# サービスロボットの行動の時空間表現に基づく タスク・モーションプランニング

2023 年 3 月

川崎　陽祐

学位論文　博士（工学）

# サービスロボットの行動の時空間表現に基づく タスク・モーションプランニング

2023 年 3 月

慶應義塾大学大学院理工学研究科

川崎　陽祐

# 論文要旨

本論文では，人の生活空間における活躍が期待されるサービスロボットによる円滑なタスク遂行を実現するため，ロボットの機能や環境を有効活用する実行しやすい行動列の計画手法を提案する．実空間を考慮してロボットが現在・未来に実行可能な行動を理解するため，行動に関する記号的な知識や，ロボットのサブシステムの性質や物体集合の幾何情報に基づき，実行可能な行動の時空間的関係を記述する環境表現手法を提案する．そして，タスクをロボットが実現可能な行動の範囲で解釈するため，環境表現と実空間における指標に基づき行動列の内容や順番，実行場所を同時に最適化する手法を提案する．具体的には，実行可能な行動を実空間に埋め込む方法として，実行場所に着目し，エッジを行動の実行，ノードを行動の実行場所とした環境表現であるアクショングラフと，それに基づくロボットナビゲーション手法を提案する．さらに，ロボットと環境の状態から構成される世界状態と実行可能な行動の相互作用を計画問題へ落とし込むため，シーングラフを用いた知識表現に基づく，再帰的多層構造を有する世界状態依存アクショングラフと，それに基づくモバイルマニピュレーション計画手法を提案する．また，Human Robot Interaction (HRI) のための人への接近行動に着目し，HRI 行動に重要なセンサ情報とセンサ特性に基づき行動を実空間へ落とし込むためのアクションモデリング手法を提案し，経路計画手法とアクショングラフへの適用方法を提案する．本研究では，移動タスクや物体運搬タスクに提案手法を適用し，実機を用いた実験を通じて有効性を検証する．

第 1 章では，本研究全体の背景と目的，また課題解決の指針を述べた．

第 2 章では，ロボットのナビゲーションタスクを対象に，複数の実行可能な行動の時空間的な関係性を記述するアクショングラフの構築アルゴリズムとそれを用いた計画手法について述べ，提案手法の有効性を検証した．

第 3 章では，ロボットのモバイルマニピュレーションタスクを対象に，世界状態と行動可能性の相互作用を表現するため，アクショングラフを時間方向へ拡張した世界状態依存アクショングラフの構築アルゴリズムとそれを用いた計画手法について述べ，提案手法の有効性を検証した．

第 4 章では，ロボットの HRI 行動のための人への接近行動を対象に，搭載されたセンサを有効活用し HRI 行動を促進する接近行動を実空間に埋め込むためのアクションモデリング手法を述べた．さらに，得たアクションモデルに基づく経路計画手法とアクショングラフの構築手法について述べ，提案手法の有効性を検証した．

第 5 章では，各章の結果を受け，本論文の結論を述べた．

# SUMMARY OF Ph.D DISSERTATION

In this dissertation, I propose a planning method of executable action sequences that exploit the robot's functions and environment, aiming to realize smooth task execution by service robots. To understand the feasible actions for the robot in the present and future, considering real space, I propose an environment representations method that describes the spatio-temporal relations between feasible actions based on symbolic knowledge about the actions and geometric data such as the properties of the robot's subsystems and object sets in the environment. Then, for the interpretation of tasks within ranges of feasible actions for the robot, I propose planning methods for simultaneously optimizing the content, order, and execution position of action sequences based on the representation methods and metrics in real space. Specifically, I first propose an action graph where edges are the execution of actions and nodes are the execution positions of actions, as a method for embedding feasible actions in real space, focusing on execution locations, and a robot navigation method based on the representation. Next, to put the interactions between the world state, which consists of the robot state and the environment state, and executable actions, into a planning method, I propose a world state-dependent action graph, which is a graph representation of the recursive multi-layered structure of feasible actions based on a knowledge representation using a scene graph, and a mobile manipulation planning methods based on the representation. Furthermore, focusing on "approaching people" for human-robot interaction (HRI), I propose an action modeling method to put actions into real space based on sensor information and sensor characteristics important for HRI, and a path planning method and a method to apply action graph construction. The proposed method is applied to a moving task and an object-carrying task, and its effectiveness is verified through experiments using actual machines.

Chapter 1 describes the background, purpose, and approach of this research.

Chapter 2 describes an algorithm for constructing an action graph that represents the spatio-temporal relations between feasible actions for the robot navigation task, a planning method based on the action graph, and experimental results to verify the effectiveness of the proposed method.

Chapter 3 describes an algorithm for constructing a world state-dependent action graph for handling mobile manipulation tasks, which is an extended action graph to represent interactions between world states and action possibilities, and a planning method based on the action graph. The results and discussions of experiments to evaluate the effectiveness of the proposed algorithm are described.

Chapter 4 describes an action modeling method of "approaching people" for the facilitation of HRI action to utilize onboard sensors. Furthermore, path planning and action graph construction methods based on the action models are described and the effectiveness of the proposed method is verified.

Chapter 5 describes the conclusion of this dissertation.

# 目次


**1 序論** **1**
1.1 サービスロボット . . . . . 1
1.1.1 サービスロボットの需要 . . . . . 1
1.1.2 サービスロボットへの要求 . . . . . 1
1.1.3 想定条件 . . . . . 3
1.1.4 サービスロボットのタスクプランニングへの要求 . . . . . 4
1.2 タスク・モーションプランニング . . . . . 4
1.2.1 動向 . . . . . 4
1.2.2 課題 . . . . . 6
1.3 本論文の目的と実現方法 . . . . . 7
1.3.1 本論文の目的 . . . . . 7
1.3.2 実現方法 . . . . . 7
1.4 本論文の構成 . . . . . 9

**2 アクショングラフに基づく時空間的ロボットナビゲーション** **12**
2.1 緒言 . . . . . 12
2.2 既存研究とその課題 . . . . . 13
2.2.1 タスクプランニングと動作計画 . . . . . 13
2.2.2 環境表現 . . . . . 13
2.3 アクショングラフ . . . . . 15
2.3.1 概要 . . . . . 15
2.3.2 移動のための行動可能性グラフの構築 . . . . . 16
2.3.3 物体への行動の対応付け . . . . . 17
2.3.4 行動可能性グラフの構築 . . . . . 19
2.3.5 環境変化を伴う行動の表現 . . . . . 22
2.4 アクショングラフに基づく時空間的ロボットナビゲーション . . . . . 23
2.4.1 概要 . . . . . 23
2.4.2 ロボットナビゲーションのためのタスクプランニングへのアクショングラフの応用 . . . . . 23
2.5 実験 . . . . . 25
2.5.1 概要 . . . . . 25
2.5.2 実験設定 . . . . . 26
2.5.3 実験 1: 行動可能性グラフの検証 . . . . . 27
2.5.4 実験 2: アクショングラフの構造の検証 . . . . . 30
2.5.5 実験 3: 実機実験 . . . . . 31
2.6 結言 . . . . . 40

**3 世界状態依存アクショングラフに基づくモバイルマニピュレーション計画 41**
3.1 緒言 . . . 41
3.2 既存研究とその課題 . . . 41
3.2.1 実空間における行動可能性の理解 . . . 41
3.2.2 行動の実現可能性を考慮したタスクプランニング . . . 42
3.3 世界状態依存アクショングラフ . . . 42
3.3.1 概要 . . . 42
3.3.2 行動知識の表現 . . . 44
3.3.3 世界状態に基づくシーングラフの構築 . . . 45
3.3.4 シーングラフへの行動の対応付け . . . 46
3.3.5 行動可能性グラフの構築 . . . 46
3.3.6 再帰的な行動可能性グラフの構築 . . . 47
3.4 世界状態依存アクショングラフに基づくモバイルマニピュレーションタスクの計画 . . . 50
3.4.1 アクショングラフにおけるモバイルマニピュレーションタスクの解釈 . . . 50
3.4.2 計画 . . . 50
3.5 実験 . . . 51
3.5.1 実験 1: 世界状態依存アクショングラフの検証 . . . 51
3.5.2 実験 2: 世界状態依存アクショングラフに基づくタスクプランニングの検証 . . . 52
3.6 結言 . . . 57

**4 マルチモーダルポテンシャル場に基づく接近行動のアクションモデリング 58**
4.1 緒言 . . . 58
4.2 既存研究とその課題 . . . 58
4.2.1 コストマップに基づくナビゲーション手法 . . . 59
4.2.2 接近行動のモデリング手法 . . . 59
4.3 人の認識 . . . 59
4.3.1 人の位置と向きの推定 . . . 59
4.3.2 認識信頼度 . . . 60
4.3.3 認識信頼度の更新則 . . . 61
4.4 センサの特性 . . . 61
4.4.1 概要 . . . 61
4.4.2 姿勢推定のための人の画像センシング特性 . . . 62
4.4.3 人の音声センシング特性 . . . 62
4.5 マルチモーダルポテンシャル場を用いた接近行動のアクションモデリング 65
4.5.1 概要 . . . 65
4.5.2 ポテンシャルの設計 . . . 65
4.5.3 マルチモーダルポテンシャル場 . . . 67
4.6 接近行動のアクションモデルに基づくマルチモーダル経路計画 . . . 69
4.6.1 システム概要 . . . 69
4.6.2 目的地の決定 . . . 70
4.6.3 経路計画手法 . . . 71
4.6.4 経路追従手法 . . . 71
4.6.5 姿勢制御手法 . . . 71
4.7 接近行動のアクションモデルに基づくアクショングラフの構築 . . . 72
4.7.1 概要 . . . 72
4.7.2 行動知識の表現 . . . 72

4.7.3 接近行動のアクションモデルに基づくアクショングラフの構築 . . 73
4.8 実験 . . . . . 75
4.8.1 実験 1: マルチモーダル経路計画の検証 . . . . . 75
4.8.2 実験 2: マルチモーダルポテンシャル場に基づくアクショングラフの検証 . . . . . 88
4.9 結言 . . . . . 94

**5 結論** **95**
5.1 貢献 . . . . . 95
5.2 今後の展望 . . . . . 97
5.2.1 想定外を扱うための課題 . . . . . 97
5.2.2 実装に関する課題 . . . . . 98
5.2.3 応用に関する拡張性 . . . . . 99
5.2.4 ベンチマーク課題の提案 . . . . . 100

**参考文献** **101**

**謝辞** **110**

**著者論文目録** **111**

# List of Figures


1.1 Diversification of service robot types . . . . . 2
1.2 An example of environments in where robots work . . . . . 2
1.3 Relation between task, action and motion . . . . . 5
1.4 Overview of thesis . . . . . 11

