関係の仮定を前提としたものである。さらに、そのアイデアを利用して道具の使用方法をロボットアームが学習するためのシステムについて概要を述べる。

第1章で述べた深層模倣学習の関連研究では、平面上に対象物があり、ロボットが可能な行動も並行移動だけなどの環境や行動を制限することにより、学習量を削減し、学習を有限時間内に収めようとする研究が多くあった。本研究は、環境やロボットの行動を制限することにより学習量を減らすのではなく、経験を用いることで、有限時間内に学習を収めようとする点で、それらの研究とは異なる。また、学習を高速化するための手法に新規性があると考えている。

## 2.2 模倣学習の高速化のためのコンセプト

人から箸の使用方法を模倣し、経験を利用し、与えられた箸の使用方法を少ない教師データから学習する方法を説明する。まず、提案手法における箸の使用方法は深層学習 (Deep Neural Network/DNN) で学習の結果獲得される重みパラメータのことである。深層学習は人の神経回路を模して設計されている。人の場合はニュー

ロンからニューロンへ電気信号が送られ、それにより行動や認識を行う。人の経験によってニューロン間の結合の強さは異なるため、電気信号は途中で減衰もしくは増幅される。深層学習においてニューロンにあたるものはユニットと呼ばれ、電気信号の代わりに数値がユニット間で伝達される。ただし、ユニット間を移動する際には、数値に重みかけられる。この重みは学習の結果得られる値であり、入力された数値に適切な重みを掛けることにより、最終的な結果を出力する。ここで述べる最終的な結果とは、ロボットであればセンサの値などの入力に対する行動であり、識別のために学習を行ったのなら、カメラ画像に対する植物や自動車などが写っているピクセルとなる。つまり、重みとは、入力から出力への変換を行うためのものであり、本研究においては現在の環境の情報からロボットの次の時刻での行動を変換するものである。

箒の柄の長さ、毛先の方向、毛先の形状などによって、ロボットの適切な行動は異なる。たとえば、柄が短ければ、ロボットは手先を床に近づける必要がある。また、毛先の形状によって接触した物体へ及ぼす効果は異なる。つまり、箒によって人の使用法は異なり、提案手法においては重みパラメータが異なると考えられる。

先行研究でも挙げた通り、ロボットに人間の行動を模倣させる場合において、深層学習は有力な手法の一つである。提案手法においても、ロボットは箒の使用法を深層学習を用いて習得する。深層学習は複雑な箒の使用法を獲得可能であるが、多くの教師データが必要となる。そこで本研究では以下の仮定を置くことにより、箒の使用法を学習するために必要な教師データの削減を試みる。

仮定：2つの箒の形状が類似している場合、2つの箒の使用法も似ている。つまり、2つの箒の使用法を表した深層学習の重みパラメータも似ている値となる。

人間が見たことのない形状の道具を目にしても、その使用法を想像することが可能なのは、以前に似た道具を使用した経験から、使用法を推定することが出来

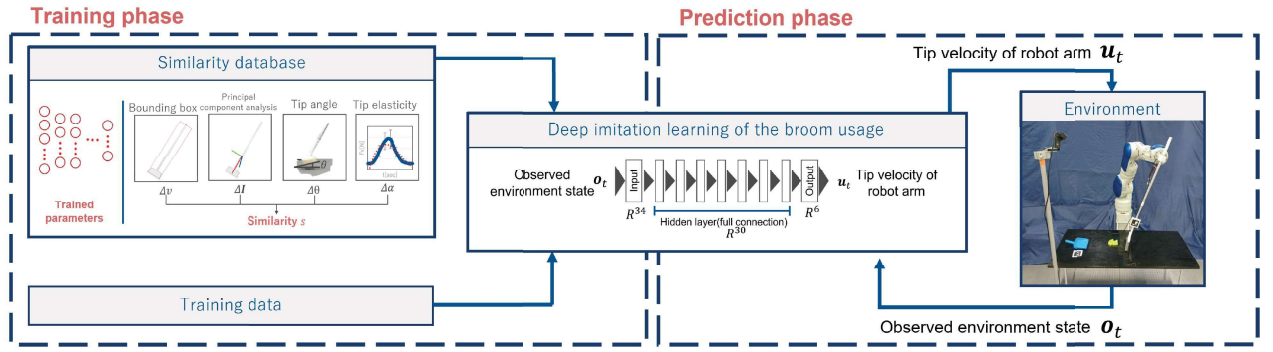


Fig. 2.1 System overview

るからだと考えられる．本研究では，これと同様に経験を利用することにより，ロボットのシステムに使用方法が組み込まれていない道具であっても，その使用方法を推定する手法を提案する．繰り返しになるが本研究における道具の使用方法とは深層学習の重みパラメータのことであるので，使用方法を推定するとは，重みパラメータを推測することに他ならない．

このシステムを実装するためにはプログラム内で表現可能なように，2つの道具の形状と性質がどれくらい似ているかという尺度を定める必要がある．本研究ではこれを類似度と呼び，詳しくは第4章で説明する．

## 2.3 道具の使用方法を高速に学習するシステムの概要

経験を利用することで高速に箒の使用方法の学習を実現するシステムの概要について述べる (Fig.2.1)．このシステムは2つのフェーズに分かれている．学習フェーズと実行フェーズである．学習フェーズは箒の使用方法の学習を行い，実行フェーズは，学習フェーズにおいて学習した箒の使用方法を実際の環境で実行することを行う．

まず，学習フェーズの概要について述べる (Fig.2.1 左側)．最初にデータベースに複数の箒の点群，毛先の角度，毛先の弾性とその箒の使用方法が格納されてい



Fig. 2.2 Point cloud of Stanford bunny <sup>[90]</sup>

る．点群とは Fig.2.2 に示すような，物体の 3 次元形状を 3 次元の点の集合体として表したものである．データベースに格納されていない箸が与えられたとき，データベースを参照し，与えられた箸とデータベース内の 2 つの箸に関して類似度の計算を行う．そのため，類似度はデータベース内に格納されている箸の数だけ算出される．そしてデータベース内の最大の類似度の箸を見つけ，その箸の使用方法をデータベースから深層学習に初期値として読み込む．そのうえで，与えられた箸の学習を行う．この学習は，与えられた箸の教師データを使用して行われる．ロボットにとっては使用方法が不明であるが，人間にとっては使用方法が分かっているため，この箸の使用方法を含んだ教師データを作成することは可能である．似ている箸の使用方法を初期値として，それを上書きする形で学習が行われる．これにより，短い学習時間でもロボットは新しい箸の使用方法を学習可能だと考えられる．なぜなら，すでに学習の初期値に，与えられた箸の使用方法に近い使用方法が読み込まれているため，学習においては箸の使用方法の差分だけを学習すれば済むからである．

さらに、その箒の形状および物理特性と新たに学習した使用方法をデータベースに追加する。別の新たな箒の使用方法の学習を行う際に、このデータベースに格納されているデータを利用し、学習に必要な時間を削減する。このように断続的なオンライン学習を繰り返すことで、効率良く道具の使用方法に関する知識を学習することが可能になると考えている。

実行フェーズ (Fig.2.1 右側) の概要を説明を述べる。このフェーズでは学習フェーズで得た重みパラメータを用いて、実際にロボットを動かす。本研究における深層学習では、力覚センサやカメラなどによって得られる環境中の情報を受け取り、ロボットの先端速度指令を出力する。その速度指令をもとにロボットは動作し、その動作の結果として、箒の角度や清掃対象物の位置などの環境が変化する。次の時刻において、前の時刻と同様に環境中の情報を受け取り、動作を決定する。これを繰り返すことによって、ロボットは清掃の動作を実行する。

教師データの構成について述べる。実行フェーズにおいて、深層学習は環境から時刻  $t$  における観測データ  $\mathbf{o}_t$  を取得し、それを入力とし、ロボットアームの先端速度  $\mathbf{u}_t$  を出力する。 $\mathbf{o}_t$  は式 (2.1) で示される。

$$\mathbf{o}_t = (\mathbf{x}_{arm/t-2;t}, \mathbf{x}_{broom}, \mathbf{x}_{dirt}, \mathbf{x}_{dustpan}, f_{vertical}) \quad (2.1)$$

$\mathbf{o}_t$  は以下の (a)~(e) の 5 つの情報から構成されており、いずれも  $[-1, 1]$  の値をとるように正規化されている。

(a)  $\mathbf{x}_{arm/t-2;t} \in \mathbb{R}^{18}$  : 時刻  $t-2$  時点から  $t$  のロボットアームの先端座標

(b)  $\mathbf{x}_{broom} \in \mathbb{R}^6$  : 箒に取り付けられた AR マーカの座標

(c)  $\mathbf{x}_{dirt} \in \mathbb{R}^3$  : 対象物の中心の位置

(d)  $\mathbf{x}_{dustpan} \in \mathbb{R}^6$  : ちり取りの AR マーカの座標

(e)  $f_{vertical} \in \mathbb{R}^1$  : 力覚センサで検出された垂直方向の力

深層学習のアーキテクチャの概要について述べる時刻  $t-2$  時点から  $t$  のロボットアームの手先座標を入力に含めることにより、速度を考慮した学習が期待される。また、学習層は8層で構成されており、入力層は34次元、中間層は30次元、出力層は6次元である。各層は全結合であり、活性化関数に正規化線形関数、損失関数は最小二乗誤差を使用している。また、ミニバッチサイズは2である。

既にある学習済み重みパラメータを流用することによって、学習を高速化し、教師データの削減を行う手法として転移学習がある。例えば、画像中からバスを検出するように学習した深層学習を、ダンプを検出するために学習させるときに使用される。本研究でこの手法を採用しなかった理由としては、道具の使用方法が大幅に異なる場合に対応するためである。転移学習は流用した深層学習の出力層以外の重みパラメータを固定する。そのために、学習する道具の使用方法によっては、学習できない場合があると考えられる。そのため、本研究では転移学習を使用しない。

## 2.4 まとめ

この章では、深層模倣学習を高速化するための仮定と、それを実現するためのシステムを説明した。まず、本研究における道具の使用方法は、深層学習における学習の結果、獲得される重みパラメータであることを述べた。そして、この重みパラメータを、新しく学習する道具の形状から推測し、深層学習の初期値として利用することにより、重みパラメータの更新回数を減少させるというアイデアを説明した。また、上述のアイデアを実装するためのシステムの概要について説明し、システムの入出力やデータの流れについて述べた。



## 第3章 模倣学習システムの構築

### 3.1 はじめに

この章では、実験に用いるハードウェアとソフトウェアの詳細について述べる。まず、ハードウェアについて説明する。使用する実験環境の概要について説明した後、安川電機製のロボットアームの可動範囲や可搬重量などのスペックについて述べる。さらに実験で使用する筈について詳しく述べる。次に、ソフトウェアについて説明する。まず、道具の使用方法を学習し推測するための学習システムについて述べる。ここでは、学習システム内の複数のプログラムがどのように連携して、道具の使用方法の学習が行われるかということと、プログラム間のデータの流れ説明する。次に、ロボットアームを制御するためのシステムについて述べる。ここでは、逆運動学を計算し、ロボットアームの手先を速度制御するための計算について説明する。さらに、教師データを直感的に、作成するためのシステムについて述べる。ここでは、バーチャルリアリティシステムをモーションキャプチャのように利用して、ロボットアームを制御するための座標変換について説明する。次に、バーチャルリアリティ以外の RGB カメラと力覚センサを用いた計測システムについて述べる。実験環境内の物体の座標を検出するための、AR マーカと画像処理のアルゴリズムについて説明する。最後に、深層学習を利用して、道具の使用方法を学習する深層学習の詳細について述べる。ここでは、教師データの作成方法および模倣学習に用いられる深層学習のアーキテクチャについて説明する。

第1章で述べた関連研究の中には、ロボットへの教示を簡単にするために、対象を平面のみに絞る研究が多くあるが、本研究では、対象を平面に制限せずに教示でき

るようにバーチャルリアリティシステムをモーションキャプチャのように使用する。

## 3.2 実験に用いるハードウェア

本研究で使用する実験環境を Fig.3.1 に示す。実験環境には7軸ロボットアームが置かれており、箒とロボットアームの手先は6軸力覚センサを介してつながれており、箒が受ける力とトルクを観測可能である。また黒い机の上には黄色の清掃対象物（10個の1cm角の立方体）とちりとりが置かれている。環境観測用にRGBカメラが設置されており、箒とちりとりの位置と角度に関してはARマーカーで、清掃対象物に関しては画像処理により座標を観測している。ロボットの制御及び計測アルゴリズムについては本章で詳しく述べる。

### 3.2.1 7軸ロボットアーム

本実験で使用するロボットアームの詳細について述べる。本実験で使用するのは安川電機製のSIA20Fである。このロボットは7軸を有する産業用ロボットアームである。その外形を Fig.3.2 に、性能を Table 3.1 に示す。SIA20Fは全長が1500mmであり、最大可搬重量が20kg、本体質量が120kgの大型のロボットアームである。垂直到達距離は1498mm、水平到達距離は910mmとなっているまた、繰り返し精度が $\pm 0.1\text{mm}$ となっている。このことから、机を箒で掃くには十分な性能を有していると言える。

実験環境を計測している各種センサからの値に基づいてロボットアームは動作する。そのためにロボットアームに搭載されているエンコーダを除く、すべてのセンサはPCに接続されており、またPCからロボットアームに指令を送れるようにケーブルを接続する必要がある。ロボットアームとPC間を含むセンサのケーブルの接続方法を Fig.3.3 に示す。ロボットアームとロボットコントローラ間およびティー





Fig. 3.1 Experimental environment

チングペンダント間は安川電機の専用のケーブルで接続されている。また、ティーチングペンダントには非常停止ボタンが設置されており、ロボットの関節角度や手先位置を移動させることが出来る。実験のためのロボットアームの手先の初期位置の決定にはティーチングペンダントを利用している。ロボットコントローラと PC 間のみ Ethernet ケーブルで接続されており、TCP 通信を用いて 40Hz でデータをやり取りすることが可能である。本実験ではロボットから PC へエンコーダの値を送信し、PC からは各関節の目標角度を送信する。一般的な産業用ロボットアームと異なり、本ロボットアームは時々刻々、目標角度を送信しそれに追従するように動作させることが可能である。この機能を利用して、学習フェーズにおける教師データの作成および、実行フェーズにおける清掃実験を行う。また、エンコーダの値か