2.1 Overview of ASTRON . . . . . 12
2.2 Action graph constructing pipeline . . . . . 16
2.3 Construction of action possibility graph for movement . . . . . 18
2.4 Construction of action possibility graph . . . . . 20
2.5 Construction of action possibility graph after state transition of environment and Representation of actions involving state transition . . . . . 21
2.6 Task planning based on action graph . . . . . 24
2.7 Example of action sequence (Strategy 3) . . . . . 24
2.8 Experimental environments . . . . . 26
2.9 System configuration of ASTRON . . . . . 28
2.10 Result of Com.2.1 in Exp. 2 . . . . . 32
2.11 Result of Com.2.2 in Exp. 2 . . . . . 32
2.12 Action graph constructed based on proposed method in Exp. 2 . . . . . 34
2.13 Planning result based on action graph based on proposed method in Exp. 2 35
2.14 Result of Scenario 3.1 in Exp. 3 . . . . . 36
2.15 Result of Scenario 3.2 in Exp. 3 . . . . . 37
2.16 Result of Scenario 3.3 in Exp. 3 . . . . . 38
2.17 Result of Scenario 3.4 in Exp. 3 . . . . . 39

3.1 Pipeline diagram of WDAG construction . . . . . 44
3.2 scene graph . . . . . 46
3.3 action associated scene graph . . . . . 46
3.4 Construction of action possibility graph . . . . . 47
3.5 Updating scene graph and world state based on action knowledge . . . . 49
3.6 Connecting action possibility graphs . . . . . 50
3.7 World state of Experiment1 . . . . . 51
3.8 Difference of action possibility graph depending on agent's state . . . . . 51
3.9 World state-dependent action graph based on world state in Experiment 1.1 . . . . . 53
3.10 Mutual interaction between action possibility and action . . . . . 53
3.11 Initial state *init* and goal specification *goal* of Experiment 2 . . . . . 54
3.12 Result of Experiment 2.1 . . . . . 55
3.13 Result of Experiment 2.2 . . . . . 56

4.1 Joint position estimation using OpenPose . . . . . 60
4.2 Example of updating the recognition reliability . . . . . 61

4.3 Measurement of recognition reliability . . . . . 63
4.4 Measurement of microphone input . . . . . 64
4.5 Human image potential . . . . . 66
4.6 Human voice potential . . . . . 66
4.7 Obstacle shape potential . . . . . 67
4.8 Design concept of potential fields weighting . . . . . 68
4.9 Flowchart of navigation based on multimodal path planning . . . . . 69
4.10 Pipeline of parameter update . . . . . 70
4.11 Sub goal on the planned path . . . . . 71
4.12 Detailed action knowledge of handover action for implementation . . . . 73
4.13 Construction of action possibility graph based on multimodal potential field 75
4.14 Determination of action position based on multimodal potential field (Left: Assumed environment, Right: Calculated potential field and action positions) . . . . . 76
4.15 Experimental environment . . . . . 77
4.16 List of tasks and actions . . . . . 77
4.17 Results from Scenario 1.1 . . . . . 79
4.18 Results from Scenario 1.2 . . . . . 79
4.19 Results from Scenario 2.1 . . . . . 81
4.20 Results from Scenario 2.2 . . . . . 81
4.21 Results from Scenario 3.1 . . . . . 82
4.22 Results from Scenario 3.2 . . . . . 82
4.23 Results from Scenario 4.1 . . . . . 84
4.24 Results from Scenario 4.2 . . . . . 85
4.25 Time history of expected voice recognition rate . . . . . 86
4.26 Pictures captured at the destination in Scenario 3.2 . . . . . 87
4.27 Assumed environment in Experiment2 . . . . . 89
4.28 Prior action possibility graph $G_0^a$ based on Comparison method 1 . . . . 91
4.29 Prior action possibility graph $G_0^a$ based on Comparison method 2 . . . . 91
4.30 Prior action possibility graph $G_0^a$ based on Proposed method . . . . . 92
4.31 Planning result based on action graph . . . . . 93

# List of Tables


1.1 Available actions . . . . . 4

2.1 Prior knowledge of subsystem-level affordance . . . . . 19
2.2 Prior knowledge of action . . . . . 19
2.3 Verification contents . . . . . 25
2.4 Robot list . . . . . 27
2.5 System parameters . . . . . 28
2.6 Result of Scenario 1.1 in Exp. 1 . . . . . 29
2.7 Result of Scenario 1.2 in Exp. 1 . . . . . 29
2.8 Condition of graph representation methods in Exp. 2 . . . . . 30
2.9 Cost of planned action sequence in Exp. 2 . . . . . 35
2.10 Cost for each strategies in Scenario 3.1 to 3.3 of Exp. 3 . . . . . 39
2.11 Cost of planned action sequences in Scenario 3.4 of Exp. 3 . . . . . 39

3.1 Prior knowledge of action . . . . . 45

4.1 Prior knowledge of handover action . . . . . 73
4.2 Environmental scenarios of Experiment 1 . . . . . 78
4.3 Robot system parameters . . . . . 78
4.4 Result of recognition reliability . . . . . 87
4.5 Experimental conditions of method in Experiment 2 . . . . . 90
4.6 Expected recognition reliability at planned action positions and cost of plans . . . . . 90

# Nomenclature

| | |
|---|---|
| $\mathbf{G}^a$ | Set of Prior Action Possibility Graph |
| $\mathcal{A}$ | Set of Action |
| $\mathcal{K}$ | Prior Knowledge of Action |
| $\boldsymbol{p}^a$ | Feasible Positions for Actions |
| $\boldsymbol{p}^g$ | Robot gazing position |
| $\boldsymbol{p}^h$ | Position of human |
| $\boldsymbol{p}^o$ | Position of Object |
| $\boldsymbol{p}^R$ | Position of Robot |
| $\boldsymbol{p}^r$ | Reachable Positions |
| $\boldsymbol{p}_g^R$ | Goal position of Task Planning |
| $\boldsymbol{p}^{v^a}$ | Position of Node in Action graph |
| $\theta^o$ | Direction of Object |
| $A$ | Action Sequence |
| $a_i$ | $i$-th Action |
| $c^a$ | Cost of Action |
| $C^r$ | Coefficient of Update Function of Recognition Reliability |
| $C^{Depth}$ | Coefficient of Depth Sensor Characteristics |
| $C^P$ | Coefficient of A* Search Algorithm based on Potential Field |
| $C_{1\sim2}^{RGB,A}$ | Coefficients of Human Pose Estimation Characteristics depending on Angle to Human |
| $C_{1\sim3}^{RGB,D}$ | Coefficients of Human Pose Estimation Characteristics depending on Distance from Human |
| $C^S$ | Coefficient of Human Voice Recoginition Characteristics |
| $cost(n, m)$ | Cost for movement from node $n$ to $m$ for A* Search Algorithm |
| $d^a$ | Appropriate Distance for Action |

| | |
|---|---|
| $E^a$ | Edge Set of Action graph |
| $e^a$ | Effect of Action |
| $e_i^a$ | $i$-th Edge of Action graph |
| $E^s$ | Edge Set of Scene Graph |
| $e_i^s$ | $i$-th Edge of Scene Graph |
| $G^a$ | Action Graph |
| $G_i^a$ | $i$-th Action Possibility Graph |
| $G_i^m$ | Action Possibility Graph for Movement |
| $G_i^s$ | $i$-th Scene Graph |
| $G_{a,e}^s$ | Effect Scene Graph of Action |
| $G_{a,p}^s$ | Precondition Scene Graph for Action |
| $G_g^s$ | Scene Graph for Goal Specification of Task Planning |
| $goal$ | Goal state of Task Planning |
| $init$ | Initial state of Task Planning |
| $l^a$ | Label of Action |
| $l^o$ | Label of Object |
| $N^o$ | Number of Object |
| $N^{p^a}$ | Number of Action positions |
| $o_e^a$ | Effected Obstacle by Action |
| $o_t^a$ | Target Obstacle of Action |
| $O_i$ | $i$-th Environmental State |
| $o_i$ | $i$-th Object |
| $P$ | Multimodal Potential |
| $P^H$ | Interaction Potential |
| $P^I$ | Human Image Potential |
| $P^O$ | Obstacle Potential |
| $P^R$ | Recognition Potential |
| $P^V$ | Human Voice Potential |
| $r^I$ | Human Image Sensing Characteristics |

| | |
|---|---|
| $r^S$ | Human Voice Sensing Characteristics |
| $R_i$ | $i$-th Robot State |
| $r^I_{All,i}$ | Recognition Reliability of $i$-th human |
| $r_{k,i}$ | Recognition Confidence of $k$-th Joint of $i$-th Human in Pose Estimation |
| $s^o$ | Shape of Object |
| $V^a$ | Node Set of Action graph |
| $v^a_i$ | $i$-th Node of Action graph |
| $V^s$ | Node Set of Scene Graph |
| $v^s_i$ | $i$-th Node of Scene Graph |
| $w^J_k$ | Importance Weight of $k$-th Joints |
| $w^S$ | Voice Importance |
| $W_i$ | $i$-th World State |

# Chapter 1

# 序論

## 1.1 サービスロボット

### 1.1.1 サービスロボットの需要

近年の急速な高齢化社会の進行により，あらゆる産業において労働力不足に陥ることが懸念されている [1]．労働力不足の解決に向け，製造現場における産業用ロボットだけでなく新たな分野へのロボットの普及が拡大し始めている [2]．そのロボットの需要が高まる新たな分野として，サービス産業が挙げられる．サービス業における活躍が期待されるロボットはサービスロボットと呼ばれ．顧客とのコミュニケーション，清掃，接客，介護，調理，家事支援など幅広いサービスを担うことが期待されている．医療・介護，建設，インフラ点検，物流・搬送，オフィス・店舗，農業など幅広い業界においてサービスロボットの需要が増大している [3]．

### 1.1.2 サービスロボットへの要求

サービスロボットには，人の生活空間において人の指示に基づき，片付けや運搬などに代表される多様なタスクを円滑に達成することが求められる．サービスロボットは多様なタスクを達成することが期待されているため，Fig. 1.1 に示すようにロボットは多様化しており，それぞれのロボットが備えている機能も多様化している．BellaBot [4] は，近年大衆飲食店で加速度的に導入が進んでいる配膳ロボットの一種であり，運搬能力に重点が置かれた設計となっている．一方，navel [5] は，コミュニケーションロボットであり，発話や表情，ジェスチャー等で意思表示をする機能が備わっており，環境に物理的に干渉する目的ではなく人とのコミュニケーションに重点を置いた設計となっている．また，TIAGo [6] は，移動機能やマニピュレーション機能等を有しており，環境へ干渉することに重点を置いた設計となっている．このように，ロボットの設計コンセプトにより有しているサブシステムや個々のサブシステムの性質は多様化しているため，それぞれのロボットの機能を有効活用する体系的な考え方が必要となる．

サービスロボットの活躍が期待される環境の一例を Fig. 1.2 に示す．人の生活空間では，人の活動により人や物体の配置などの環境状態が時々刻々と変化するため，サービスロボットには状況に応じて動作を判断しつつタスクを遂行することが求められる．すなわち，ロボットが実行するべき動作を事前に固定することは困難であり，人の指示や周辺環境に応じて動作を計画する必要がある．

ロボットが人の生活空間において円滑にタスクを実行するための計画手法を構築するうえで，考慮すべき項目を以下に二つ挙げる．一つ目は，ロボットの振る舞いが，人間社会に受け入れられるものであり，人の性質に寄り添った設計となっていること．二つ目は，ロボットの振る舞いが，ロボットが有する機能やおかれた環境を活かせるように設計されていることである．本研究論文では特に二つ目の要素に着目する．これまで，人

(a) BellaBot [4]

(b) navel [5]

(c) TIAGo [6]

Figure 1.1: Diversification of service robot types

Figure 1.2: An example of environments in where robots work

の生活空間における従来のロボットの動作計画では，一般的に環境中のすべての物体を障害物として避ける受動的な考え方が適用されてきた．しかし，サービスロボットが活躍する人の生活空間は人を中心に設計されているため，その環境は必ずしもロボットがタスクを遂行しやすい環境とは限らない．そのため，人の生活空間において円滑にタスクを遂行するためには，環境中の物体や人に働きかける行動によりタスクを遂行しやすい環境を作り出すといった，各ロボットの機能や置かれた環境を有効活用することが重要である．

従来のサービスロボットのタスクでは，サービス対象の人への働きかけに焦点が当てられてきたが，本研究では自身の機能を活かしつつタスクを達成するため，環境中のサービス対象以外の人や物体へも能動的に働きかけることを考慮する．また，サービス対象の人への働きかけにおいても，従来は人の性質を重視しロボットの動作が設計されてきたが，本研究ではロボットの機能を活かしやすさを考慮して動作を設計する．以上の設計により，ロボットの機能や環境を活かすことで，実空間における円滑なタスク遂

行を実現する．

### 1.1.3 想定条件

#### タスクに関する想定条件

本論文で扱うタスクは，ロボットを指定された位置へ移動させるロボットナビゲーションタスクと，指定された環境条件を満たすように物体を移動させ環境状態を変更するモバイルマニピュレーションタスクとする．ロボットに指示されるタスクは静的に指定され，動的にタスクが変更されることや新たにタスクが割り込むことは起こりえないこととする．最終状態でロボットの位置や環境条件を満たす限り，タスクを遂行する過程で環境を変更することは可能とする．

#### タスク，行動（アクション），動作（モーション）の関係性

ロボットに指令されるタスクはロボットが満たすべき条件で指定される．ロボットナビゲーションタスクでは，ロボットの胴体が満たすべき目標位置を，実空間を連続的に表現した幾何空間の絶対座標系における 2 次元座標で指定する．本研究では，ロボットの高さ情報は扱わない．モバイルマニピュレーションタスクでは，目標状態において満たすべき物体の配置を実空間を離散的に表現した記号空間の表現で指定される．例えば，”コーヒを机に運んでほしい”という内容を指示する場合には，”テーブルの上のカップにコーヒーが入っている”ことを意味するシーングラフなどの記号表現を用いて目標状態を指定する．同じ環境に同じ名称の物体が複数存在する場合は，目標状態を実現する物体の ID をロボットに委ねることも可能であり，目標状態に物体の ID も含めてより詳細に指定することも可能である．一方，目標状態を記号表現に基づき指定するため，”テーブルの右から 5cm，上から 10cm の場所へコーヒーを置いて”といった幾何的に詳細な位置の指定は扱わない．

行動（アクション）$a$ とは，離散的な記号空間においては状態 $s_i$ から $s_{i+1}$ へ遷移させるものであり，位置空間やロボットのコンフィギュレーション空間などの連続的な幾何空間においては状態 $q_j$ から $q_k$ へ遷移させるものである．行動は，ロボットが実現可能な記号空間における状態遷移の最小単位である．また，行動は記号空間における離散的な変化を連続的な幾何空間に落とし込む役割を担っている．

動作（モーション）$Q = \{q_j, q_{j+1}, ..., q_k\}$ とは，記号空間における状態遷移に対応する幾何空間における状態遷移を実現するための状態列である．各行動は，その行動の目的を果たすロボットの位置系列や関節角度系列等の連続的な動作で実現される．

Fig. 1.3 に示すように，ロボットのタスクは一般的に移動，マニピュレーション，対話などを含む複数の離散的な行動 $a$ を実行することから達成される．タスクを達成するための行動列 $A = \{a_1, a_2, ..., a_n\}$ を決定することは，タスクプランニングと呼ばれる．また，各行動を実空間において実現するための幾何空間における動作を決定することは，動作計画と呼ばれる．

#### タスクを遂行するロボットに関する想定条件

ロボットの胴体に対し，環境中の物体が衝突した場合，タスクの遂行は失敗とする．しかし，ロボットのマニピュレータで環境中の物体に干渉することは可能とする．行動に関する知識は既知且つ不確かさはないものとし，各章で扱う行動の種類は Table 1.1 に示す通りである．そして，ロボットはその知識を用いて，タスク遂行時の環境状態やロ

Table 1.1: Available actions

| | Section 2 | Section 3 | Section 4 |
|---|---|---|---|
| *movement* | ◯ | ◯ | ◯ |
| *speech* 1 "Let me through" | ◯ | ◯ | |
| *speech* 2 "Please remove chair" | ◯ | | |
| *push chair* | ◯ | ◯ | ◯ |
| *pick up bottle* | | ◯ | ◯ |
| *place bottle* | | ◯ | ◯ |
| *handover bottle* | | | ◯ |

ボットの状態を考慮したうえで実行可能な行動や行動を実行することによる結果を把握する．ロボットが実行する行動のリスクや失敗することは考慮しない．また，ロボットは事前にSLAM(Simultaneous Localization and Mapping)により環境地図を取得しており，環境地図における自身の位置は自己位置推定アルゴリズムにより取得可能とする．さらに，環境センシングシステム等を用いることで環境中の物体の位置や種類，形状が取得可能とする．

タスクを遂行する環境に関する想定条件

環境中の人はロボットに協力的であるとし，基本は初期状態から状態変化せず，ロボットの指示に従ってのみ変化するとする．また，環境中の物体は，静的物体を想定しており，ロボットの行動によってのみ状態変更が可能であるとする．また，環境中へ動的に物体が追加されることは生じないこととする．

### 1.1.4 サービスロボットのタスクプランニングへの要求

ここでは，ロボットが有するサブシステムやおかれた環境を有効活用しつつタスクを遂行するうえで，行動列が満たすべき要求について整理する．

- 各行動が実空間において実行可能であること
- 行動列において一見タスクに関係のないロボットのサブシステムや環境中の物体も利用することが考慮されていること
- 移動距離や実行時間などの実空間における指標で行動列を評価すること
- 各行動において次の行動の実行しやすさを考慮していること

## 1.2 タスク・モーションプランニング

### 1.2.1 動向

本研究が関連する研究分野は，タスクプランニングとモーションプランニングを統合的に考慮したタスク・モーションプランニングである．

モーションプランニングでは，移動やマニピュレーションなどの個々の行動を対象に，幾何空間において初期状態から所望の目標状態までの台車位置や関節位置の連続的

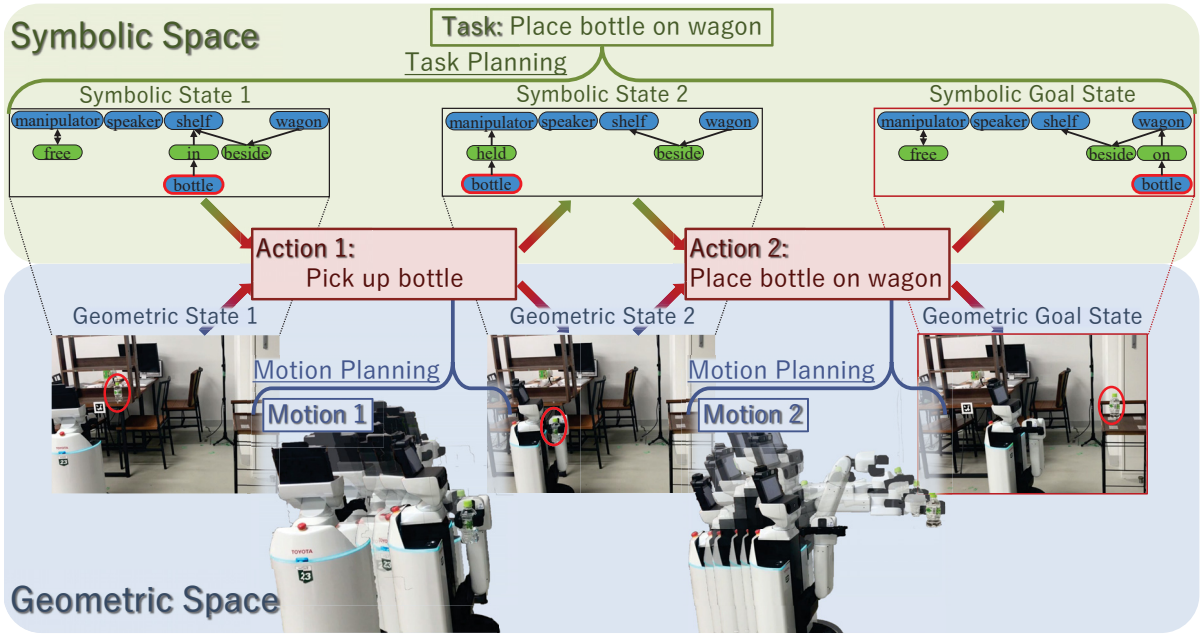


Figure 1.3: Relation between task, action and motion

な経路が決定される．ロボットのためのモーションプランニングアルゴリズムは主にサンプリングベースの手法 [7–9] と，最適化ベースの手法 [10, 11] が提案されている．サンプリングベースの代表的なアプローチとしては，自由空間をサンプリングし，ロードマップを生成する確率的ロードマップ法 (PRM: Probabilistic Roadmap) [7] や木を拡張し幾何空間を探索する Rapidly Exploring Random Tree (RRT) [8, 9, 12] などが挙げられる．

タスクプランニングでは，複数の物体の移動などのタスクを対象に，実行可能なアクションとその $Precondition$ や $Effect$ を定義するタスクドメインが与えられたうえで，初期状態から所望の目標状態までの一連の離散的な行動が決定される．タスクドメインは，Planning Domain Definition Language (PDDL) [13–15] などの記号空間における表現で記述される．Stanford search Institute Planning System (STRIPS) [16] をはじめとするタスクプランニング手法には，状態空間を効率的に探索するためのヒューリスティック探索手法 [17, 18] や制約充足問題として探索する手法 [19, 20] がある．