(a) Front view of the robot arm (b) Reachable area of the robot arm

Fig. 3.2 The appearance of the robot arm

らロボットアームの手先位置及び姿勢への変換はPC側で計算する。

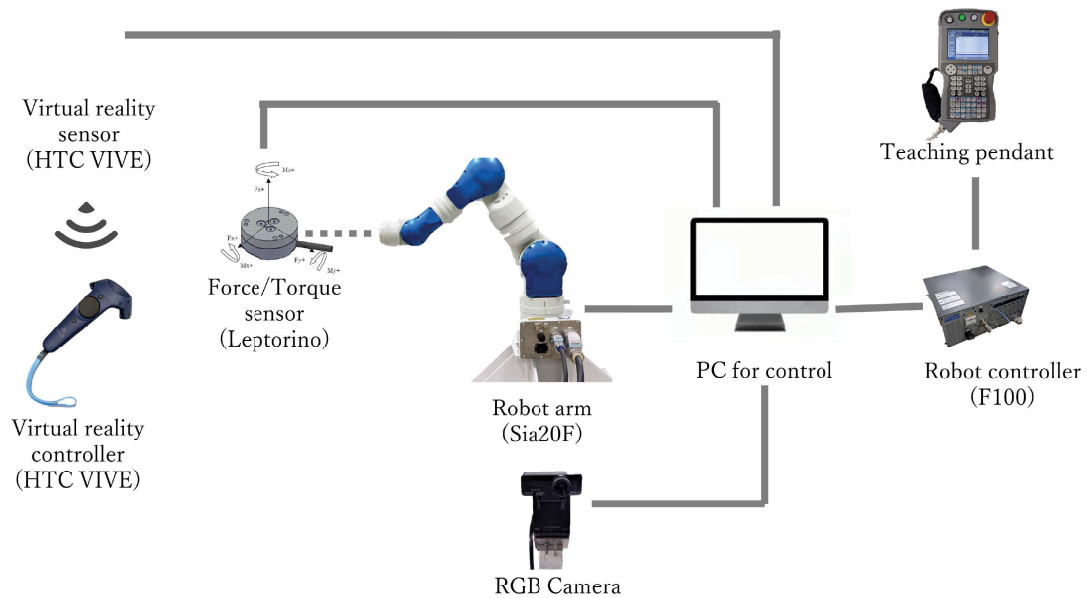


Fig. 3.3 Cable connection of the experimental environment

Table 3.1 Specifications of the robot arm

名称	MOTOMAN-SIA20F	
形式	YR-SIA020F-A100	
可搬重量	20 kg	
最大リーチ	910 mm	
繰り返し位置決め精度	$\pm 0.1$ mm	
動作範囲	S 軸（旋回）	-180 deg $\sim$ +180 deg
	L 軸（下腕）	-110 deg $\sim$ +110 deg
	E 軸（肘）	-170 deg $\sim$ +170 deg
	U 軸（上腕）	-130 deg $\sim$ +130 deg
	R 軸（上腕回転）	-180 deg $\sim$ +180 deg
	B 軸（手首振り）	-110 deg $\sim$ +110 deg
	T 軸（手首回転）	-180 deg $\sim$ +180 deg
最大速度	S 軸（旋回）	2.27 rad/s, 130 deg/s
	L 軸（下腕）	2.27 rad/s, 130 deg/s
	E 軸（肘）	2.97 rad/s, 170 deg/s
	U 軸（上腕）	2.97 rad/s, 170 deg/s
	R 軸（上腕回転）	3.49 rad/s, 200 deg/s
	B 軸（手首振り）	3.49 rad/s, 200 deg/s
	T 軸（手首回転）	6.98 rad/s, 400 deg/s

### 3.2.2 実験に使用する箒

本論文で使用する箒に関して述べる．6種類の箒の図を Fig. 3.4 に示す．箒は3種類の毛先と2種類の長さの柄によって構成されている．Fig. 3.4 中の a,d の毛先は自在箒であり，b,e はスポンジ，e,f はブラシとなっている．また，a,b,c は短い柄を各

毛先に装着したものであり，d,e,fは長い柄を装着したものである．各箒によって若干長さが異なるのは，毛先側の装着具の長さが異なるためである．これらの箒は特




Fig. 3.4 Brooms used for the experiment

別に作成したものではなく，既製品である．今後，aを短自在箒，bを短スポンジ，cを短ブラシ,dを長自在箒，eを長スポンジ，fを長ブラシと呼ぶ．

### 3.3 実験に用いるソフトウェア

#### 3.3.1 システムの概要

このシステムにおける箒の使用方法の学習方法について説明する。Fig.3.5 にデータの流れを示す。赤い矩形はデータを表し、青い矩形は実験環境内の機器を表す。また、白い矩形は複数のプログラムが相互通信しながら一つの役割を果たすモジュールである。まず、Experience Database に数種類の箒の点群、毛先の角度  $\theta_{database}$ 、毛先の弾性  $\alpha_{database}$  とその箒の使用方法  $\omega_{database}$  のセットが格納されている。ここでいう箒の使用方法とは深層学習で用いられる重みパラメータのことである。次にデータベースに存在しない形状の箒の点群が与えられる。Similarity Calculator は、その与えられた箒と Experience Database に保存されている箒の類似度  $s$  を計算する。具体的な計算の方法については第 4 章で説明する。類似度計算機はデータベース内の箒の中から最大の類似度  $s_{max}$  を有する箒を見つけ出し、そのパラメータ  $\omega_{max}$  を Broom Network に送る。

具体的な Broom Network の構造に関しては Fig.3.12 および 5.4.2 節で述べる。箒の使用方法  $\omega_{max}$  を読みこんだ後に、追加の少量の教師データ  $D_{extra}$  を読み込み、学習を行うことで与えられた箒の使用方法を学習する。

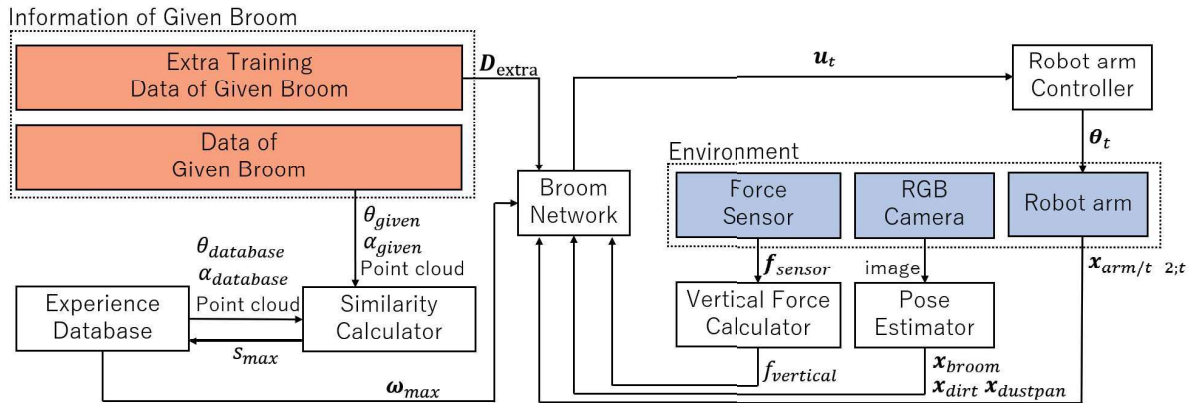


Fig. 3.5 Signal flow in the system



### 3.3.2 ロボットアーム手先速度制御システム

Fig.3.5 内の Robot arm Controller の機能について述べる．このモジュールはロボットアームの手先目標速度  $\mathbf{u}_t$  を受け取り，7つのモータの目標角速  $\boldsymbol{\theta}_t$  へ変換を行う．さらにロボットアームに安全のために搭載されている電磁ブレーキの開閉などの安全機能に関してもこのモジュールが制御を行う．このシステムにおけるモジュールの制御周期は 40Hz である．

このモジュールが行っている具体的な計算について述べる．まず，手先速度  $\mathbf{u}_t$  を受け取る．このプログラムは手先速度の受信に関しては別のスレッドで受け取り，キューに入れる．キューのサイズは 1 に設定されているため，処理前に次の  $\mathbf{u}_t$  が到着した場合には，新しい値に置き換えられる．これにより，PC 内の処理や通信の遅れによる，ロボットアームの動作への影響を最小限に抑え，40Hz の周期で目標角度を送信することが可能となる． $\mathbf{u}_t$  は速度を表す  $\dot{x}, \dot{y}, \dot{z}$  と各軸回りの角速度を表す  $\dot{r}, \dot{p}, \dot{w}$  で構成されている．

このモジュールでは  $\mathbf{u}_t$  を用いて，手先速度を関節角速度  $\dot{\boldsymbol{\theta}}$  へ変換する．まず，現時刻におけるヤコビアンを計算する．ヤコビアンの定義は一樣ではなく，ロボット分野では行列のことを指し示し，機械学習の分野では，その行列の行列式のことを指すが，本研究ではロボット分野の定義を採用する．そのため，本研究においてはヤコビアンとはロボットの関節角速度から手先速度へ変換するときに使用される行列のことで，行列の各要素に手先位置を関節角度で偏微分したものを要素に持つ．

ヤコビアン  $J$  の逆行列を求め，その行列に  $\mathbf{u}_t$  を右からかけることにより，関節角速度  $\dot{\boldsymbol{\theta}}$  を求めることが出来る．ただし， $\mathbf{u}_t \in R^6, \dot{\boldsymbol{\theta}} \in R^7$  であるため，ヤコビアンは  $J \in R^{6 \times 7}$  となり，正則行列ではない．そこで，逆行列の代わりにムーアペンローズの疑似逆行列  $J^\dagger$  を計算に用いる． $J^\dagger$  は式 (3.1) で得られる．

$$J^\dagger = (J^T J)^{-1} J^T \quad (3.1)$$

$J^\dagger$ を用いることで、所望の手先速度  $\mathbf{u}_t$  から関節角速度  $\dot{\boldsymbol{\theta}}$  を式 (3.2) により計算することが出来る。

$$\dot{\boldsymbol{\theta}} = J^\dagger \mathbf{u}_t \quad (3.2)$$

ロボットコントローラは関節角度を受け取るので、 $\dot{\boldsymbol{\theta}}$  を積分し  $\boldsymbol{\theta}$  を得る。得られた  $\dot{\boldsymbol{\theta}}$  と  $\boldsymbol{\theta}$  がロボットの動作範囲内であることを確認し、ロボットコントローラへ送信する。

### 3.3.3 計測システム

#### VR システムを用いたロボット制御システムの構築

教師データは実際にロボットアームを動かして作成する。また、本研究で使用するロボットアームは人協働用のロボットアームではないため、可動範囲外から操作する必要がある。以上2点を考慮して、VR システム (HTC Vive Pro) をモーションキャプチャとして使用することで、ロボットアームを直感的に操作可能なシステムを作成した。以下ではシステムの構成について述べる。Fig.3.6 は VR システムを使用してロボットを操作し、教師データを作成している様子である。人間が手に持っているコントローラの変位に追従するようにロボットアームの手先は移動する。その間に、教師データを構成するデータを記録することによって、教師データは作成される。

本研究で用いた VR システムの位置観測センサおよびコントローラを Fig.3.7 に示す。Light house と呼ばれる位置観測センサは赤外線を照射し、コントローラ表面の反射材からの赤外線が返ってくる時間を求めることにより、コントローラの位置と姿勢を計測することが可能である。位置観測センサは 1.8m の三脚上に載っており、このセンサは操作者を挟んで対角線上に2つ設置してある。それにより 3×3m の範囲にあるコントローラの位置と姿勢を計測することが出来る。また、コントローラ




Fig. 3.6 Teleoperation using virtual reality tool



(a) Virtual reality position sensor



(b) Virtual reality controller

Fig. 3.7 Virtual reality observation system

には4つのボタンが設置されており，教師データのロギング開始および終了させるために使用される．サンプリング周期は最大 250Hz であるが，本研究では 100Hz で使用している．


Fig.3.8a に、VR システムによって構築された位置観測センサと VR コントローラの座標系を示す。位置観測センサと VR コントローラはそれぞれ2つずつ表示されている。この座標系の原点は手前の位置観測センサが原点となる。

一方、Fig.3.8b にロボットアームの座標系を示す。こちらの座標系はロボットアームの根元を原点とし、ロボットアームの手先の座標 (Fig.3.8b 内 Tool frame) ともう一つの座標 (Fig.3.8b 内 Target frame) が存在する。Target frame はロボットアームの手先の目標座標を示しており、Tool frame に VR コントローラの差分を加えたものが Target frame となる。Tool frame から見た Target frame の差分に対して、フィードバック制御を行い、指令値となるような目標手先速度  $u_t$  を計算する。これを Robot arm controller モジュールに送ることにより、VR コントローラに追従するようなロボットアームの手先制御を行っている。


## RGB カメラを用いた清掃対象物計測システム

上記の章ではロボットを制御するために VR システムをモーションキャプチャとして利用し、操作者が把持するコントローラの座標を計測する方法について述べた。本章ではそれ以外の計測システムについて述べる。Fig.3.5 内の Pose Estimator によって本章で説明する処理は行われる。また、計測されたデータは教師データの作成に用いられる。Fig.3.5 内の Pose Estimator は清掃対象物と AR マーカーの位置と姿勢を推定する。実験環境には RGB カメラが設置されており、箒の先端とちり取りの横に設置された AR マーカー、および机上の清掃対象物を撮影することが出来る。

まず、AR マーカーによる箒先端とちり取りの座標の検出方法について述べる。Fig.3.9a に AR マーカーを示す。黒地に白い複数の白い矩形が並べられており、矩形のパターンは AR マーカーごとに一つ一つ異なる。マーカーをカメラで撮影することによりカメラから見たマーカーの座標と ID を取得することが可能である。ただし、カメラのレンズは中心から外側に向かって収差が発生し、画像が歪んでしまう。



(a) Virtual reality devices coordinate system




(b) Robot arm coordinate system

Fig. 3.8 Coordinate system

これにより，マーカー座標の推定の精度の低下を招くため，事前にカメラの内部行列を求め，カメラの収差を補正した．また，マーカーが小さいと，検出が難しくなるため，今回は  $60 \times 60\text{mm}$  のものを使用した．Fig.3.9b に検出結果を示す．2つのマーカー上に座標系が描画されていることから，適切にマーカーを検出できていることが分かる．AR マーカーの検出処理には Garrido らの手法を用いた<sup>[91]</sup>．

次に，画像処理を用いた清掃対象物の位置の検出方法について述べる．Fig.3.10 に処理の流れと結果を示す．上記の AR マーカーで使用したのと同じ画像を入力とする．まず，RGB 色空間を HSV 色空間へ変換し，清掃対象物が残るように，H,S,V の各チャンネルにおいて，一定範囲の輝度値を有するピクセルだけを抜き出し，二



(a) AR marker



(b) Input image from RGB camera

Fig. 3.9 AR maker and detected result

値化を行う．HSV 色空間は色相（Hue），彩度（Saturation），明度（Value）の3つの成分からなる色空間である．RGB 色空間から変換した理由は，周囲の物体と清掃対象物の分離がRGB 色空間で行うよりも精密に分離することが可能なためである．

次にオープニング処理とクロージング処理を行う．オープニング処理とは収縮処理の後に膨張処理を行う処理のことで，画素値が0（黒）の領域のノイズ除去のため

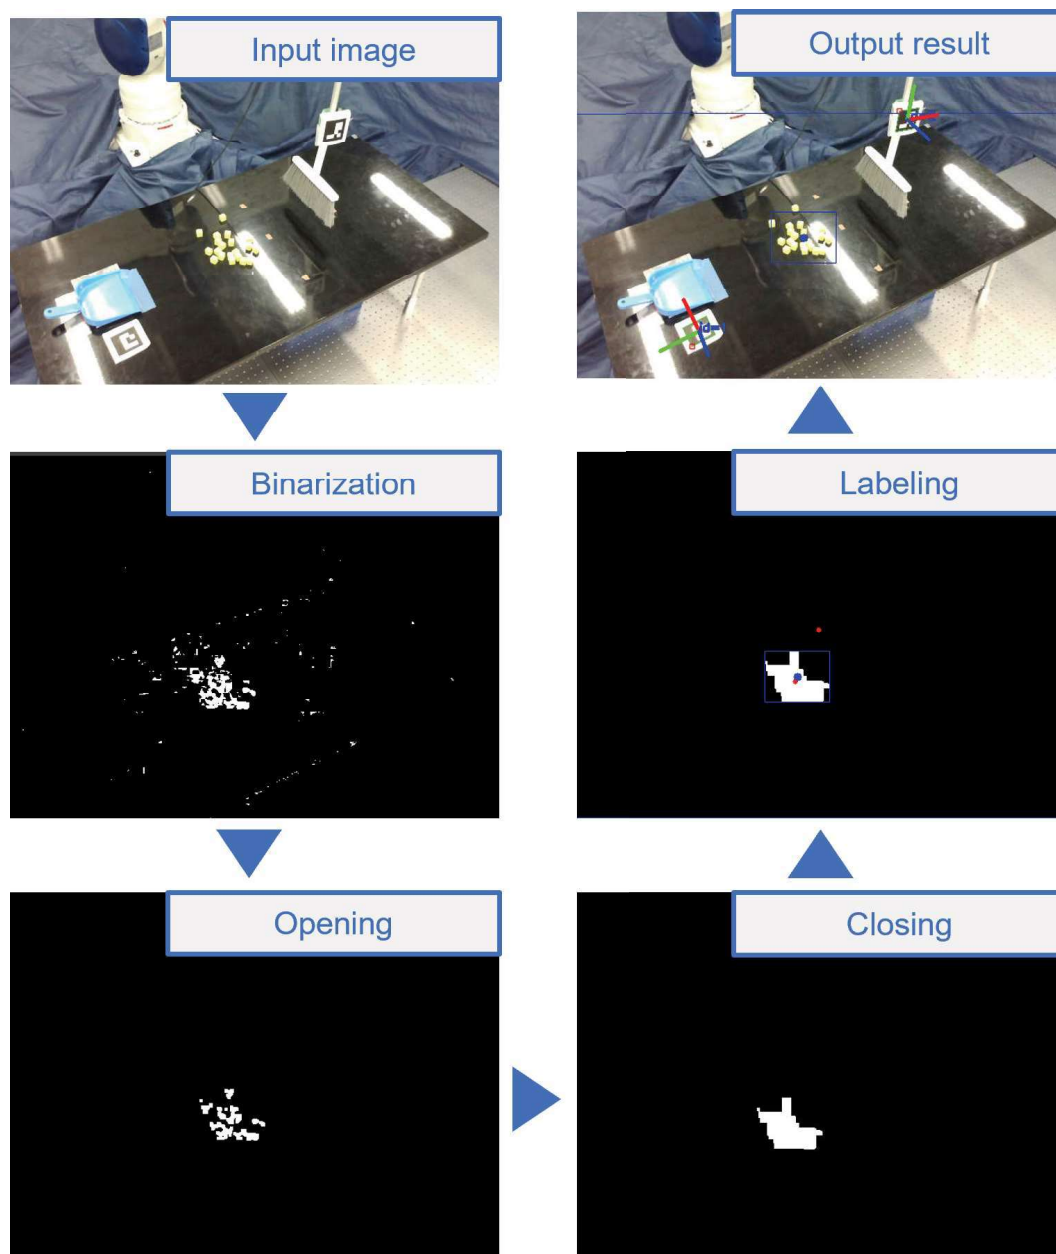


Fig. 3.10 Image processing for dirt position

めに使用する．一方，クロージング処理はオープニング処理とは処理の順番が異なる手法であり，膨張処理の後に収縮処理を行うことで，画素値が1（白）の領域のノイズ処理のために使用する．本研究においては，ノイズ処理ではなく，複数ある清掃対象物を一塊として結合するために使用される．

収縮処理とは二値化された画像に対して、カーネルと呼ばれる行列を1画素ずつスライドさせ、行列に含まれる画素の画素値がすべて1（白）であれば1となり、そうでなければ0（黒）として元画像を上書きする。この処理の結果として白い画素が画像に占める領域が減少する。ノイズは占める画素の領域が小さいため、収縮処理をすることにより、消滅させることが可能である。

膨張処理は収縮処理の逆の処理である。行列内の画素値に一つでも1が含まれれば、行列内に含まれる全ての画素値を1（白）にして出力する。この処理の結果として白い画素が画像に占める領域が増加する。この処理では収縮処理によってノイズを削除した画像の減少してしまった白い画素の領域をもとに戻すことが可能である。

最後にラベリング処理を行う。この処理により、付近の画素値が1（白）である画素を結合し、塊として検出する。これにより、清掃対象物を一つの画素の塊として認識し、その塊を矩形で近似し、矩形の重心を計算する。Fig.3.10では青い矩形で清掃対象物が囲まれ、その重心が青い点により描画されていることが分かる。

画像処理により得られるのは、清掃対象物の机上の位置のみである。ちり取りと清掃対象物は机にのっているため、2つの物体の $z$ 座標は同じ値となる。そのため、 $z$ 座標はちり取りのARマーカーと同じ値を使用する。この処理により清掃対象物の座標を測定する。

### 3.3.4 学習システム

#### 教師データ作成システム

深層学習の学習のための教師データの作成手法について述べる。 $i$ 個めの教師データセット  $D_i = \{(\mathbf{o}_t^{(i)}, \mathbf{u}_t^{(i)})\}$  は時刻  $t$  における観測データ  $\mathbf{o}_t$  と対応する手先速度指令  $\mathbf{u}_t$  をデータポイントとする集合である。データポイントは1つの入力と出力のペアであり、これを複数集めたものをデータセットと呼ぶ。 $\mathbf{o}_t$  には時刻  $t-2$  時点



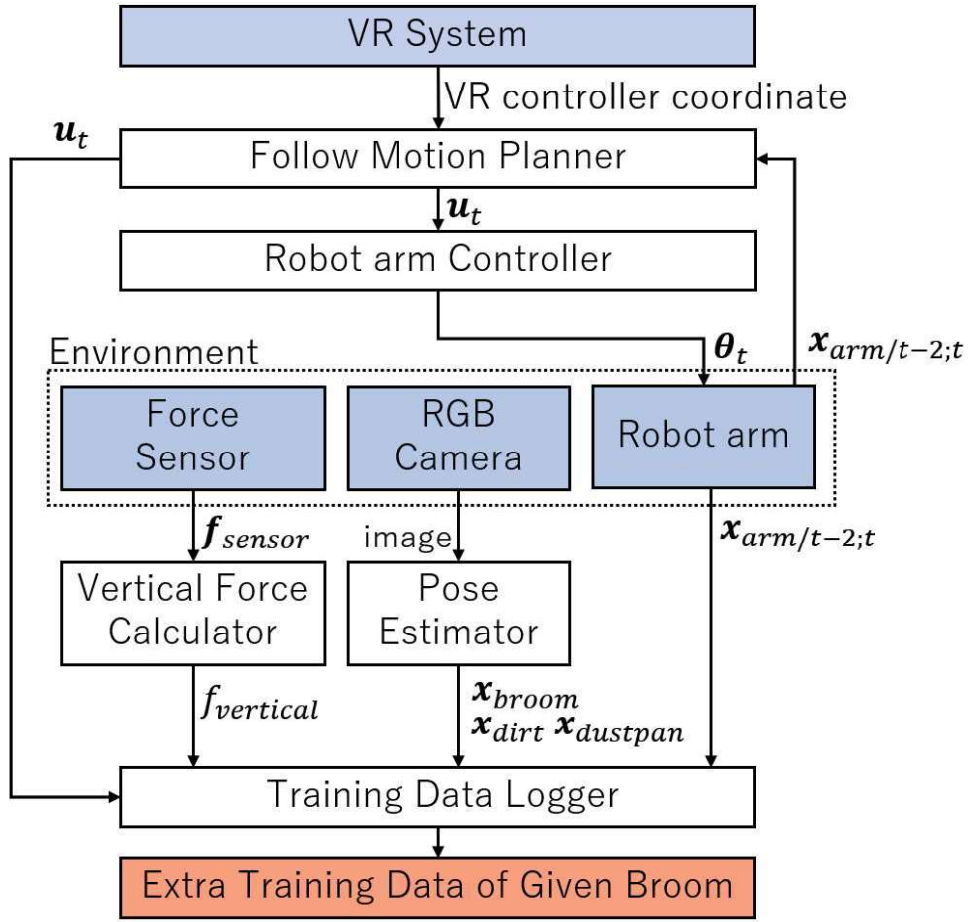


Fig. 3.11 Signal flow in the training data set collection

から  $t$  のロボットアームの手先座標  $\mathbf{x}_{arm/t-2;t} \in \mathbb{R}^{18}$ , 箒に取り付けられた AR マーカの座標  $\mathbf{x}_{broom} \in \mathbb{R}^6$ , 対象物の中心の位置  $\mathbf{x}_{dirt} \in \mathbb{R}^3$ , ちり取りの AR マーカの座標  $\mathbf{x}_{dustpan} \in \mathbb{R}^6$ , 力覚センサで検出された垂直方向の力  $f_{vertical} \in \mathbb{R}^1$  が含まれる. 教師データセットの作成は実際にロボットを操作者が動かし, 各時刻における  $\mathbf{o}_t$  と  $\mathbf{u}_t$  を計測することによって行われる. 教師データセット作成時の情報の流れを Fig.3.11 に示す. Fig3.11 内の青い矩形はハードウェアであり, 赤い矩形は教師データセットである. また, それ以外の白い矩形はモジュールを示す. まず, 5.2 章で述べた VR システムにより, VR コントローラの座標を取得する. コントローラの座標は Follow Motion Planner モジュールに送られる. このモジュールは 5.2 章で述

べた通り座標変換を行うことで、コントローラにロボットアームの手先が追従するための偏差を計算し、ロボットアームの手先の速度指令値を出力する。Robot arm Controller は手先速度を関節角速度へ変換するためにヤコビアン疑似逆行列を計算し、与えられた手先速度をロボットアームが受信可能な関節角速度へ変換する。ロボットアームは受信した関節角速度により、手先速度を変化させる。これにより実験環境が変化する。具体的には、ロボットアームの手先位置が変化し、また、ロボットアーム手先の箒を介して清掃対象物の位置が変化する。この変化した環境を、力覚センサとカメラを用いて、机から箒に伝わる力や箒のARマーカー、清掃対象物、また、ちり取りの座標を計測する。Training Data Logger モジュールはそれらのデータポイントを集め、出力する。また、このモジュールにおける教師データの記録開始・終了はVRコントローラのボタンから制御することが可能である。

## 深層模倣学習システム

環境の状態  $\mathbf{o}_t$  を入力として受け取り、ロボットアームの手先速度  $\mathbf{u}_t$  を出力する。深層学習の構造について述べる。本研究において深層学習の計算を行うモジュールを Broom Network と呼ぶ。Broom Network のアーキテクチャを Fig.3.12 に示す。順伝播型ニューラルネットの構造を有し、入力層は34次元、中間層は30次元、出力層は6次元となっており、全8層を有する。各層は全結合となっており、活性化関数に正規化線形関数、損失関数は最小二乗誤差を使用している。また、ミニバッチサイズは2であり、最適化アルゴリズムにミニバッチ確率的勾配降下法を用いる。Broom Network に教師データが入力される前に、教師データに対して行われる前処理が行われており、各教師データは移動平均フィルタ ( $N = 10$ ) によりノイズを取り除いた後、データ中の値の最大値が1、最小値が-1になるように正規化される。