タスクを達成するロボットの動作は，離散的な行動の記号的な情報に基づき行動列を計画するタスクプランニングと幾何的な情報に基づき各行動の連続的な動作を計画する動作計画によって決定される．しかし，記号空間におけるタスクプランニングでは，物体集合とロボットの位置関係などに依存する実空間における行動の実行可能性の考慮が困難であるため，計画された行動列が実空間における動作計画が困難な行動を含む可能性や，タスクプランニングにおいて考慮される実行可能な行動が不足する可能性がある．

そこで，幾何空間における動作計画と記号空間におけるタスクプランニングを組み合わせるタスク・モーションプランニング手法が研究されている [21–26]．従来の一般的なタスク・モーションプランニングでは，初期状態から所望の目標状態までの一連の離散的な行動列とそれに対応する連続的な経路を計画し，実行可能な行動列と経路を取得する．具体的には，所望の目標状態を満たす行動列の探索の過程で，動作計画を交互に実施し，各行動の実行可能性，経路やコストを検証することで，行動列と経路を決定する．これにより，実行困難な行動が含まれる場合，その結果をタスクプランナにフィードバックすることで，実行可能な行動列を決定する．解法としては，記号的な計画手法で実行可能な行動列を取得する手法 [27–30] や最適化ベースの手法 [31] も存在する．また，より効率的かつ高速に解を得るアプローチや自然言語による指示を解釈するアプローチとして機械学習の応用もなされている [32–35]．さらに，動的環境など環境情報に不確かさ

が存在する場合には，動的に行動の実行可能性や行動列のコストが変化するが，それらの不確かさを考慮したうえでロバストに効率的な行動列を決定するためのタスク・モーションプランニング手法も提案されている [36–38].

タスクプランナから得られた各行動を動作計画に落とし込む際，行動に対応した幾何空間における目標状態を決定する必要がある．この目標状態の一般的な決定方法として，行動と事前にエンドエフェクタやその他の関節の目標状態を対応付ける方法や，複数サンプリングされたエンドエフェクタの目標状態の候補のうち，その他の関節状態やその行動の動作が決定可能なものを選択する方法がとられている．

### 1.2.2 課題

従来のタスク・モーションプランニングの多くでは，少ない探索でより早く実空間で実行可能な行動列を取得することを考慮したアルゴリズムが設計されている．しかし，実空間においてロボットの機能を活かすことができる行動列を取得するためには，移動距離やタスク遂行時間など実空間における指標がより良い評価となる行動列を計画するためのアルゴリズム設計が必要となる．1.1.4 項に述べたように，ロボットが有するサブシステムや環境を有効活用しつつタスクを遂行する上で，行動列や個々の行動の動作目標状態を決定する際，移動距離や実行時間などの実空間における行動列全体の評価や次以降行動の実行しやすさを考慮する必要がある．しかし，タスクプランニングと動作計画を階層的に組み合わせる従来のタスク・モーションプランニングにおける行動の実行可能性や目標状態の決定方法では，個々の行動のみに着目している．

従来のタスク・モーションプランニングの課題や，実空間における評価指標を考慮したタスク・モーションプランニングを実現する上での難しさは以下のとおりである．

- 従来のタスク・モーションプランニングでは，実空間における行動の位置関係に基づき，行動列における行動の順番や目標状態を決定することが困難である

  タスクプランニングと動作計画を階層的に組み合わせ，行動列と動作を個別に計画する従来の手法では，計画中に動作経路上にない物体やその物体に対応する行動の位置関係が考慮できないため，把握できる実行可能な行動の位置関係には限りがある．そのため，得られた行動列が物体集合とロボットの位置関係などに依存して実空間の評価が悪化する可能性がある．行動可能性を広げるため環境中の物体配置等に基づき物体へ干渉するといった行動列を導出するためには，実空間における行動の位置関係に関する評価に基づき行動の内容や順番，実行場所を同時に決定する必要がある．

- タスクプランニングと動作計画を統合する際，連続的な幾何空間をタスクプランニングへ落とし込む必要があるため探索空間が膨大となる

  実空間においてロボットの機能を活かす行動列を取得するためには，実空間における指標に基づき，行動列の内容と順番，実行場所を同時に決定する必要がある．しかし，タスクプランニングと動作計画を統合する際，連続的な幾何空間をタスクプランニングへ落とし込む必要があり，探索空間が膨大となる課題がある．

- 従来のタスク・モーションプランニングでは，個々の行動を動作計画における目標状態へ落とし込むうえで，次の行動の実行しやすさが未考慮である

  ロボットの機能を有効活用するためには，次の行動の実行しやすさを考慮したうえで個々の行動の目標状態を決定する必要がある．しかし，特にサービスロボットに必要とされる人とのインタラクション行動（HRI 行動）の実行しやすさは未考慮である．個々の行動の目標状態は，次の行動に関する記号的情報，ロボットのアク

チュエータやセンサなどのサブシステムや物体集合に関する幾何的な情報を同時に考慮する必要がある．

以上の課題を解決するため本研究では，実行場所に着目し，行動を幾何空間に埋め込み，連続的な幾何空間を適切に離散化することで，実空間を考慮したうえでロボットが実行可能な行動を網羅的に把握する表現を構築し，その表現に基づき行動列の内容と順番，実行場所を同時に決定する．さらに，個々の行動においてもロボットの機能を有効活用するため，行動に関する記号的情報，ロボットのサブシステムや物体集合に関する幾何的な情報を同時に考慮した行動の実行場所の決定により，行動の幾何空間への埋め込みを実現する．

## 1.3 本論文の目的と実現方法

### 1.3.1 本論文の目的

実空間においてロボットの機能や環境を活かすことができる行動列を取得するためには，連続的な幾何空間を適切に離散化することでタスクプランニングと動作計画を統合し，実空間における指標に基づき行動列の内容と順番，実行場所を同時に決定する必要がある．

そこで本研究では，実行場所に着目し行動を幾何空間に埋め込むことで，連続的な幾何空間を離散化し，実行可能な行動の時空間的な関係性（行動の実行場所とその変化）を把握することでタスクプランニングと動作計画を統合する．そして，実空間を考慮して把握した現在・未来にロボットが実行可能な行動の範囲でタスクを解釈することで行動列を決定する．

具体的には，実空間に実行可能な複数の行動を埋め込む方法として，行動の実行場所に着目し，行動に関する記号的情報や幾何的情報に基づく環境中のロボットの行動可能性（複数の行動の空間的な関係性：どこでどのような行動が実行可能か）を記述する表現手法を構築する．行動の実行場所とは，移動行動同士が接続される位置や移動行動とその他の行動が切り替わる位置であり，行動に対応した動作の初期位置や目標位置に相当する位置である． さらに，ロボットが行動することによる行動可能性の変化も含めた行動の時空間的な関係性を計画に落とし込む表現手法を構築する．また，行動に関する情報やアクチュエータやセンサの性質に依存する次の行動の実行しやすさ考慮したうえで，個々の行動を構築した行動の時空間表現へ落とし込む手法を構築する．これにより，ロボットが選択可能な行動の内容と順番，実行場所を一つのグラフで表現する．そして，移動距離やタスク遂行時間など実空間における指標を評価関数とした最適化アルゴリズムをその表現に適用し，行動列の内容と順番，実行場所を同時に最適化する．本研究では，実空間における指標の例として移動距離を用いて行動列を評価する．そして得られる行動列は，ロボットが選択可能な行動を網羅的に把握したアクショングラフでの範囲で，移動距離が最小となる行動列である．

### 1.3.2 実現方法

ロボットの行動の実行場所に着目し，ロボットが実空間において実行可能な行動とその変化のグラフ表現であるアクショングラフを提案する．アクショングラフは，エッジを行動の実行，ノードを行動の実行場所としたグラフ表現であり，行動の時空間的な関係性を表現する．アクショングラフの基本的な構築は，Algorithm 1 に示す通りである．まず，初期状態において，ロボットが実行可能な行動の空間的な関係性を表現する行動可能性グラフを Algorithm 2 に示す **GetActionPossibilityGraph** に基づき構築する．そして，Algorithm 3 に示す **GetPosteriorActionPossibilityGraphs** に基づき，ロボット

**Algorithm 1** Overview of Action Graph Construction

**Require:** Prior Knowledge of Action $\mathcal{K}$, Observed Environmental State $O_0$
**Ensure:** Action Graph $G^a$
1: $G_0^a$ := **GetActionPossibilityGraph**($\mathcal{K}$, $O_0$)
2: $\mathbf{G}^a$ := **GetPosteriorActionPossibilityGraphs**($\mathcal{K}$, $O_0$, $G_0^a$)
3: $G^a$ := GetActionGraph($G_0^a$, $\mathbf{G}^a$)

**Algorithm 2** Construction of Action Possibility Graph

1: **function** GetActionPossibilityGraph(Prior Knowledge of Action $\mathcal{K}$, Environmental State $O_i$)
2: $G_i^a.\mathcal{A}$:= AssociateActionsWithEnvState($\mathcal{K}$,$O_i$)
3: $\boldsymbol{p}^{\boldsymbol{r}}$:= GetReachablePositions($O_i$)
4: $\boldsymbol{p}^{\boldsymbol{a}}$:= GetFeasiblePositionsForActions($\mathcal{K}$, $G_i^a.\mathcal{A}$)
5: $G_i^a.V^a$ :=$\boldsymbol{p}^{\boldsymbol{r}}\cup\ \boldsymbol{p}^{\boldsymbol{a}}$
6: $G_i^a.E^a$ := GetEdges($O_i$, $G_i^a.V^a$)
7: **return** $G_i^a$
8: **end function**

が環境変化を起こした後の行動可能性グラフを構築する．最後に，環境変化前後の行動可能性グラフをエッジで接続することで，行動の時空間的な関係性を表現するアクショングラフを構築する．

本研究では，まず，アクショングラフをロボットナビゲーション問題に適用し，アクショングラフとそれに基づく移動計画のアルゴリズムを提案する．その際，アクショングラフではロボットの行動による環境中の物体の配置変化に伴う，移動可能性の変化を扱うため Algorithm 3 の事後行動可能性グラフの構築手法 **GetPosteriorAction PossibilityGraphs** により，多層構造のアクショングラフを構築する．

次に，アクショングラフをロボットのモバイルマニピュレーションタスクに適用するため，環境状態とロボット状態も含めた世界状態を対象とした世界状態依存アクショングラフを提案する．世界状態依存アクショングラフでは，世界状態と実行可能な行動の相互作用を計画に落とし込むため，アクショングラフを時間方向に拡張する．特に，ロボットが実現可能な世界状態と行動の時空間的関係性を網羅的に把握するため，事後行動可能性グラフの構築手法 **GetPosteriorActionPossibilityGraphs** を Algorithm 4 に示すものへ変更し，再帰的多層構造を有するアクショングラフを構築する．

また，Algorithm 2 に示す実行可能な行動の空間的な関係性を把握する行動可能性グラフの構築手法 **GetActionPossibilityGraph** における，行動を実空間に埋め込む処理

**Algorithm 3** Construction of posterior action possibility graphs for ASTRON

1: **function** GetPosteriorActionPossibilityGraphs(Prior Knowledge of Action $\mathcal{K}$, Environmental State $O_0$, Action Possibility Graph $G_0^a$)
2: $\mathbf{G}^a := \{\}$
3: **for** $i = 1$ to $i \leq |G_0^a.\mathcal{A}|$ **do**
4: $O_i$ := PredictEnvironmentState($\mathcal{K}$,$O_0$, $a_i^0 \in G_0^a.\mathcal{A}$)
5: $G_i^a$ := **GetActionPossibilityGraph**($\mathcal{K}$, $O_i$)
6: $\mathbf{G}^a \leftarrow \mathbf{G}^a \cup \{G_i^a\}$
7: **end for**
8: **return** $\mathbf{G}^a$
9: **end function**

**Algorithm 4** Construction of posterior action possibility graphs for WDAG

**function** GetPosteriorActionPossibilityGraphs(Prior Knowledge of Action $\mathcal{K}$, World State $W_0$, Action Possibility Graph $G_0^a$)
  $i := 0$
  $j := 0$
  $\mathbf{G}^a := \{\}$
  $\mathbf{W} := \{W_0\}$
  **while** $i >= j$ **do**
    **for** $k = 1$ to $k \leq |G_j^a.\mathcal{A}|$ **do**
      $W_{new}$ := PredictWorldState($\mathcal{K}$,$W_j$, $a_k \in G_j^a.\mathcal{A}$)
      **if** $W_{new} \notin \mathbf{W}$ **then**
        $i \leftarrow i + 1$
        $G_i^a$ := **GetActionPossibilityGraph**($\mathcal{K}$, $W_{new}$)
        $\mathbf{W} \leftarrow \mathbf{W} \cup \{W_{new}\}$
        $\mathbf{G}^a \leftarrow \mathbf{G}^a \cup \{G_i^a\}$
      **end if**
    **end for**
    $j \leftarrow j + 1$
  **end while**
  **return** $\mathbf{G}^a$
**end function**

である **GetFeasiblePositionsForActions** において，より詳細な情報を扱えるように拡張する．具体的には，サービスロボットの性質を考慮し，HRI に着目した人への接近行動を実空間へ落とし込むためのポテンシャル場を用いたアクションモデリング手法を構築し，経路計画手法とアクショングラフへの導入法を構築する．

## 1.4 本論文の構成

本論文の構成を Fig.1.4 に示す．第 1 章では，本研究全体の背景と目的，また課題解決の指針を述べた．第 2 章では，ロボットのナビゲーションタスクを対象に，複数の実行可能な行動の時空間的な関係性を記述するアクショングラフの構築アルゴリズムとそれを用いた計画手法について述べるとともに，提案の計画手法の有効性について検証する．第 3 章では，ロボットのモバイルマニピュレーションタスクを対象に，世界状態と行動可能性の相互作用を表現するため，アクショングラフを時間方向へ拡張した世界状態依存アクショングラフの構築アルゴリズムとそれを用いた計画手法について述べるとともに，提案の計画手法の有効性について検証する．第 4 章では，ロボットの HRI 行動のための人への接近行動を対象に，ロボットに搭載されたセンサの有効活用することによる HRI 行動を促進するため，接近行動を実空間に埋め込むアクションモデリング手法を提案し，ロボットナビゲーションタスクにおいて提案手法の有効性について検証する．さらに，コストマップで得られるアクションモデルに基づきアクショングラフを構築するアルゴリズムを提案し，提案手法の有効性について検証する．最後に，第 5 章で本論文の結論を述べる．各章の概要を以下に示す．

### 第 1 章

本論文の背景，研究目的を述べ，その位置づけと論文の構成を述べた．

**第 2 章**

ロボットナビゲーションにおいてロボットの備えている機能を有効活用するため，アクショングラフに基づきロボットが実空間で実行可能な複数の行動の時空間的な関係性において指令を解釈し，実現可能な行動列を取得するナビゲーション手法について述べる．具体的には，まず，実空間におけるロボットの行動可能性に着目した新たな環境表現であるアクショングラフを提案する．そして，アクショングラフに基づくタスク・モーションプランニングの設計例として，ロボットの移動タスクに着目した，Action based Spatio-Temporal RObot Navigation（ASTRON）を提案する，また，提案手法の有効性についてシミュレーションと実機実験により検証する．

**第 3 章**

ロボットのモバイルマニピュレーションタスクを対象に，実行可能な行動列の候補をより多く獲得することにより，実空間において環境とロボットが有する機能を有効活用するタスク・モーションプランニング手法について述べる．具体的には，世界状態に基づく行動可能性とロボットが実行する行動の相互作用を網羅的に把握し表現するため，アクショングラフを時間方向へ拡張した世界状態依存アクショングラフを提案する．そして，世界状態依存アクショングラフを用いたタスク・モーションプランニング手法の設計例を提案する．また，提案手法の有効性についてシミュレーションと実機実験により検証する．

**第 4 章**

アクショングラフの構築における個々の行動を実空間へ埋め込む処理に着目し，ロボットに搭載されているセンサを活かし HRI 行動を促進するための人への接近行動のアクションモデリング手法を提案する．そして，HRI 行動を実行する際，特に重要となる情報として人の画像情報や音声情報に着目し，それぞれの必要性に応じてカメラやマイクのマルチモーダル情報を取得可能な位置への接近を実現する．具体的には，カメラやマイクのセンサ特性や人の情報などの次元の異なる情報を実空間におけるポテンシャル場を用いて同じ情報空間へ統合するマルチモーダルポテンシャル場に基づくアクションモデリング手法について述べる．そして，接近行動のアクションモデルに基づくロボットナビゲーション手法とアクショングラフの設計例について述べる．また，提案手法の有効性についてシミュレーションと実機実験により検証する．

**第 5 章**

提案するアクショングラフに基づくタスク・モーションプランニングについてその特徴をまとめ，結論を述べる．また，本研究の現時点における課題よび制限事項を整理し，今後の展望を述べる．