Fig. 3.12 Architecture of the deep imitation learning

### 3.4 まとめ

この章では、本研究で使用する実験環境とシステムの詳細について述べた。まず、7軸ロボットアームと実験に使用する箒の詳細について説明した。次に、システムは、さらに細かい複数のモジュールから構成されていることを説明し、各モジュールの入出力やデータの流れについて述べた。さらに、個別のプログラムについて説明を行った。最初は、ロボットアームの手先速度制御するためのモジュールについて説明した。7軸ロボットアームの手先目標速度から、各関節速度へヤコビアンを使用して変換する手法について説明した。次に、直感的に教師データを作成するために、バーチャルリアリティシステムをモーションキャプチャとして利用したことを述べた。実験環境中には、RGBカメラが設置してあり、それを利用して清掃対象物と箒とちり取りを計測する。計測に用いた2つの手法について説明した。1つはARマーカであり、もう1つは清掃対象物を検出するための画像処理アルゴリズムであった。最後に、道具の使用方法の学習システムについて説明した。まず、教師データを作成するためのシステムについて述べた。このシステムが、どのようなモジュールの組み合わせによってできているのかを説明した。さらに、このシステムにより、ロボットアームを操縦者が操作し、その時の操作データと実験環境の観測データから、教師データのもととなるデータが記録されることを説明した。次に、

道具の使用方法を学習する深層模倣学習システムの詳細について述べた。ここでは、入力層が 34 次元、中間層が 30 次元、そして、出力層がロボットアームの手先速度を表す 6 次元となっていることを説明した。また、活性化関数は ReLU であることも述べた。

## 第4章 箒の類似度の評価システム

### 4.1 はじめに

この章では、提案手法の一部である道具の類似度を評価するアルゴリズムについて説明する。まず、道具の類似度を評価するシステムの概要について述べる。ここでは、本研究で類似度を評価するアルゴリズムを新たに作成する必要性、およびアルゴリズムの概要について述べる。次にアルゴリズムの入力の一つである、箒の毛先の弾性の処理について述べる。ここで、力覚センサを用いた毛先反力の時系列データの計測実験と、そのデータから、弾性への変換方法について述べる。さらに、計測実験の妥当性についても検証を行う。さらに、アルゴリズムの入力の一つである、点群に関する処理について述べる。ここでは、点群の作成方法をはじめに説明し、2つの点群アルゴリズムを利用した類似度の評価方法について説明する。そのあとにアルゴリズムの入力の一つである箒の毛先角度についての評価方法について述べる。最後に、類似度の計算手法について述べ、計算された類似度を示し、その妥当性について説明する。

また、本研究では学習する道具として、清掃道具である箒に着目した。しかし、類似度を評価し、それをもとに、利用すべき経験を決定し、深層模倣学習の高速化を図るという仕組みは、箒に限らず利用可能である。本研究ではこれ以降、箒を対象にしてシステムを構築するが、この仕組み自体は、幅広い道具への応用が期待できると考えている。

## 4.2 類似度評価システムの概要

現在、ある物体が似ているかどうか、もしくは同じカテゴリに属する物体かどうかを判定する手法として機械学習を用いた分類手法がある。しかしこれらの手法は箒の種類の判定には適さないと考えられる。まず、機械学習のための多くの教師データを準備する必要がある。多くの物体分類のデータセットが公開されており利用することが可能であるが、公開されているデータセットを使用するためには大規模な学習器が必要がある。提案手法では箒の分類のみを対象とするので大規模な学習器を構成する必要はない。また、事前に学習済みのモデルも公開されているが、これら既存のモデルは汎用的な目的のために学習されており、使用しても箒の種類まで特定することは難しい。さらにこれらの既存の手法の多くは画像が入力である。そのため、画像に写っている箒の実際の外形が大きいのか、もしくは近くで写っているため画像に占める箒の領域が大きいのかを判別することが出来ない。したがって、箒の外形の大きさを考慮して分類することができない。そこで、本研究では新しい手法を考案した。この手法は数値的な手法であり、機械学習のためのデータセットを必要とせず、計算量も機械学習による手法と比較して少ない。また、入力には箒の形状を表現する点群や物理特性値である。そのため、実際の箒の外形の大きさや毛先の柔らかさを考慮して、箒の類似度を計算することが可能となっている。

提案する類似度の計算アルゴリズムの概略について述べる。また、計算アルゴリズムを Fig.4.1 に示す。このアルゴリズムは2つの箒について類似度を計算するものである。2つの箒どうしが似ていれば類似度は大きく、似ていなければ類似度は小さくなる。そのため、もし2つの箒が同一のものであれば、類似度は $\infty$ となる。このアルゴリズムは入力として、2つの箒のそれぞれについて、点群と毛先の角度および反力の3つの値を受け取る。それら3つの入力から、類似度計算のための4つの指標を計算する。4つの指標とは外形の大きさの差  $\Delta v$ 、慣性モーメントの差  $\Delta I$ 、毛先の角度の差  $\Delta \theta$ 、毛先の弾性の差  $\Delta \alpha$  である。以下の節ではそれぞれの計算方法




Fig. 4.1 Similarity Calculation algorithm

について述べる.

### 4.3 箒の毛先反力からの類似度要素の取得

類似度を計算するための4つの指標の内の1つである、箒の毛先反力の計測方法と計算方法について述べる. 計測するために、箒を Fig.3.1 のように設置する. ロボットアームの手先と箒の間には6軸力覚センサが設置されている. 6軸力覚センサを Fig.4.2 に、スペックを Table 4.1 に示す. この力覚センサは直径が34mmのものであり、力覚センサの表面に垂直な方向が $z$ 軸となっており、 $z$ 軸に直角となるように $x$ と $y$ 軸が設けられている. 機械的特性としては $x$ ,  $y$ 軸の力が $\pm 50\text{N}$ までの力を測定可能となっており、 $z$ 軸は $100\text{N}$ である. 本実験では、ロボットが計測を開始する初期姿勢において、力覚センサの $x$ 軸が机に対して垂直上向きになるようにロボットの手先に取り付けている.

毛先の反力を測定するために、Fig.4.3に示すような箒の毛先と机の位置関係になるようにロボットの手先を移動させる. 具体的には箒の毛先が机から $0.045\text{m}$ に位置するようにロボットの手先位置を調整する. また、毛先は机に対して $45$ 度の角度




Fig. 4.2 Force sensor

Table 4.1 6 axes force torque sensor

機械特性	$F_x$	$\pm 50 \text{ N}$
	$F_y$	$\pm 50 \text{ N}$
	$F_z$	$\pm 100 \text{ N}$
	$M_x$	$\pm 3 \text{ Nm}$
	$M_y$	$\pm 3 \text{ Nm}$
	$M_z$	$\pm 3 \text{ Nm}$
電気的特性	分解能	$\pm 1/1000$
	サンプリング周波数	1.2 kHz
	電源	DC5.0V $\pm 5\%$

に設定する．これは毛先が机と垂直の場合，座屈を起こし適切に計測を行えなくなることを防ぐためである．次に，ロボット手先の  $z$  軸だけを振幅 0.06m の  $\cos$  波で動作させ，毛先が机に接触し，たわみ，また机から離れるようにする．そのため，箒の毛先は 0.015m だけ押し込まれることになる．この動作を 20 回繰り返すことに






Fig. 4.3 Experimental environment for reaction force measurement

より，20 回分の反力の時系列データを得ることが出来る．このデータを平均し，2 次関数で近似する．このときの 2 次の係数を弾性として使用する．このとき，与えられた箒の弾性を  $\alpha_g$ ，データベース内の箒を  $\alpha_d$  として類似度の計算に使用する．

箒の毛先が机に押し込まれる量を 0.005, 0.015, 0.025m と変えて，反力を計測し，そこから弾性を計算したときのグラフを Fig.4.4 に示す．この図によると，どの押し込み量を使用した場合においても，自在箒，ブラシ，スポンジの順に係数が大きくなっていることが分かる．したがって，0.005 m 以上の押し込み量により，ほうきを判別可能であると考えられる．ただし，0.025m より押し込み量を大きくした場合，毛先の付け根のプラスチックの部分が床に接触してしまい，正しく反力を計測することが出来なかった．類似度の計算には押し込み量 0.0015m の値を使用している．

## 4.4 箒の点群からの類似度要素の計算

このアルゴリズムにおける点群を利用した類似度要素の計算について述べる．アルゴリズムには 2 つの点群が入力される．1 つ目の点群は与えられた箒の点群  $p_g$

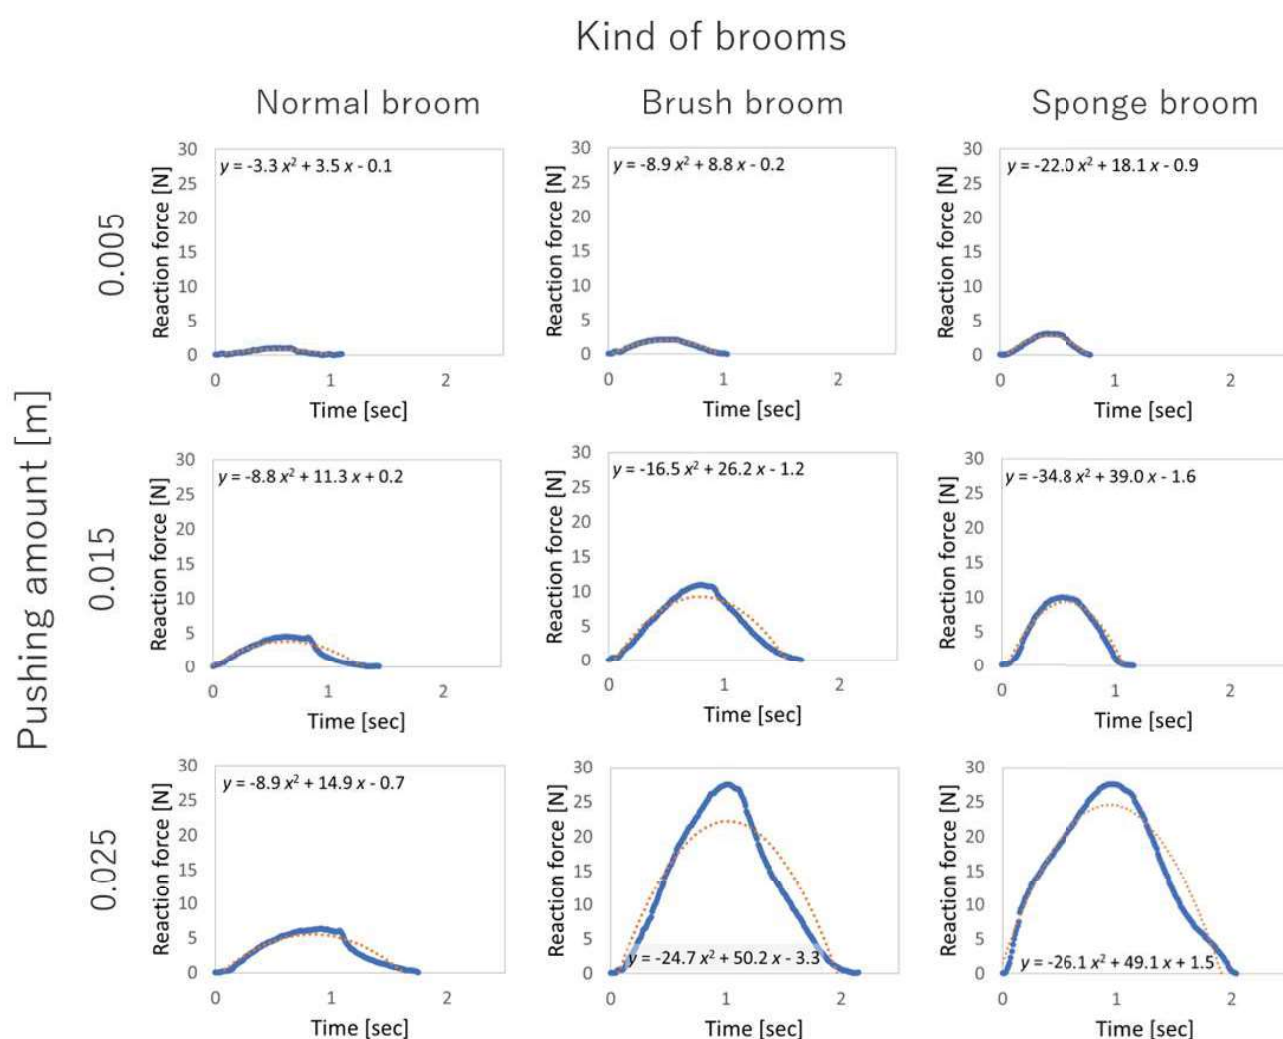


Fig. 4.4 Reaction force of brooms

である．もう一つはデータベース内に登録されている点群  $p_d$  である．この2つの点群に関して，どのくらい似ているか計算を行う．今回，点群を作成するために，3DCADにより，各箒を作図し，それを点群の形式で出力することにより箒の点群を作成した．長自在箒の3DCADをFig.4.5に，点群をFig.4.6に示す．




Fig. 4.5 CAD of the long normal broom




Fig. 4.6 Point cloud of the long normal broom




Fig. 4.7 Principle component analysis

#### 4.4.1 慣性モーメントの計算

2つの箸の外形が似ているかどうかの計算を行うための計算を説明する．これは Fig.4.7に示すような基底を作成し，各軸回りの慣性モーメントの大きさが結果として出力される．各軸ごとの慣性モーメントの差が大きければ，形状が異なり，小さければ形状は近いと考えられる．点群  $p_g, p_d$  に対して多変量解析の手法である主成分分析（PCA）を行うことでそれらの点群の重心と基底を得る．このとき基底は最も点群の分散が大きい方向を x 軸，その次に分散が大きい方向を y 軸とし，それらに直行する方向を z 軸とする．また点群の重心は基底の原点となる．したがって，PCA を利用することで点群に一意的に基底を作成することができる．その後，作成した基底まわりの慣性モーメントを計算する． $p_g$  から慣性モーメント  $I_{xg}, I_{yg}, I_{zg}$  を得る．また同様にして  $p_d$  からは慣性モーメント  $I_{xd}, I_{yd}, I_{zd}$  を得る．

#### 4.4.2 有向バウンディングボックスの計算

2つの箸の外形が似ているかどうかの計算を行うための計算を説明する。これは点群をすっぽりと包む Fig.4.8 に示すような直方体を、点群ごとに作成し、それらの直方体の体積の差を計算することにより、外形がどのくらい似ているかを計算する。例えば、長い自在箸と短いブラシでは差が大きくなり、長いブラシとでは差が小さくなると考えられる。このような点群を包み込む直方体を作成するために有向バウンディングボックス (Object Oriented Bounding Box) を使用する。有向バウンディングボックスは物理シミュレータ内で物体の形状をバウンディングボックスで近似することにより計算を高速化するためのものである。計算方法としては、主成分分析で得られた  $x, y, z$  軸の中で、基底から最も遠い点をそれぞれ見つける。その点に対して直方体の壁となる平面を6つ作成する。たとえば、 $x$  軸から正の方向と負の方向で最も遠い点に対して  $y-z$  軸に平行な平面を生成する。これらの平面が交わる点を得ることによりバウンディングボックスを作成している。ただし、有向バウンディングボックスのみでは、 $x, y, z$  方向の長さが同じ箸と板が似ていることになってしまうため、前述の慣性モーメントを利用し、各軸の点群の偏りを類似度の計算に含めている。




Fig. 4.8 Object oriented bounding box

## 4.5 箒毛先の角度からの類似度要素の計算

このアルゴリズムにおける箒の毛先角度を利用した類似度要素の計算について述べる．ここで言う箒の毛先角度とは，Fig.4.9 に示すような箒の柄と毛先のなす角のことである．この角度を3種類の毛先それぞれに対して計測を行った．計測の結果，自在箒は柄と毛先が同じ方向を向いているので  $0^\circ$  となっており，また，ブラシとスポンジはそれぞれ  $36^\circ$  と  $42^\circ$  であった．計測は分度器により行った．新たに与えられた箒の毛先角度を  $\theta_g$  と定義し，データベース内に登録されている毛先角度を  $\theta_d$  とする．




Fig. 4.9 the angle of the broom tip

## 4.6 箒の類似度の計算結果

これらの計算手法によって得られた値の差分を式 (4.1)~(4.6) により計算する.

$$\Delta v = v_g - v_d \quad (4.1)$$

$$\Delta I_x = I_{xg} - I_{xd} \quad (4.2)$$

$$\Delta I_y = I_{yg} - I_{yd} \quad (4.3)$$

$$\Delta I_z = I_{zg} - I_{zd} \quad (4.4)$$

$$\Delta \theta = \theta_g - \theta_d \quad (4.5)$$

$$\Delta \alpha = \alpha_g - \alpha_d \quad (4.6)$$

これらの差分を式 (4.7) に代入することによって2つの箒の類似度  $s$  を計算する.

Table 4.2 The calculation result of similarity

		long			short		
		broom	brush	sponge	broom	brush	sponge
long	broom	$\infty$	0.2591	0.3080	0.0622	0.0556	0.0563
	brush	-	$\infty$	0.5811	0.0774	0.0687	0.0699
	sponge	-	-	$\infty$	0.0702	0.0630	0.0645
short	broom	-	-	-	$\infty$	0.3718	0.3450
	brush	-	-	-	-	$\infty$	0.8144
	sponge	-	-	-	-	-	$\infty$

$$s = \frac{1}{\sqrt{w_1\{\Delta I_x^2 + \Delta I_y^2 + \Delta I_z^2\} + \Delta v^2 + w_2\Delta\theta^2 + w_3\Delta\alpha^2}} \quad (4.7)$$

式 (4.7) における重み  $w_1$ ,  $w_2$ ,  $w_3$  はそれぞれ 0.1, 0.1, 0.0001 であり, 桁合わせのために使用される.

これによると短スポンジは短ブラシに対して最も類似度が高く 0.8144 であった. また, 長自在箒は長いスポンジに対して最も類似度が高く 0.3080 であり, 次いで長ブラシに対して類似度が高く 0.2591 であった. 一方, 短い自在箒に対しては類似度が 0.0622 となっており, 形状が大きく異なると低い類似度を算出していることがわかる. なお同じ箒では, 類似度を  $\infty$  としている.

## 4.7 まとめ

この章では, 2つの道具間の類似度を計算するアルゴリズムについて説明した. アルゴリズムは4つの要素に分けることができる. 要素はそれぞれ, 箒の毛先の角度



と弾性，および慣性モーメントと外形の大きさである．このうち，弾性は実験的に計測し，また，慣性モーメントは外形の大きさについては，点群を処理することにより得ることを説明した．類似度の計算式は式 4.7 で表され，最終的な箸の類似度は Table 4.2 に示した．また，短ブラシと短スポンジ間の類似度が大きく，また，短スポンジと長自在箸間の類似度が小さいことから，類似度の計算が妥当であると判断した．

## 第5章 実験

### 5.1 はじめに

実験により，提案手法の有効性の検証を行う．実験で検証すべきことは3つある．1つは，類似度が大きい道具の使用方法を読み込むことにより，深層学習の学習回数をどの程度減少させられるかということである．2つ目は，そのようにして少ない学習回数で獲得した道具の使用方法が適切なものかどうかを検証することである．3つ目は，実際の清掃現場における清掃能力である．

1つ目の学習回数の削減を検証する実験では，類似度が大きい，もしくは小さい道具の使用方法を読み込んだ場合と，それらを読み込まず，ゼロから学習した場合の深層学習のテスト誤差の推移を調べる．テスト誤差が0.002以下になった学習回数を比較することにより，類似度の大小と学習回数との関係性を調べる．また，テスト誤差が0.02以下になった学習回数に関してt検定を行い，統計的な提案手法の有意性を調べる．

2つ目の学習した使用方法の動作を検証する実験では，2つの実験を行う．1つ目は長自在箒の使用方法を学習する際に，長スポンジの使用方法を読み込んだ場合の動作検証であり，2つ目は短スポンジの使用方法を学習する際に，短ブラシの使用方法を読み込んだ場合の動作検証である．この実験では，清掃対象物として1cm角の黄色い木材を使用した．

3つ目の実際の現場における清掃能力を検証する実験では，黄色い木材ではなく，工芸用の石と鋳型で使われる珪砂を清掃対象物として清掃実験を行う．2つ目の実験と同様に，長自在箒を用いて清掃を行った場合に，どれくらいの清掃対象物が

ちり取りに移動されたかを検証する．これにより，実際の清掃現場における清掃能力を調べる．また，細かい砂の清掃に適していると思われるモップを使用する実験も行うことで，道具による清掃能力の変化についても検証する．

## 5.2 使用方法の学習における時間短縮実験

まず，1つ目の実験として，経験を用いることで高速に学習可能かどうかを検証する．箒の使用方法の学習において，道具間の類似度を評価し，最も類似度が高い道具を選択する．その道具の使用方法を表す深層学習の重みパラメータを，新しい道具の使用方法を学習する深層学習の重みパラメータの初期値として流用することで，学習時間を短縮することが可能かどうか検証する．まず，提案手法を用いない場合と比較してどれくらいの高速化が可能かを検証する．具体的には，長自在箒を学習する際に，長スポンジの使用方法を初期値として流用した場合と，しなかった場合の差を検証する．差の検証にはテスト誤差が0.002を初めて下回るまでの学習回数を比較する．また，それぞれの学習を5回ずつ行い，テスト誤差の分散についても検証する．また，統計的に提案手法の有意さを示すために，統計的仮説検定の一つであるt検定を行う．t検定に使用するテスト誤差のみ閾値が0.002ではなく，0.02となっている理由は，12000回の学習回数の中で0.002までテスト誤差が収束しなかった実験があり，5回すべての実験結果を使用できなくなったためである．そのため，閾値を大きくし，そのときの学習回数を用いて検定を行った．

2つ目の実験として，類似度が高い箒の重みパラメータを初期値として読み込んだ場合，類似度が低い箒を読み込んだ場合，初期値を使用せずゼロから学習を行った場合を比較することにより，類似度が高速化に及ぼす影響について検証する．具体的には，長自在箒に対して類似度が大きい箒として，長スポンジを用いる．類似度が小さい箒として，短いスポンジを用いる．これらの類似度はそれぞれ，0.308と0.056であり，類似度が十分異なるために，比較対象として実験に用いた．また，初

期値を用いない場合は、長自在箒の学習をゼロから行う。実験方法は、こちらでもテスト誤差を記録し、テスト誤差の値が0.002を初めて下回った学習回数を比較する。3つの実験における学習回数の大小関係により、類似度と高速化の関係性を調べる。

まず、学習に使用される教師データの詳細について述べる。Fig.5.1に-1～1に正規化された長自在箒の教師データを示す。上から順にFig.5.1aに箒のARマーカのx,y,x座標の時系列データ、Fig.5.1bに清掃対象物の机上のxy座標の軌跡、ロボットアームの手先のx,y,z座標、力覚センサの値、Fig.5.1cにそれらの観測データを受けて出力されたロボットアームの目標速度を示す。

VRシステムを使用して、ロボットで清掃を1回だけ行うことにより、Fig.5.1のような各種データを1つ得ることが出来る。

1つ目の実験結果として、長自在箒を学習する際に、スポンジの使用方法を初期値として読み込んだ場合と、ゼロから学習した場合のテスト誤差の5回分の平均値をFig.5.2に濃い線で示す。テスト誤差が0.002を下回るまでに初期値を読み込んだ場合は3044回、ゼロから学習した場合は6844回が必要であった。これは平均で56%の短縮ができたことを意味している。また、薄い領域はその学習回数の中のテスト誤差の25パーセンタイルと75パーセンタイルの値である。これはその学習回数の中のテスト誤差5回分の最大を100%、最小を0%としたときの25%の値と75%の値である。Fig.5.2によると、ゼロから学習した場合のテスト誤差は、学習初期では大きい値を取り、分散も大きい。一方、初期値を読み込んだ場合は小さい値を取り、分散も小さい。このことから、提案手法により、初期値を読み込むことによって学習回数を低減させることが可能だと考えられる。また、学習回数が6000回の付近においても、ゼロから学習したときより、初期値を読み込んだ方がテスト誤差が小さくなっていることが分かる。そのため、学習後期の傾きが緩やかな場面においても初期値の読み込みは影響を及ぼしていると考えられる。

また、テスト誤差が0.02を下回った学習回数に関してt検定を実施した。また、

その学習回数の箱ひげ図を Fig.5.3 に示す．本実験においては，Fig.5.2 の薄い領域が示すように，初期値を読み込んだ場合と，読み込まなかった場合の分散が等しくないと考えられるためウェルチの  $t$  検定を使用する．

$t$  検定の結果， $p$  値は 0.02 となり有意水準の 0.05 を下回った．そのため，初期値を読み込んだ場合と読み込まなかった場合において，それらの平均値に差がないという帰無仮説が棄却され，したがって，パラメータを読み込んだ場合の学習回数の低減に関して，提案手法の有意性を示すことが出来た．

次に 2 つの目実験として，類似度による学習における高速化の差について検証実験を行った．正規化した教師データを用いて学習を行う際に，類似度が小さい筈の学習のパラメータを初期値とした場合と，類似度が大きいものを用いた場合の学習誤差を平均フィルタ ( $N = 40$ ) により平滑化した結果を Fig.5.4 に示す．図では長い自在筈に対し，類似度が小さい短いスポンジを初期値とした場合と，類似度が大きい長いスポンジを初期値とした場合の学習時間の低減効果を示している．学習誤差が 0.002 を下回った学習回数を調べた．類似度が小さい場合は 3457 回を要したのに対して，類似度が大きい場合は 518 回となり，収束までに必要な学習回数を 85% 短縮した．本論文で使用した計算機 (Intel core-i7 8700) では 12000 回の学習回数に 11.66 分を要するので，518 回で早期に計算を終了することにより，30.19 秒に短縮可能である．これにより，清掃現場でも利用可能だと考えられる．この結果より類似度を計算し，適切な学習済みパラメータを初期値として用いることで学習時間を大きく短縮可能であると言える．また，Fig.5.4 より，長い筈に対して長いスポンジ初期値として読み込む類似度が大きい場合，短いスポンジのパラメータを初期値として読み込む類似度が小さい場合，および読み込まずゼロから学習を行った場合の学習誤差が 0.002 を下回るイテレーションはそれぞれ，518, 3457, 7553 であった．このことから，類似度が低いものを読み込んでも学習の妨げにならず，学習時間の削減が可能だと考えられる．ゼロから学習場合と比べて，類似度が小さくても初期

値を読み込んだことにより学習回数を 54%短縮をすることが出来た。

### 5.3 長自在箒を用いた清掃実験

長自在箒を対象として、実際に清掃実験を行い、提案手法の清掃能力を明らかにする。長自在箒に対して最も類似度が大きい長スポンジの使用方を、深層学習の重みパラメータの初期値として流用し、長自在箒の使用方の学習を行う。清掃対象としての木材を用いる。机の上には木材とちり取りが置いてあり、木材をちり取りへ移動させた個数により清掃能力を評価する。

次に、実験環境の条件について述べる。特に清掃対象物について説明する。実験に使用する清掃対象物の立方体を Fig.5.5 に示す。本実験の清掃対象物には、この 1cm 角の立方体 20 個を用いる。また、1つ 1.65g の質量がある。これは一般的な清掃現場においては存在しないかもしれない。しかし清掃対象物の表面摩擦が極端に大きくもなく小さくもない、また、1つ1つの質量が同じという特性は清掃能力の評価という点においては適していると考えられるため本実験で使用する。また、黄色に塗装されているため、画像処理が行いやすく、得られた座標についてもノイズが混じりにくいと考えられる。そのため、計測ノイズに影響されることなく、純粋な深層学習の清掃能力について評価できることも、この立方体を清掃対象物とする理由である。

次に実験の手順を説明する。実験の手順は2つのフェーズに分けられる。箒の学習を行う学習フェーズと、学習した結果を利用して、実際に箒を動かす実行フェーズである。まずの学習フェーズの条件に関して述べる。長自在箒に対して、最も類似度が大きい長スポンジの重みパラメータを、長自在箒の使用方を学習する深層学習に初期値として読み込む。つぎに、長自在箒の教師データを 30 個用意し、それをもとに長自在箒の使用方の学習を行う。学習回数が 12000 回を超えた時点で、学習を終了し、重みパラメータの更新を停止し、保存する。

次に、学習した使用方法を用いて、ロボットアームの手先速度を制御し、長自在箒により、清掃対象物をちり取りに入れる実行フェーズに関して述べる。先ほど保存した重みパラメータを読み込んだ深層学習を用意する。教師データではなく、実際の実験環境中のカメラや力覚センサから値を計測し、その値を深層学習に入力する。これにより、現在の実験環境の状態において、ロボットアームの手先が出すべき手先速度が推定される。この推定された手先速度により、実験環境中のロボットアームを動作させる。この実験環境の状態観測とロボットアームの手先速度の推定、さらにロボットアームの制御を繰り返すことにより、箒を利用して清掃対象物をちり取りへ移動させる。