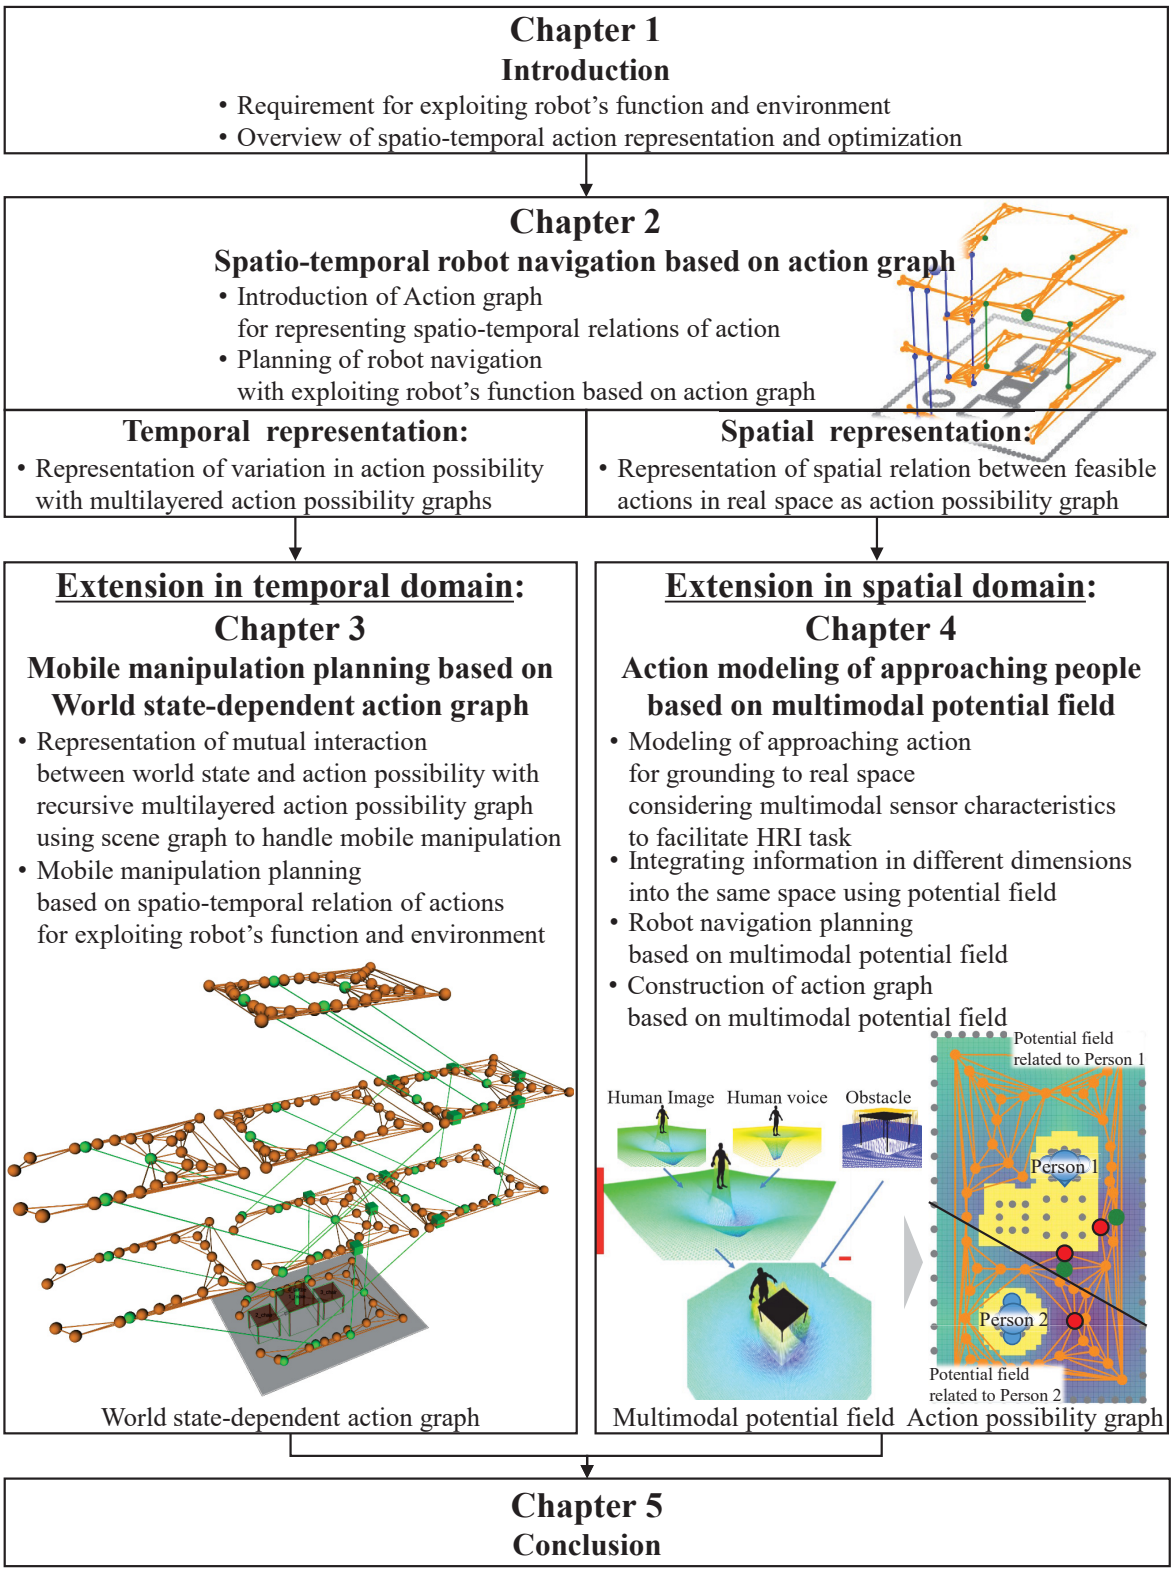


Figure 1.4: Overview of thesis

# Chapter 2

# アクショングラフに基づく時空間的ロボットナビゲーション

## 2.1 緒言

本章では，まず，本研究で取り扱う，実空間における行動可能性を考慮したタスクプランニングや動作計画，観測によって得られる環境情報に基づく環境表現に関する関連研究と，関連研究における課題を述べる．そして，ロボットナビゲーションにおいてロボットの備えている機能を有効活用するため実空間におけるロボットの行動可能性や，その変化の範囲内で指令を解釈し，実現可能な行動列を取得するナビゲーション手法について述べる．具体的には，Fig. 2.1 の全体像に示すように以下の二つについて述べる．

- 空間におけるロボットの行動可能性や，その変化を表現するための新たな環境表現のアクショングラフと，基本的なアクショングラフの自動構築アルゴリズム
- アクショングラフに基づく実空間におけるタスクプランニングの設計例として，移動タスクに着目した，Action based Spatio-Temporal RObot Navigation（ASTRON）

最後に，提案手法の有効性をシミュレーションと実機実験で検証する．具体的には，アクショングラフの構築において，Subsystem-level Affordance や幾何推論の双方を考慮すること，多層構造を採用することで多様な行動が表現可能で，環境内で選択可能な戦略を把握できることを検証した．さらに，提案手法により実世界において実行可能でサブシステムを有効活用可能な行動列を計画可能であることを検証するため，サブシステム構成の異なる複数のロボットを対象とした実機実験を実施した．

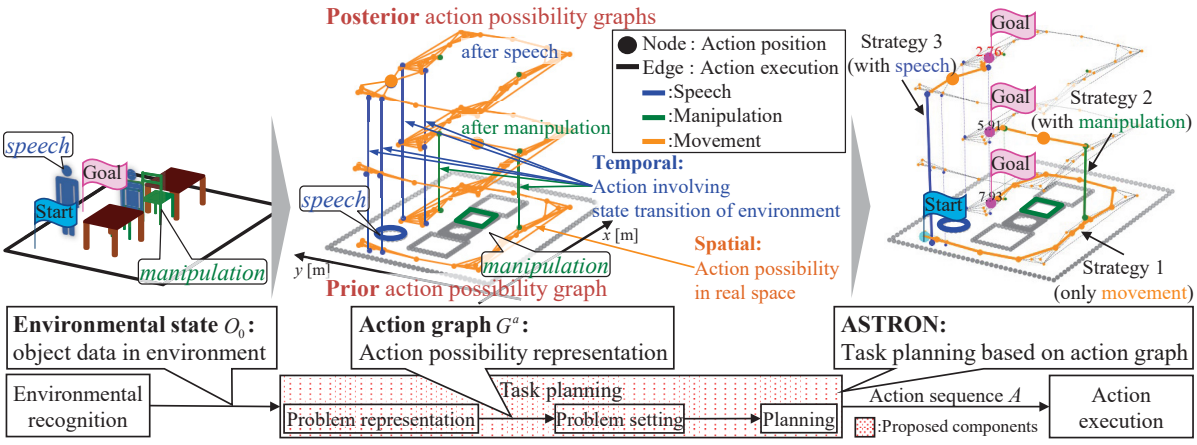


Figure 2.1: Overview of ASTRON

## 2.2 既存研究とその課題

### 2.2.1 タスクプランニングと動作計画

本研究は，実空間における行動の実現可能性を考慮したタスクプランニングや動作計画に関連している．その既存手法の 1 つとして，記号空間におけるタスクプランニングとコンフィギュレーション空間における動作計画を組み合わせた Task and motion planning(TAMP) があげられる [22, 23, 39]．また，他の手法として，障害物を回避するだけでなく移動可能な障害物への干渉も考慮したナビゲーション手法である Navigation Among Movable Obstacles(NAMO) が挙げられる [40, 41]．これらの手法において，実空間における行動の実現可能性は以下の二つの手順に基づき検証される．まず，対象の環境において干渉可能な物体を除外した上で，各行動の目標状態に向かう経路を計画する．次に，動作計画で取得した経路と除外した鑑賞可能な物体の位置関係との交差を検証する．交差している場合，その行動は実行困難な行動として認識された上で，その交差した物体へ干渉する行動をロボットが実行するべき行動，すなわち，検証した行動の必要条件として認識される．動作計画において，一般的に経路は直線的に目的地へ向かうヒューリスティクスに基づき計画される．そのため，動作計画に基づき行動の実現可能性や必要な行動を検証するアプローチでは，直接目標位置に向かわない一見遠回りに見える行動列を決定することは困難である．

一方，提案手法では，まず，ロボットが認識している全ての物体集合とロボットのサブシステム構成に基づきアクショングラフを構築することで，実空間においてロボットが実行可能な行動を把握することが可能である．さらに，構築したアクショングラフに基づくタスクプランニングでは，目的地に到達する上で選択可能な環境変化毎に，行動列を計画することが可能である．これにより，目標位置に直接向かわない戦略も含めて環境中で選択可能な戦略をより多く把握することが可能であり，その中から適切な戦略を選択することが可能である．

### 2.2.2 環境表現

本研究は，環境表現手法にも関連している．古典的な環境表現の一つに Simultaneous Localization And Mapping(SLAM) 等のアルゴリズムを通じて構築される占有格子地図が挙げられる [42]．占有格子地図では，実空間上の格子点における物体の有無の情報が表現され，従来のロボットの経路計画手法において活用されてきた．また，占有格子地図で表現される物体の有無の情報に加えて，名称などの物体の属性情報も埋め込まれたセマンティックマップと呼ばれる環境地図も存在する [43, 44]．さらに，3D シーングラフという，物体集合における各物体の属性情報だけでなく，物体間の 3 次元的な位置関係も記述する環境表現も提案されている [45]．これらの環境表現手法では，環境中に存在する物体集合に関する情報を正確に記述することを目的としており，それらの情報は従来の記号空間におけるタスクプランニングにおいて活用されてきた．

また，環境における物体情報だけでなく，行動に関する情報も記述する環境表現手法も提案されている．一つのアプローチとして，人の行動の履歴に基づき，行動の可能性を実環境に埋め込む手法が提案されている [46, 47]．その他のアプローチとして，アフォーダンスの概念に基づき物体を分類し，物体の場所に対して行動を紐づける手法が提案されている [48, 49]．

さらに，実空間における動作計画に活用することを念頭に置いた環境表現として，移動行動に着目した個々の行動に関する情報だけでなく行動間の繋がりを表現する手法が提案されている．占有格子地図 [42] やトポロジカルマップ [50, 51] では，実空間における走行可能性に基づく実行可能な移動が移動元と移動先の繋がりとしてグラフを用いて記述されている．また，Multi-Layer Environmental Affordance Map は，ロボットの移動行動の繋がりだけでなく環境中の物体集合に基づき推論された空間の概念等の情報を

占有格子地図に反映した環境表現であり，人の活動に配慮した移動経路の決定に活用されている [52].

一方，提案のアクショングラフでは，多層のグラフ構造を採用することで，環境変化を伴う行動による行動可能性の変化も表現可能である．これにより，移動行動だけでなく発話やマニピュレーションなど環境変化を伴う行動も含めた，複数種類の実行可能な行動の繋がりを表現することを実現した.

## 2.3 アクショングラフ

### 2.3.1 概要

アクショングラフ $G^a$ では，認識した環境状態 $O_0$ に基づき，ロボットが実空間においてどこでどの物体に対してどのような行動が実行可能であるかの情報である行動可能性と，その変化を行動のつながりで表現する．

環境状態 $O_0 = \{o_1, o_2, \ldots, o_{N^o}\}$ は，$N^o$ 個の物体の集合である．本研究では，物体の種類の例として，人，椅子，机を扱う．物体 $o$ に含まれる情報は以下のとおりである．

- $l^o$: 物体のラベル
- $\boldsymbol{p}^o$: 絶対座標系の 2 次元平面における物体位置
- $\theta^o$: 絶対座標系の 2 次元平面における物体の向き
- $s^o$: 四角形や円形などの単純な幾何形状と大きさなどの情報から構成される物体の形状情報．人は円形で表現され，椅子や机は四角形で表現される．

アクショングラフ $G^a$ は，ノード集合とエッジ集合で定義される $G^a = (V^a, E^a)$．ここで，$V^a$ はノード集合，$E^a$ はエッジ集合である．アクショングラフにおけるノード $v^a$ は実空間におけるアクションの実行場所を示している．各ノード $v^a$ に含まれる情報は以下の通りである．

- $\boldsymbol{p}^{v^a}$: 絶対座標系の 2 次元平面におけるロボットが行動を実行可能の位置

また，エッジ $e^a$ には行動 $a$ が割り当てられており，ノード間の遷移はエッジに割り当てられた行動 $a$ の実行を意味するそれぞれのエッジ $e^a$ に含まれる情報は以下の通りである．

- $a$: 実行する行動の内容
- $c^a$: 移動距離や所要時間など行動の実行に伴うコスト

行動 $a$ には名称や行動対象の物体名称，作用対象の物体名称等，行動を実行するために必要な情報が含まれる．行動 $a$ に含まれる具体的な情報は，2.3.3 項に述べる．