実験の結果について説明する。実験の様子を Fig.5.6 に示す。清掃対象物全体の質量を、ちり取りに入れたものの質量で割ったものを成功率と呼ぶことにする。本実験における成功率は88%であった。ただ、ちり取りの奥にこぼれてしまったものがあり、成功率を下げる要因となった。

## 5.4 短スポンジを用いた清掃実験

上述の長自在箒を用いた実験と同様の手順および条件で、短スポンジの実験を行った。短ブラシに対して短スポンジは最大の類似度 0.8144 を有しているため、短ブラシの使用方法を学習している重みパラメータを深層学習の初期値として読み込ませ、学習を行う。その後実際に清掃を行い、どのくらい清掃能力があるかを検証する。

実験の結果について説明する。Fig.5.7 に実験の様子を示す。成功率は68%であった。短スポンジの類似度は長自在箒より大きいにもかかわらず、成功率が低い理由として毛先の横幅が自在箒と比べて70mmだけ小さいことが挙げられる。立方体のまとまりが箒で移動されるにつれ、箒の形に沿って広がっていき、最終的には箒の端からこぼれてしまう。そのため、スポンジは自在箒と比較して早い段階で立方体がこぼれると考えられる。この様子は Fig.5.7 から確認できる。

## 5.5 実用的な対象物を用いた清掃実証実験

立方体を清掃の対象として実験を行うと、対象物の特性に左右されずに箒ごとの清掃能力を計測することが出来る。しかし、実際の清掃の対象物となるとは考えづらい。そこで、清掃対象物を変え、実際の現場における清掃能力を検証する。

実験条件について説明する。長自在箒を用いた清掃実験とは異なり、立方体ではなく、Fig.5.8 に示す2つの清掃対象物を用意した。Fig.5.8a は工芸用の石であり、花壇の傍や道端で見かけることが出来る。Fig.5.8b は工業用に生成された珪砂であり、鑄造工場で砂型として使用されることがある。2種類とも 33g を用意した。清掃実験のために長自在箒を使用する。そのほかの条件は長自在箒を用いた清掃実験と同様である。

実験の手順について説明する。清掃対象物が立方体から工芸用の石と珪砂になった。そのため、画像処理アルゴリズムのパラメータを変更し、清掃対象物の検出を行う。具体的には、Fig.3.10 の2値化において、石および珪砂のみを抽出するように、HSV 色空間の閾値を変更した。それ以降の画像処理アルゴリズムは、長自在箒を用いた清掃実験と同様である。

清掃実験の結果を述べる。成功率は工芸用の石が61%であり、珪砂は15%であった。珪砂の実験の様子を Fig.5.9 に示す。工芸用の石に対して長い自在箒の成功率が低い理由としては、個々の石の一つ一つの質量が大きいため、石を一つ取りこぼすことによる成功率の下げ幅が大きいためである。珪砂の成功率が極端に低い原因としては、珪砂の粒子が非常に細かく摩擦が少ないため、毛先でとらえることができずに Fig.5.6 の青枠に示すように、広げるだけになったためである。対象物が立方体の場合の短いスポンジおよび、工芸用の石の場合の長い自在箒に関しては、掃き動作を一回だけでなく、複数回行うことによって成功率を上げることが可能と考えられる。一方、珪砂の場合は、自在箒を選択しないような、対象物の性質を考慮して清掃道具を選択する方法により清掃が可能だと考えられる。



毛先をモップに変更することにより，成功率の変化を検証した．使用した毛先を Fig.5.10 に示す．これは長スポンジに埃を取るために市販されている毛糸カバーを取り付けたものである．また，実験の様子を Fig.5.11 に示す．長自在箒を使用した実験と比較すると毛先の下に入り込む珪砂の量が少なく，毛先によって押される珪砂の量が多いことが分かる．これは毛先の性質によるものだと考えられる．毛先は毛糸が編み込まれたものであり，ホコリなどの微小な粒子を吸着するようにできている．そのため，自在箒と比べると摩擦が大きく，多くの珪砂を移動させることが出来ていると思われる．計測の結果，200g の珪砂の 37.9% にあたる 75.8g を清掃できたことが分かった．また，33g の場合は 1 回目の掃き動作で 40% にあたる 13.12g を，2 回目の掃き動作で 45% にあたる 8.86g を清掃することが出来た．これは，自在箒と比べると量が多く，このことから，清掃対象物の性質に合わせて毛先を選択することで清掃の成功率が上昇することが分かった．

## 5.6 まとめ

実験により，提案手法の有効性の検証を行い，結果について考察を行った．検証のために 3 つの実験を行った．1 つ目は深層学習の学習回数をどの程度減少できるか検証するものであった．2 つ目は提案手法により従来より短い学習回数で獲得された道具の使用方法が，適切な道具の使用方法かどうかの検証を行うものであった．3 つ目は，工芸用の石と珪砂を清掃対象物として，実際の清掃現場における清掃能力の検証を行った．


1 つ目の実験の学習回数と類似度の関係性の検証においては，類似度が大きいとテスト誤差が 0.002 以下になるための学習回数が 518 回であり，小さい場合は 3457 回であった．ゼロから学習した場合は 7553 回を要した．また，テスト誤差が 0.02 を下回った際の学習回数に関して t 検定を行った．その結果，p 値は 0.02 となり，有意水準である 0.05 を下回った．これにより学習回数の削減という結果は偶然起こっ

たわけではなく、提案手法に起因することが示された。この結果から、類似度が大きいと削減可能な学習回数も大きく、類似度が小さい場合と削減効果も小さくなることが分かった。


2つ目の実験では、類似度が大きい道具の使用方法を初期値として読み込み、学習した場合に獲得された動作の検証を行った。長自在箒を使用した実験では、清掃対象物の88%をちり取りへ移動させることが出来た。短スポンジを使用した実験では、68%の清掃対象物を移動させることが出来た。また、この結果から類似度の大小と清掃能力は比例しないことが分かった。

3つ目の実験では、実際の清掃現場における清掃能力の検証を行った。清掃対象物として工芸用の石と珪砂を、利用する箒として長自在箒とモップを用いて実験を行った。長自在箒を用いた実験では、工芸用の石と珪砂はそれぞれ61%と15%をちり取りへ移動させることが出来た。また、モップを利用して、珪砂を清掃する実験では、37.9%を移動させることができた。


また、この結果から実際の清掃能力は、清掃対象物に対する箒自体の性質に影響されることが分かった。



(a) Broom position (input)



(b) Other observed data (input)



(c) Robot end-effector velocity (output)

Fig. 5.1 Normalized training data

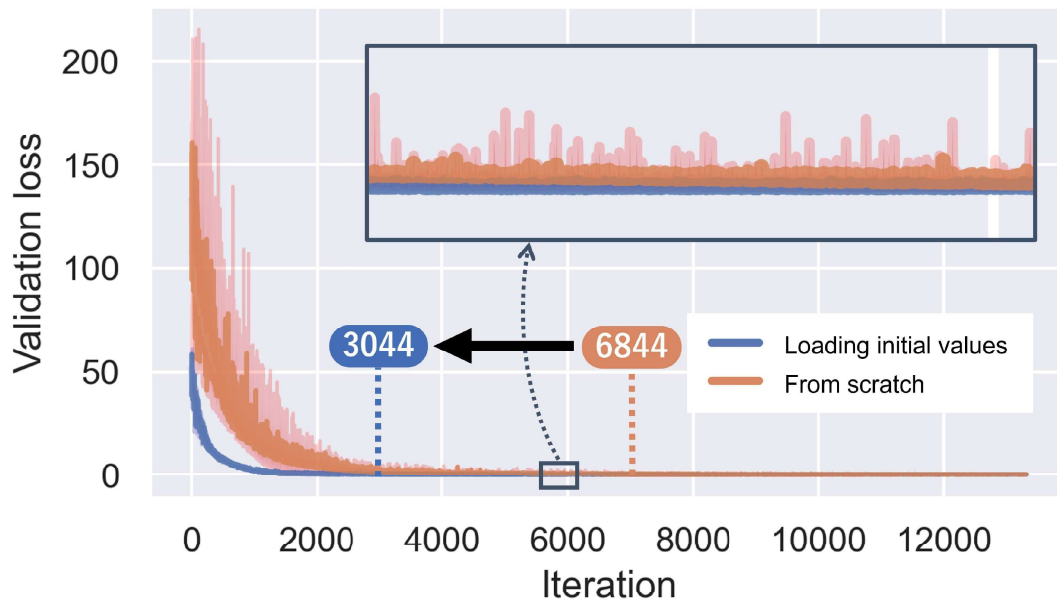


Fig. 5.2 Convergence of validation loss average with long normal broom






Fig. 5.3 T-test for first iteration under 0.02



(a) Learning iteration with brooms of large and small similarity



(b) Learning iteration with brooms of large similarity and from scratch

Fig. 5.4 Reducing learning iteration by using experience



Fig. 5.5 Cubes to be cleaned




Fig. 5.6 Experiment with long normal broom and cubes




Fig. 5.7 Experiment with small sponge and cubes



(a) Gardening stones



(b) Sand

Fig. 5.8 Items to be cleaned







Fig. 5.9 Experiment for sand





Fig. 5.10 long mop broom




Fig. 5.11 Experiment for sand with mop



## 5.7 考察

### 5.7.1 類似度計算アルゴリズムに対する考察

第4章のTable 4.2は類似度の計算結果である。Table 4.2において最大の類似度は短いブラシに対する短いスポンジの類似度である。これは全体の形状が似ていることに加えて、毛先の反力が近いことが理由として挙げられる。また、長スポンジの長自在箒に対する類似度は0.3080であるが、長ブラシに対する類似度は0.5811となっている。これは長スポンジと長ブラシの毛先形状が似ているためだと考えられる。なぜなら毛先の幅は長自在箒が0.22m、長スポンジが0.15m、長ブラシが0.11mとなっている。長自在箒と長スポンジの幅の差が0.07mであるのに対して、長ブラシと長スポンジの幅の差が0.04mとなっており、長ブラシと長スポンジの方が毛先の幅が近いということが分かる。そのため長スポンジに対する長自在箒と長ブラシの類似度の差は毛先の幅に起因すると考えることが出来る。またTable 4.2における最低の類似度は長自在箒の短スポンジに対するもので0.0563あった。ただし、長自在箒の短スポンジに対する類似度も0.0557となっており、あまり差がほとんどないことが分かる。長自在箒と短自在箒の類似度をそれら2つと比較すると、それらより大きく0.0622となっていることが分かる。この差は毛先の形状、毛先反力、および角度を反映したものだと考えられる。これらのことから、本研究で提案した類似度計算アルゴリズムは箒の種類を判別することが可能であることが分かる。また、特性が似ているものは近い類似度を計算し、似ていないものは差が大きくなることが確かめられた。

### 5.7.2 学習回数の短縮に対する考察

学習済み箒の深層学習のパラメータを初期値として読み込むことにより、少ない学習回数で使用方法を獲得することが出来るシステムを提案した。そこで、類似度

が大きい箒を初期値として読み込んだ場合と、類似度が小さい箒を読み込んだ場合では獲得される動作や学習回数にどのような差があるかを実験結果から考える。

まず、初期値として読み込んだ箒の類似度の大小によって獲得される動作への影響を考える。立方体を清掃対象物とした清掃実験では長自在箒と短スポンジの使用方法を獲得した。長自在箒の学習に際しては長スポンジのパラメータを初期値として読み込み、短スポンジの学習に際しては短ブラシのパラメータを初期値として読み込んだ。長自在箒の長スポンジに対する類似度は0.3080であり、短スポンジの短ブラシの類似度は0.8144であり、短スポンジのほうが類似度が大きかった。そのため、類似度が使用方法に影響を及ぼすならば、短スポンジのほうが清掃実験の成功率が高いことが考えられる。しかし結果は、類似度が長自在箒より大きいにも関わらず、成功率は低かった理由としては、毛先の横幅が自在箒と比べて70mmだけ小さいことが考えられる。立方体のまとまりが箒で移動されるにつれ、箒の形に沿って広がっていき、最終的には立方体は箒の端からこぼれる。そのため、自在箒と比較して早い段階で立方体がこぼれてしまっていた。この様子はFig.5.7からも確認できる。そのため、類似度が使用方法に及ぼす影響は確認できなかった。また、そもそもの箒の清掃能力に成功率が左右されることが分かった。

次に学習回数に類似度の大小が及ぼす影響を考える。これは第5章のFig.5.4から考察することが可能である。Fig.5.4は類似度が大きい場合と小さい、さらにゼロから学習したときにテスト誤差が0.002を下回るために必要な学習回数を示したものである。これによると、類似度が大きい場合は518回、小さい場合は3457回、ゼロからの学習では7553回必要であった。したがって、類似度が小さくても読み込むことにより、ゼロから学習するときと比べて54%の高速化が可能であることが分かった。この理由として、類似度が異なるからと言っても清掃道具の使用方法は毛先を床につける、清掃対象物に毛先を付けるなどの使用方法が似ている部分がある。そのため、それらの使用方法においては学習の省略が可能であり、差分のみを学習

すれば済むため高速化が可能だったと考えられる。このことから、類似度の低い道具の使用方法を初期値として読み込んでも学習の妨げにはならず、類似度が大きい掃除道具には及ばないものの、学習回数の短縮が可能だと考えられる。

また、実用的な対象物を用いた清掃実証実験における工芸用の石に対して長い自在箒の成功率が低い理由としては、個々の石の一つ一つの質量が大きいため石を一つ取りこぼすことによる成功率の下げ幅が大きいことが考えられる。珪砂の成功率が極端に低い原因としては、珪砂の粒子が非常に細かく摩擦が少ないため、毛先でとらえることができずに Fig.5.9 の青枠に示すように、広げるだけになったためである。一方、モップを使用した実験では、長自在箒と比べて、22.9%の清掃能力の向上が見られた。モップの毛先は毛糸が編み込まれたものであり、微小な粒子を吸着するようにできており、また、毛先の摩擦も大きい。そのため、長自在箒と比べて、多くの珪砂の粒子をちり取りへ移動させることが出来たと考えられる。このことから、清掃能力は類似度の大小より、清掃対象物に及ぼす箒の毛先の性質によって決まると考えられる。