アクショングラフ $G^a$ は，複数の行動可能性グラフから構成される．行動可能性グラフは，環境状態とロボットのサブシステム構成に基づき，ロボットが実行可能な行動とその実行場所を示すグラフである．実行可能な行動の実行場所は行動可能性グラフのノードで表現される．また，行動可能性グラフ内のエッジでは実空間上を移動する移動行動が表現される．さらに，環境変化に伴い行動の可能性も変化するため，環境変化を伴う行動は，環境変化前の行動可能性グラフ $G_0^a$ と環境変化後の行動可能性グラフ $G_1^a$ を接続するエッジで表現される．この複数の行動可能性グラフで構成されるアクショングラフでは，実行可能な行動とその行動を実行することによる行動可能性の変化を明確に記述可能である．例えば，環境変化前の行動可能性グラフ $G_0^a$ に，環境変化を伴う行動が含まれない場合，次式のように環境変化前の行動可能性グラフ $G_0^a$ とアクショングラフ $G^a$ は一致する．

$$G_0^a = G^a \tag{2.1}$$

しかし，環境変化前の行動可能性グラフ $G_0^a$ に環境変化を伴う行動集合 $\mathcal{A}$ が含まれる場合，アクショングラフ $G^a$ は環境変化前の行動可能性グラフ $G_0^a$ と環境変化後の行動可能性グラフ $G_{1\sim N^{\mathcal{A}}}^a$ を内包するグラフとなる．

$$G_0^a, G_1^a, \ldots, G_{N^{\mathcal{A}}}^a \in G^a \tag{2.2}$$

ここで，$N^{\mathcal{A}}$ は環境変化前の環境状態 $O_0$ において実行可能な環境変化を伴う行動の個数である．

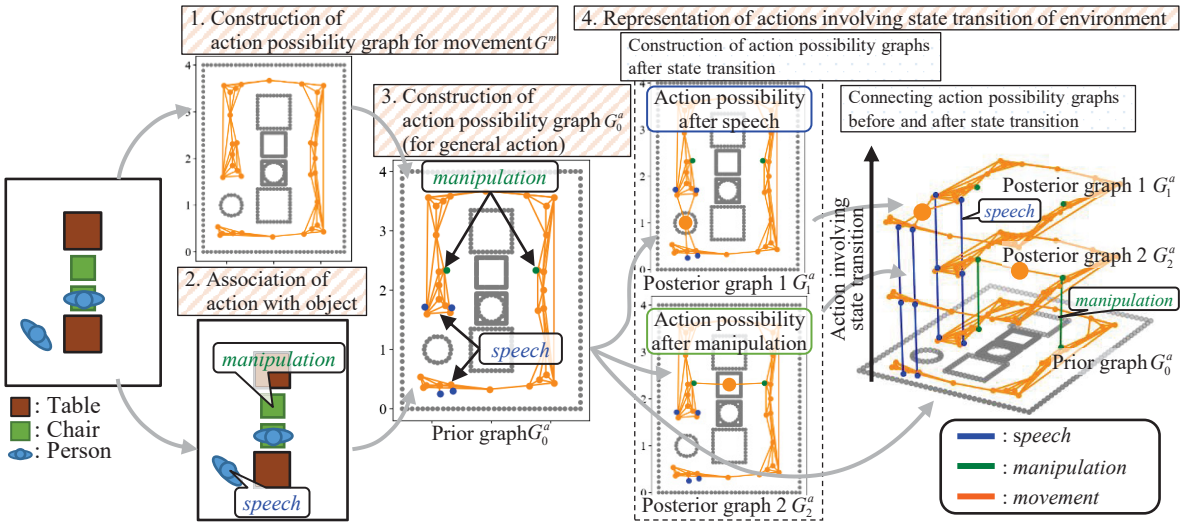


Figure 2.2: Action graph constructing pipeline

1. 環境中でロボットが到達可能な位置を把握するため，移動に関する行動可能性グラフ $G^m$ を構築 (2.3.2 項)
2. サブシステムベースのアフォーダンスに基づく環境中の物体と行動を対応付け (2.3.3 項)
3. 移動以外の行動も含めた行動可能性を表現するため，行動可能性グラフ $G_0^a$ の構築 (2.3.4 項)
   (a) 行動が対応付けられた各物体に到達可能な位置を移動のための行動可能性グラフ $G^m$ から選択
   (b) 物体にアプローチ可能な位置と対応付けられた行動の性質に基づき，行動に関するノードやエッジを移動のための行動可能性グラフ $G^m$ へ追加
4. アクショングラフにおける環境変化を伴う行動の表現 (2.3.5 項)
   (a) 環境変化を伴う行動による環境変化後の行動可能性グラフ $\mathbf{G}^a = \{G_1^a, \ldots, G_{N^\mathcal{A}}^a\}$ の構築
   (b) 環境変化前の行動可能性グラフ $G_0^a$ と環境変化後の行動可能性グラフ $\mathbf{G}^a$ をエッジで接続することによるアクショングラフ $G^a$ の構築

以下では各処理の詳細について述べる．

### 2.3.2 移動のための行動可能性グラフの構築

#### 概要

ロボットが到達可能な位置をスパースに表現するため，環境内で認識した物体の配置や大きさに基づき，移動のための行動可能性グラフ $G^m$ を構築する．屋内環境におけるロボットの移動行動を対象とするため，このグラフは 2 次元空間で構築される．以下に，Fig. 2.3a の環境を例とした本グラフの構築に関する具体的な処理の流れを示す．

#### 一般化ボロノイ図の構築

まず，壁を含めた環境中の物体のフットプリントを 2 次元平面上の点の集合で表現する．そして，Fig. 2.3b に示すように，物体のフットプリントを表現する点を母点とした一般化ボロノイ図を生成する．

#### 環境中の物体とロボットの形状に基づく到達可能なノードやエッジの抽出

一般化ボロノイ図にはロボットが到達できないエッジやノードが含まれるため，ロボットのフットプリントや環境中の物体の形状を考慮した上で，通過が困難なエッジや到達が困難なノードを削除し，Fig. 2.3c のようなグラフを得る．

#### 効率的な表現のためのグラフの簡略化

より効率的にロボットが到達可能な場所を表現するため，Fig. 2.3d のようにグラフを簡略化する．エッジの数が二つのノード同士が接続されている場合，それらのノードを一つのノードに統合する．その際，統合後の新たなエッジが障害物を遮らない場合，その統合は採用される．この統合を繰り返し実施することでノードの数を削減する．

#### ドロネー図に基づくノード同士の接続

ロボットの移動の効率性を改善するため，グラフ内の接続可能なノードを接続する．接続可能性は，ドロネーの三角分割をノードに適用し，そのエッジと物体の交差，ロボットのフットプリントに基づき検証する．そして最終的に Fig. 2.3e のような移動のための行動可能性グラフ $G^m$ を得る．また，移動のための行動可能性グラフ $G^m$ におけるエッジは移動行動を意味するため，エッジの $l^a$ には移動を割り当て，コスト $c^a$ はエッジの長さとタスクプランニングの評価指標に基づき算出する．

### 2.3.3 物体への行動の対応付け

ロボットと物体の間に存在する行動に関する関係性はロボットのサブシステム構成に応じて変化する．また，ロボットと物体の間に存在する行動の関係性は個々の物体の性質だけでなく，周囲の物体に応じて変化する．そこで，ロボットのサブシステム構成を考慮したアフォーダンスを Subsystem-level Affordance として定義する．Subsystem-level Affordance とは，ロボットが有するサブシステムと物体集合の間に存在する行動の関係性とし，物体集合とロボットが有するサブシステムに行動を対応付ける．ここで，ロボットが有するサブシステムは，ロボットを構成する部分的なアクチュエータ集合と定義し，移動台車やスピーカ，ディスプレイ，マニピュレータなどがサブシステムの例である．本研究では，アフォーダンスの分類手法 [48, 49] や行動理解手法 [53, 54] の発展に伴いアフォーダンスや行動に関する知識は取得可能として，Tables 2.1，2.2 に示す事前知識をロボットに与える．また，各ロボットは自身のサブシステムの構成は把握可能とする．そして，これらの事前知識とロボットのサブシステムの構成に基づき，環境中の物体集合に対して行動を対応付ける． Table 2.1 に示す Sub-system Level Affordance に基づき，物体集合とロボットのサブシステムの組み合わせに対して行動名称 $l^a$ を対応付ける．本研究で扱うサブシステムは例として，移動台車，スピーカ，マニピュレータとした．行動名称 $l^a$ の例は，*movement*，人にその場を通してもらえるよう依頼する *speech*1，人に椅子の移動を依頼する *speech*2, 椅子を移動させる *manipulation* を扱う．そして，Sub-system Level Affordance の詳細は以下の通りである．1 人の人に対してはスピーカが必要となる *speech*1，椅子単体にはマニピュレータが必要となる *manipulation* が対応付けられる．さらに物体集合に着目したうえで，人が椅子に座っている場合には行動は関連付けない

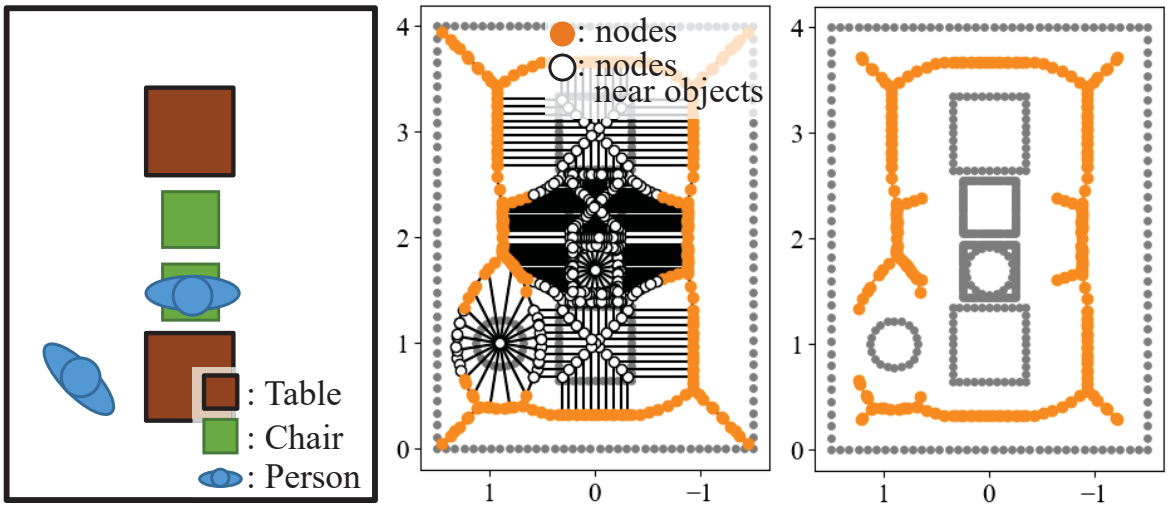


(a) Example of environment (b) Generalized Voronoi diagram (c) Extracting valid nodes considering objects