## 第6章 結言と今後の展望

本研究では、ロボットアームによる道具の使用方法の高速な模倣学習システムの提案および実証実験を行った。提案システムは道具の形状と物理的特性が似ている場合には、それらの道具の使用方法も類似するという仮定に基づいている。また、動作の模倣には深層学習を利用した。そのため、深層学習の重みパラメータが道具の使用方法を表していると考えられる。したがって、本研究における上述の仮定は、道具どうしが似ている場合には、深層学習で学習される重みパラメータも近い値をとることが出来ると定義することが出来る。この仮定を利用して、深層学習の重みパラメータとして表される道具の使用方法と、その道具の特徴量をデータベースに格納しておき、新しい道具が与えられたときに、データベース内の筭と与えられた筭の類似度を計算し、最も類似度が高かった道具の学習済み重みパラメータを、新しい深層学習の初期パラメータとして読み込むことにより、使用方法の差だけを学習すれば済むようになると考え、学習回数の低減を試みた。

本研究では特に使用方法を学習する道具として筭に着目した。まず、本研究では道具どうしが似ていることを数値的に計算するための手法を提案した。この手法は、従来のように大規模な機械学習を用いずに、筭の3次元的特徴と毛先の反力という物理的な特徴から筭間の類似度を計算することができた。また、教師データの作成にはVRのシステムをモーションキャプチャとして使用し、操作者が産業用ロボットを遠隔で操作し、その動作と環境の状態を画像処理により計測することで、教師データを作成することが出来るシステムを作成した。これにより直感的に人の動作をロボットアームに教示することが可能であった。深層学習には順伝播型のアーキテクチャを用いた。環境の状態を入力とし、次の時刻における適切なロボットアーム

ムの手先速度を推定する回帰問題として模倣をとらえ学習を行った。実験では、似ている箒の使用方法を読み込むことによる学習回数の低減を検証した。似ている箒の重みパラメータを初期値として読み込んだときと、読み込まなかったときを比較した。具体的には、テスト誤差が初めて 0.02 を下回るまでの学習回数を比較を行った。その結果 56% の短縮が出来たことが判明した。また、t 検定を行い、統計的にも本提案システムが有効であることを示した。また、実際の清掃能力に関しても実験を行い、検証した。清掃対象物として立方体を用意し、長自在箒と短スポンジの使用方法を提案システムにて学習し、清掃を行った。その結果、清掃成功率は 88% と 68% となり、類似度の大きさと成功率の高さは相関しないことが分かった。さらに、実際の現場における清掃能力を検証するために、珪砂と工芸用の石を対象物として実験を行った。その結果、工芸用の石の成功率は 61% であり、珪砂は 15% であった。これは珪砂自体の摩擦が小さいため、箒の毛先の下に入り込んでしまい、掃くことが出来ないことが原因であった。したがって、清掃する対象物に関して、箒を選択可能なように、目的に合わせて類似度が変化する仕組みが必要であると考えられる。

今後の展望として、下記の項目が挙げられる。

- 清掃対象物に合わせた道具の選択

立方体や園芸用の石に関しては清掃することが出来たが、珪砂に関しては成功率が低くなった。これは、珪砂の粒子表面の摩擦が非常にすくないために、箒によって引きずることが出来ず、まとまっていた珪砂を押し広げる動作になってしまったためである。そこで、珪砂に対して箒を変えることによる成功率の検証と、対象物に対する効果によって類似度が変化するシステムが望まれる。

- 清掃対象物の検出の自動化

現在は箒の毛先やちり取り、また清掃対象物の画像中からの検出方法を事前に人がプログラミングしておく必要がある。しかしながら、実際の清掃現場でそのような作業を行うのは手間がかかり現実的ではない。そこで、それらを自動で行うシステムの追加が求められている。例えば、深層学習のアーキテクチャの一つである Convolutional neural network (CNN) は画像を入力として受け取ることが可能なため、物体認識などに使用されている。これを利用することにより、カメラがとらえた画像から必要な情報を抜き出すことが出来ると期待される。

- 深層学習の出力を速度から圧力へ変更

本研究では、深層学習は手先の速度を推定している。しかしながら、珪砂などの細かい粒子状の物体が対象物となるときは、適切な圧力を箒に加えることで、粒子が箒の毛先の下に潜り込むことを防げると考えられる。したがって現在は速度制御を用いているが、圧力制御を使用することによって粒状の対

象物の成功率が増加させられると考えている。

- 清掃以外への応用

本研究では主に清掃に着目し、箒の使用方法の学習について研究を行った。また、類似度の計算に関しても箒の毛先の弾性が指標の一つとなるなど、清掃を前提としたシステムとなっている。どのような道具でも使用方法を獲得可能なように、清掃以外の分野に関して応用を行うことが必要であると考えられる。例えば、包丁などがあげられる。しかし、箒の使用方法を包丁の使用方法に流用することは難しいと考えられる。そのため、初めに、形状が似ていて使用方法が少し異なる道具を学習し、データベースに格納しておく。学習した道具が増えるにつれ、データベース内の使用方法が多様化する。最終的には、包丁の使用方法も高速に学習可能になると考えられる。

- 清掃現場での実用化道具の使用方法の模倣について研究した。しかし、より実用的なシステムを作成するためには、清掃対象物がどのように変形するかを予測するシステムと組み合わせることにより、清掃対象物が複数の塊に分かれている場合や、複数回に分けて、ちり取りまで移動させる行動が可能になると考えられる。また、人間は重いゴミを掃くときには、引きずるようにして、軽いゴミを掃くときには、箒を往復運動させることにより回収している。引きずるような動作のみ本研究では獲得の対象とした。軽いゴミは体積が小さい場合が多く、毛先と床の間をすり抜けていく。そのため往復運動により清掃を行うことは、清掃能力の向上に寄与すると考えられる。現在のシステムでは、そのような往復運動を扱うことは難しい。なぜなら、以前の行動履歴により、実験環境が同じであっても、異なる行動を選択する必要があるためである。そのため、Long short-term memory のような時系列データに特化した

深層学習を使用することで、人が軽いゴミを掃くときのような動作を獲得可能だと考えている。



## 参考文献

- [1] 総務省統計局, “人口推計 2019 年（令和元年）12 月報,” 2019.
- [2] 国立社会保障・人口問題研究所, “日本の将来推計人口（平成 29 年 4 月推計）,” 2017.
- [3] 総務省, “統計からみた我が国の高齢者 - 「敬老の日にちなんで」 -, ” 2020.
- [4] 経済産業省, “2050 年までの経済社会の構造変化と政策課題について,” 2018.
- [5] 厚生労働省, “令和 2 年厚生労働白書,” 2020.
- [6] 内閣府「選択する未来」委員会, “未来への選択 <参考図表編>,” 2014.
- [7] 独立行政法人 労働政策研究・研修機構, “資料シリーズ No.209 労働力需給の推計 -労働力需給モデル- （2018 年度版）による将来推計,” 2019.
- [8] 厚生労働省, “平成 27 年度 雇用政策研究会報告書概要,” 2015.
- [9] 厚生労働省, “人材開発政策の現状と課題, 今後の見通しについて,” 2019.
- [10] 首相官邸 働き方改革実現会議, “働き方改革実行計画（平成 29 年 3 月 28 日働き方改革実現会議） 参考資料,” 2017.
- [11] 内閣府「選択する未来」委員会, “選択する未来 -人口推計から見えてくる未来像-, ” 2015.
- [12] 総務省, “平成 30 年 情報通信白書,” 2018.

- [13] 国土交通省, “国土交通白書 2015,” 2015.
- [14] 国立社会保障・人口問題研究所, “国立社会保障・人口問題研究所,” 2017.
- [15] 厚生労働省, “平成 28 年版 厚生労働白書 (平成 27 年度厚生労働行政年次報告) -人口高齢化を乗り越える社会モデルを考える-,” 2016.
- [16] 森川 洋, “人口減少時代の地域政策,” 経済地理学年報, 第 61 巻, pp. 202-218, 2015.
- [17] 後藤純一, “少子高齢化時代における黒人労働者受け入れ政策の経済学分析,” 国際経済, 第 66 巻, 2015.
- [18] 赤川 学, “人口減少社会における選択の自由と負担の公平,” 日本社会学会誌 社会学評論, 第 56 巻, 第 1 号, pp. 20-37, 2005.
- [19] 川本 敏, “少子化対策の現状と効果的な対策の推進,” 白鳳大学論集, 第 32 巻, 第 2 号, pp. 1-25, 2018.
- [20] 川本 敏, “少子化対策における移民の役割,” 白鳳大学論集, 第 33 巻, 第 1 号, pp. 49-78, 2018.
- [21] 厚生労働省, “令和元年版働く女性の実情 II 働く女性に関する対策の概況,” 2019.
- [22] 厚生労働省, “パンフレット (簡易版) 高年齢者雇用安定法改正の概要,” 2021.
- [23] 経済産業省, “中小企業庁 第四次産業革命と中小企業について,” 2017.
- [24] 経済産業省, “ロボットを取り巻く環境変化と今後の施策の方向性 ～ロボットによる社会変革推進計画～,” 2017.

- [25] 日本学術会議 機械工学委員会ロボット学分科会, “日本学術会議 要旨提言 より良い近未来創造のためのロボット/AI の理解と人材育成,” 2020.
- [26] Daron Acemoglu and Pascual Restrepo, “The Race Between Man and Machine: Implications of Technology for Growth, Factor Shares, and Employment,” AMERICAN ECONOMIC REVIEW, Vol. 108, No. 6, pp. 1488-1542, 2018.
- [27] Graetz Georg and Guy Michaels, “Robots at Work,” Review of Economics and Statistics, Vol. 100, No. 5, pp. 753-768, 2018.
- [28] Autor David, Frank Levy and Richard J. Murnane, “The skill Content of Recent Technological Change: An Empirical Exploration,” The Quarterly Journal of Economics, Vol. 118, No. 4, pp. 1279-1333, 2003.
- [29] 足立 大輔, 海沼 修平, 川口 大司, 齋藤 有望子, “自動化技術の導入と労働代替,” 独立行政法人経済産業研究所, 2019.
- [30] 産業経済省 産業構造審議会 産業技術分科会 評価小委員会, “ロボット産業の現状と課題,” 2012.
- [31] 国立研究開発法人 新エネルギー・産業技術総合研究所, “NEDO ロボット白書 2014,” 2014.
- [32] 新井 民夫, “生産自動化の現状,” 精密工学会誌, 第 75 巻, 第 1 号, p. 61, 2009.
- [33] 国立研究開発法人 新エネルギー・産業技術総合研究所, “NEDO ロボット白書 2014,” 2014.
- [34] 佐藤知正, “協働ロボット (コボット) が拓く生産と生活の革新 人間・ロボット共存の新時代,” 横幹, 第 9 巻, 第 2 号, pp. 79-85, 2015.

- [35] 河野克己, “社会・産業分野のスマート化と産業制御システム,” 制御と計測, 第 57 巻 第 1 号, 2018.
- [36] 経済産業省 近畿経済産業局, “ロボット導入促進ガイドブック”
- [37] 橋本 尚久, “日本のロボット分野における産業技術者育成に関する取り組み,” 日本ロボット学会誌, 第 38 巻, 第 9 号, pp. 785-788, 2010.
- [38] 公益社団法人東京ビルメンテナンス協会, “次世代における清掃ロボットの導入事例紹介レポート,” 2021.
- [39] 飛田和輝, 嵯峨山功幸, 盛真唯子, 田淵絢子, 福島庸介, 勅使河原誠一, 小川博教, “日本のロボット分野における産業技術者育成に関する取り組み,” 日本ロボット学会誌, 第 38 巻, 第 9 号, pp. 785-788, 2010.
- [40] 小柳 栄次, “サブクローラを持つレスキューロボット,” 日本ロボット学会誌, 第 28 巻, 第 2 号, pp. 147-150, 2010.
- [41] 貞本 敦史, “NEDO 生活支援ロボット実用化プロジェクトの概要,” 日本ロボット学会誌, 第 29 巻, 第 9 号, pp. 760-764, 2011.
- [42] 小山俊彦, 岡本淳, 後藤哲哉, “パッシブ型手術支援ロボット iArmS,” 医療機器学, 第 86 巻, 第 4 号, pp. 377-383, 2016.
- [43] 才藤 栄一, 平野 哲, 田辺 茂雄, 山田 純也, 園田茂, “運動学習と歩行練習ロボット—片麻痺の歩行再建—,” The Japanese Journal of Rehabilitation Medicine, 第 53 巻, 第 1 号, pp. 27-34, 2016.
- [44] アイロボットジャパン合同会社, “iRobot Roomba i7 ロボット掃除機 取扱説明書”

- [45] Gambao Ernesto and Hernando Miguel, “Control System for a Semi-Automatic Facade Cleaning Robot,” The 2006 International Symposium of Automation and Robotics in Construction, pp. 406-411, 2006.
- [46] Mir-Nasiri Nazim, Siswoyo Hudyjaya and Ali Md Hazrat, “Portable Autonomous Window Cleaning Robot,” Procedia computer science, pp. 197-204, 2018.
- [47] Jaradat Mohammad A., Tauseef Mohammad, Altaf Yousuf, Saab Roba, Adel Hussam, Yousuf Nadeem and Zurigat Yousef H., “A Fully Portable Robot System for Cleaning Solar Panels,” 10th International Symposium on Mechatronics and its Applications, pp. 1-6, 2015.
- [48] Emaad Mohamed H. Zahugi, Mohamed M. Shanta and T. V. Prasad, “Design of Multi-Robot System for Cleaning up Marine Oil Spill,” International Journal of Advanced Information Technology, Vol. 2 No. 4, 2021.
- [49] Sanpeng Deng, Xiaoli Xu, Chongning Li and Xinghui Zhang, “Research on The Oil Tank Sludge Cleaning Robot System,” International Conference on Mechanic Automation and Control Engineering, 2010.
- [50] Lee Hyunsoo and Banerjee Amarnath, “Intelligent Scheduling and Motion Control for Household Vacuum Cleaning Robot System Using Simulation Based Optimization,” Winter Simulation Conference, 2015.
- [51] 薩見 雄一, 青山 元, 石川 和良, 関 淳也, 足立 佳儀, 石村 左緒里, 高橋 朝美, 横田 和隆, “トイレ用小型清掃ロボットの開発,” 日本ロボット学会誌, 第 29 巻, 第 7 号, pp. 573-583, 2011.
- [52] 青山 元, 石川 和良, “ビルのロボット清掃システム,” 日本機械学会誌, 第 113 巻, 第 1102 号, pp. 709-709, 2010.

- [53] 舟田 裕史, 小越 康宏, 藤田 智司, 帆谷 竜起, 齋藤 秀明, 荒木 睦大, “川の清掃ロボット～水中の空き缶回収ロボット～,” 日本知能情報ファジィ学会 ファジィ システム シンポジウム 講演論文集 第 27 回ファジィシステムシンポジウム, p. 239, 2011.
- [54] 小山 猛, 米倉 達郎, 澤口 翔, 北村 憲一, 蛇口 卓也, 三浦 孝洋, “水中ロボットを用いた緩速ろ過池運用の高度化-緩速ろ過池清掃ロボットの開発と実地実験,” 全国会議水道研究発表会 講演集 令和元年度, pp. 350-351, 2019.
- [55] 角道 貴久, 渡辺 桂吾, 永井 伊作, “階段清掃ロボットにおける移動機構の検討,” ロボティクス・メカトロニクス講演会講演概要集, 2011.
- [56] Ye Changlong, Ma Shugen, Li Huaiyong and Yang Junjun, “Development of a Pipe Cleaning Robot for Air Conditioning System,” IEEE International Conference on Robotics and Biomimetics, 2010.
- [57] Le Anh Vu, Kyaw Phone Thiha, Veerajagadheswar Prabakaran, Muthugala MA Viraj J. Elara Mohan Rajesh, Kumar Madhu, Nhan and Nguyen Huu Khanh, “Reinforcement Learning-Based Optimal Complete Water-Blasting for Autonomous Ship Hull Corrosion Cleaning System,” Ocean Engineering, Vol. 220, 2021.
- [58] 青木 貴宏, 金 丸隆志, “掃除ロボットに追加する片付け機能に必要な物体認識の研究,” 日本機械学会 年次大会 , 2016.
- [59] 鹿嶋 雅之, 有馬 拓也, 佐藤 公則, 渡邊 睦, “自動掃除ロボットのゴミ分別収集のための能動的物体認識手法,” 画像電子学会誌, Vol. 43, No. 3, pp. 392-396, 2014.

- [60] 平田 鷹志, 山崎 亘, 吉川 雅博, 池田 篤俊, 高松 淳, 小笠 原司, “ロボットアームを搭載した室内掃除ロボット,” ロボティクス・メカトロニクス講演会講演概要集, 2015.
- [61] 福田 拓人, 森田 峰史, 高橋 智一, 鈴木 昌人, 青柳 誠司, “ロボット掃除機ルンバによる蛍光灯位置情報を利用した地図作成と自己位置推定 (移動ロボットの自己位置推定と地図構築),” ロボティクス・メカトロニクス講演会講演概要集, 2014.
- [62] Joshua D. Langsfeld, Ariyan M. Kabir, Krishnanand N. Kaipa and Satyandra K. Gupta, “Online Learning of Part Deformation Models in Robotic Cleaning of Compliant Objects,” 11th International Manufacturing Science and Engineering Conference. Americal Society of Mechanical Engineers, Vol. 49903, pp. V002T04A003, doi:<https://doi.org/10.1115/MSEC2016-8663>, 2016.
- [63] Joshua D. Langsfeld, Ariyan M. Kabir, Krishnanand N. Kaipa and Satyandra K. Gupta, “Robotic Bimanual Cleaning of Deformable Objects with Online Learning of Part and Tool Models,” IEEE International Conference on Automation Science and Engineering, pp. 626–632, 2016.
- [64] Jurgen Hess, Gian Diego Tipaldi and Wolfram Burgard, “Null Space Optimization for Effective Coverage of 3d Surfaces Using Redundant Manipulators,” IEEE/RSJ International Conference on Intelligent Robots and Systems, pp. 1923–1928, 2012.
- [65] Sarah Elliott and Maya Cakmak, “Robotic Cleaning Through Dirt Rearrangement Planning with Learned Transition Models,” IEEE International Conference on Robotics and Automation, pp. 1623–1630, 2018.

- [66] 内田 大貴, 堀内 匡, “模倣学習による実ロボットの歩容動作獲得に関する検討,” 日本知能情報ファジィ学会 ファジィ システム シンポジウム 講演論文集, 第 26 回, 2010.
- [67] 宇田川 大二郎, 内田 大貴, 堀内 匡, “模倣学習を用いた二脚駆動ロボットの行動獲得,” 日本知能情報ファジィ学会 ファジィ システム シンポジウム 講演論文集, 第 27 回, 2011.
- [68] 壺内 将之, 尾形 哲也, 奥乃 博, 西出 俊, 信田 春満, “柔軟関節をもつ人間型ロボットにおける神経力学モデルを用いたダイナミック動作の模倣,” 情報処理学会 第 74 回全国大会講演論文集, pp. 103-104, 2012.
- [69] 望月 敬太, 西出 俊, 奥乃 博, 尾形 哲也, “神経回路モデルを用いたロボットの描画運動における発達の模倣学習,” 人工知能学会 第 75 回全国大会講演論文集, pp. 217-218, 2013.
- [70] Mochizuki Keita, Nishide Shun, Okuno Hiroshi and Ogata Tetsuya, “Developmental Human-Robot Imitation Learning of Drawing with a Neuro Dynamical System,” IEEE international conference on systems, man, and cybernetics, pp. 2336-2341, 2013.
- [71] Tanis Mar, Vadim Tikhonoff, Giorgio Metta and Lorenzo Natale, “Self-Supervised Learning of Grasp Dependent Tool Affordances on The iCub Humanoid Robot,” IEEE International Conference on Robotics and Automation, pp. 3200–3206, 2015.
- [72] Tanis Mar, Vadim Tikhonoff, Giorgio Metta and Lorenzo Natale, “What Can I Do With This Tool? Self-Supervised Learning of Tool Affordances From Their



- 3-D Geometry,” IEEE Transactions on Cognitive and Developmental Systems, pp. 595–610, 2017.
- [73] Handy Wicaksono and Claude Sammut, “Relational Tool Use Learning by a Robot in a Real and Simulated World,” Australasian Conference on Robotics and Automation, 2016.
- [74] Alexander Stoytchev, “Behavior-grounded Representation of Tool Affordances,” IEEE international conference on robotics and automation, pp. 3060–3065, 2005.
- [75] Jivko Sinapov and Alexander Stoytchev, “Learning and Generalization of Behavior-Grounded Tool,” IEEE 6th International Conference on Development and Learning, pp. 19–24, 2007.
- [76] Vadim Tikhanoff and Ugo Pattacini, Lorenzo Natale and Giorgio Metta, “Exploring Affordances and Tool Use on the iCub,” 13th IEEE-RAS International Conference on Humanoid Robots, pp. 130–137, 2013.
- [77] Chelsea Finn, Tianhe Yu, Tianhao Zhang, Pieter Abbeel and Sergey Levine, “One-Shot Visual Imitation Learning via Meta-Learning,” The 1st Annual Conference on Robot Learning, pp. 357–368, 2017.
- [78] Aravind Rajeswaran, Vikash Kumar, Abhishek Gupta, Giulia Vezzani, John Schulman, Emanuel Todorov and Sergey Levine, ”Learning Complex Dexterous Manipulation with Deep Reinforcement Learning and Demonstrations,” arXiv preprint arXiv:1709.1008, 2017.
- [79] Daniel Seita, Aditya Ganapathi, Ryan Hoque, Minh Hwang, Edward Cen, Ajay Kumar Tanwani, Ashwin Balakrishna, Brijen Thananjeyan, Jeffrey Ichnowski, Nawid Jamali, Katsu Yamane, Soshi Iba, John Canny and Ken Goldberg, “Deep

- Imitation Learning of Sequential Fabric Smoothing Policies,” arXiv preprint-arXiv:1910.04854, 2019.
- [80] Yunpeng Pan, Ching-An Cheng, Kamil Saigol, Keuntaek Lee, Xinyan Yan, Evangelos Theodorou and Byron Boots, “Agile Autonomous Driving Using End-to-end Deep Imitation Learning,” arXiv preprintarXiv:1709.07174, 2017.
- [81] Chelsea Finn, Xin Yu Tan, Yan Duan, Trevor Darrell, Sergey Levine and Pieter Abbeel, “Deep Spatial Autoencoders for Visuomotor Learning,” IEEE International Conference on Robotics and Automation, pp. 512–519, 2016.
- [82] Sergey Levine, Chelsea Finn, Trevor Darrell and Pieter Abbeel, “End-to-end Training of Deep Visuomotor Policies,” The Journal of Machine Learning Research Vol. 17, pp. 1-40, 2016.
- [83] Yoshinori Fujita, Takuya Hanyu, Yosuke Kanada and Takeshi Yoneyama, “Gripping Force Feedback System for Neurosurgery,” International Journal of Automation Technology, Vol. 8, No. 1, pp. 83-94, 2014.
- [84] Ryoya Kamata, Ryosuke Tamura, Satoshi Niitsu, Hiroshi Kawaharada and Hiroyuki Hiraoka, “Use of 1DOF Haptic Device for Remote-Controlled 6DOF Assembly,” International Journal of Automation Technology, Vol. 8, No. 3, pp. 452-459, 2014.
- [85] Kiyoshi Hoshino, Naoki Igo, Motomasa Tomida and Haime Kotani, “Teleoperating System for Manipulation a Moon Exploring Robot on the Earth,” International Journal of Automation Technology, Vol. 11, No. 3, pp. 433-441, 2017.
- [86] Harumo Sasatake, Ryosuke Tasaki, Takahito Yamashita and Naoki Uchiyama, “Deep Imitation Learning for Broom-Manipulation Tasks Using Small-Sized

- Training Data,” IEEE 7th International Conference on Control, Decision and Information Technologies, pp. 731-738, 2020.
- [87] Tianhao Zhang, Zoe McCarthy, Owen Jow, Dennis Lee, Xi Chen, Ken Goldberg and Pieter Abbeel, “Deep Imitation Learning for Complex Manipulation Tasks from Virtual Reality Teleoperation,” IEEE International Conference on Robotics and Automation, pp. 5628-5635, 2018.
- [88] Wang Bernie, Wu Virginia, Wu Bichen and Keutzer Kurt “LATTE: Accelerating Lidar Point Cloud Annotation via Sensor Fusion, One-Click Annotation, and Tracking,” IEEE Intelligent Transportation Systems Conference, pp. 265-273, 2019.
- [89] Wu Zifeng, Shen Chunhua, Van Den and Hengel Anton, “Wider or Deeper: Revisiting the Resnet Model for Visual Recognition,” Pattern Recognition, Vol. 190, pp. 119-133, 2019.
- [90] Heng Yang and Luca Carlone, “A Polynomial-time Solution for Robust Registration with Extreme Outlier Rates,” arXiv preprint arXiv:1903.08588, 2019.
- [91] S. Garrido-Jurado, R. Muñoz-Salinas, F. J. Madrid-Cuevas, and M. J. Marín-Jiménez. ”Automatic Generation and Detection of Highly Reliable Fiducial Markers under Occlusion, ” Pattern Recognition, Vol. 47, No. 6, pp. 2280-2292, 2014.
- [92] Graham Neubig, Chris Dyer, Yoav Goldberg, Austin Matthews, Waleed Ammar, Antonios Anastasopoulos, Miguel Ballesteros, David Chiang, Daniel Clothiaux, Trevor Cohn, Kevin Duh, Manaal Faruqui, Cynthia Gan, Dan Garrette, Yangfeng Ji, Lingpeng Kong, Adhiguna Kuncoro, Gaurav Kumar, Chaitanya

Malaviya, Paul Michel, Yusuke Oda, Matthew Richardson, Naomi Saphra, Swabha Swayamdipta and Pengcheng Yin, “DyNet: The Dynamic Neural Network Toolkit,” arXiv preprint arXiv:1701.03980, 2017.

# 謝辞

本論文の執筆にあたり，多くの先生方のご指導と多くの方々のご協力を賜りました．

指導教員である豊橋技術科学大学機械工学系教授 内山直樹先生にはロボットによる道具の模倣学習の研究を行いたいとの私のわがままを受け入れていただきありがとうございました．また，学部生のときからロボットの制御の基礎，機構学，その応用まで多大な知識をご教授していただきましたこと心より感謝申し上げます．どのように大きな目標を掲げ，いかにしてそれを実現していくかということ，知識を蓄えるだけでなく，それを丁寧に説明する姿勢など，研究者，技術者としてのあり方を学ばせていただきました．何度もご迷惑をおかけいたしましたが，最後まで辛抱強くご指導いただきありがとうございました．

青山学院大学理工学部機械創造工学科 准教授 田崎良佑先生には学生でありながら非常勤講師兼客員研究員として，学生を指導する貴重な経験を頂きましたこと，また，博士課程として，研究者としてどのようにふるまうべきかご教示いただきましたこと心より感謝申し上げます．

豊橋技術科学大学 学長 寺嶋一彦先生には旧システム制御研究室の教授であったころに研究室の学生として，また，学長になられてからもたびたび気にかけて頂き，ご助言を頂きましたことを心から感謝いたします．

青山学院大学理工学部機械創造工学科 助教 山下 貴仁先生には電子回路の知識や学生への接し方などについて多くのことを学ばせて頂きました．感謝申し上げます．

また，ご多忙にも関わらず，本論文の審査委員を務めて頂き，有益なご助言をい

ただきました機械工学系教授 高山弘太郎先生，情報・知能工学系教授 北崎充晃先生に厚くお礼を申し上げます．

本研究を行うにあたり，助言，およびご協力をいただきましたシステム工学研究室の皆様，特に Ho Duc Tho 氏にはお礼を申し上げます．

最後に，研究を行うにあたり長年にわたり多大なご迷惑をお掛けし，ご支援を頂いた両親に深くお礼を申し上げます．