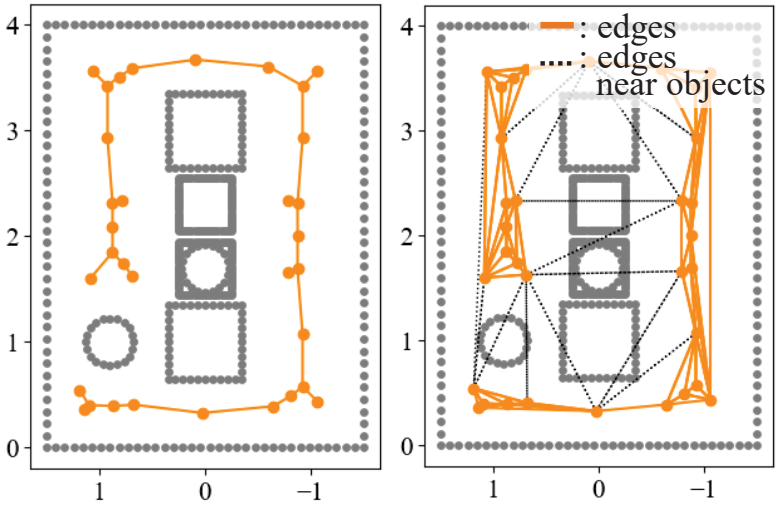


(d) Simplifying graph for efficient expression (e) Applying shortcut based on Delaunay triangulation

Figure 2.3: Construction of action possibility graph for movement

とし，人とその付近にある椅子に対してはスピーカが必要となる *speech2* が対応付けられる．具体的には，人と椅子の距離が，特定の範囲 $r^{speech2}$ 内の場合には *speech2* が対応付けられる．行動名称に対応する行動の性質は Table 2.2 に示す Action Property の通りである．アクショングラフ $G^a$ のエッジに埋め込まれる行動 $a$ の情報は Action Property と同様である．

行動の性質の各項目の内容は以下のとおりである．

- $l^a$: 行動名称
- $o_t^a$: ロボットが働きかける対象物体
- $d^a$: 行動を実行するために必要な対象物体との適切な距離
  この項目は，記号的な行動の情報を実空間に落とし込むうえで，必須の情報である
- $o_e^a$: 行動を実行した結果，作用を受ける物体
  $o_t^a$ と $o_e^a$ が一致している場合，$o_t^a$ は $itself$ とする．一方，例えば人に椅子の移動を依頼する *speech2* においては，$o_t^a$ は *person* で，$o_e^a$ は *chair* である．

Table 2.1: Prior knowledge of subsystem-level affordance

| | object set | 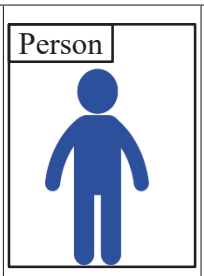 | 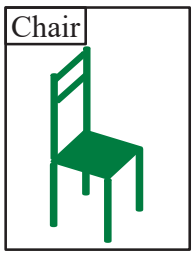 | 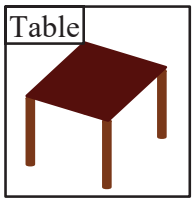 | 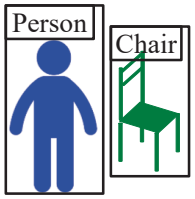 | 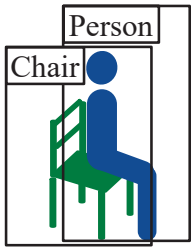 |
|---|---|---|---|---|---|---|
| subsystem | *mobile base* | none | none | none | none | none |
| | *speaker* | *speech*1 | none | none | *speech*2 | none |
| | *manipulator* | none | *manipulation* | none | none | none |

Table 2.2: Prior knowledge of action

| action label $l^a$ | *movement* | *speech*1 "Let me through" | *speech*2 "Please remove chair" | *manipulation* remove object |
|---|---|---|---|---|
| target object $o_t^a$ | none | person | person | chair |
| appropriate distance $d^a$ from $o_t^a$ | none | $d^s$ e.g., 0.5 m | $d^s$ e.g., 0.5 m | $d^m$ e.g., 1.0 m |
| influenced object $o_e^a$ | none | itself | chair | itself |
| effect $e^a$ | none | *removed* | *removed* | *removed* |

- $e^a$: 行動の結果，$o_e^a$ が受ける影響
  本研究では，効果の例として *removed* を扱う．*removed* は，$o_t^a$ は取り除かれ，その場所が移動可能となることを意味する．

Tables 2.1，2.2 で与えられるアフォーダンスや行動に関する事前知識は，設計例の一つであり拡張可能である．

### 2.3.4 行動可能性グラフの構築

**概要**

行動可能性グラフ $G_0^a$ では，*movement* 行動だけでなく，物体に対応付けられた行動も含めた，一般的な行動の実行位置を表現するグラフである．行動の実行位置が満たすべき条件は，ロボットのフットプリントや周辺の障害物を考慮したうえで，ロボットがその場所へ到達可能であること，その場所から行動の対象 $o_t^a$ へ到達可能であること，そして行動の対象 $o_t^a$ から行動の実行に適した距離を確保できることである．

行動が対応付けられた物体毎に，Fig. 2.4 に示す手順を適用し，移動に関する行動可能性グラフ $G^m$ に各行動の実行位置に関するノードやエッジを追加することで行動可能性グラフ $G_0^a$ を取得する．

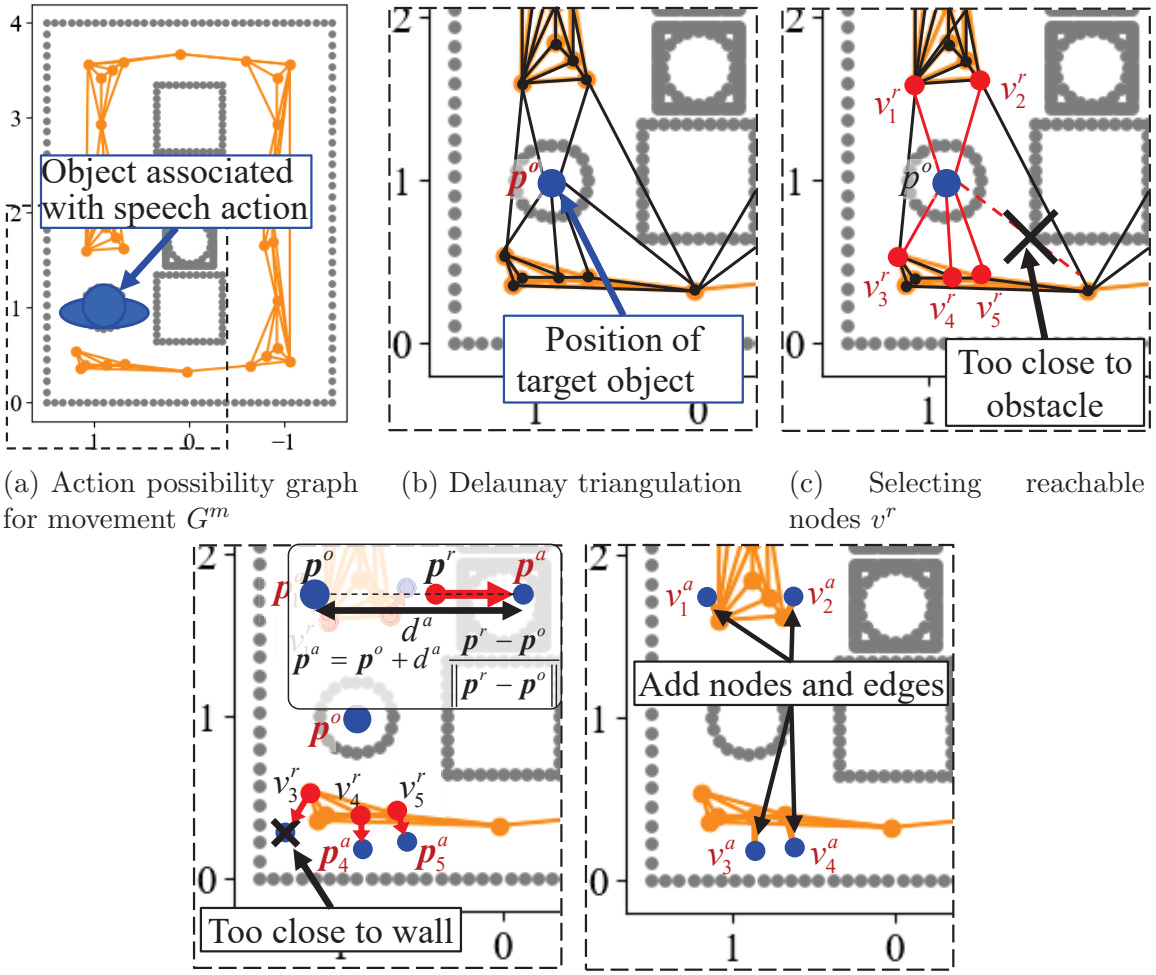


(a) Action possibility graph for movement $G^m$

(b) Delaunay triangulation

(c) Selecting reachable nodes $v^r$

(d) Determining action position $p^a$

(e) Action possibility graph

Figure 2.4: Construction of action possibility graph

### 到達可能ノードの選択

移動に関する行動可能性グラフ $G^m$ におけるロボットが到達可能な位置の中から行動の対象物体に到達可能なノード $v^r$ を選択する．

まず，Fig. 2.4b に示すように移動に関する行動可能性グラフ $G^m$ のノードと行動の対象物体の位置 $p^o$ を含めてドロネー三角形分割を適用する．そして，Fig. 2.4c に示すように到達可能なノード $v^r$ を決定する．ドロネー三角形分割の結果における，行動の対象物体に接続されているノードを到達可能なノード $v^r$ の候補とする．そして，その候補の中で，ロボットのフットプリントや周辺の障害物を考慮したうえで，行動の対象物体へ到達可能なものを到達可能ノード $v^r$ として採用する．

### 行動の実行場所に対応するノードの追加

行動を促進するため，事前知識で与えられている行動の性質の一つである行動を実行するために必要な対象物体との適切な距離 $d^a$ と選択された行動の対象物体に到達可能なノード $v^r$ を基準に行動の実行位置 $\boldsymbol{p}^a$ を決定する．そして，移動に関する行動空間グラフ $G^m$ へ行動の実行位置 $\boldsymbol{p}^a$ に関連するノード $v^a$ とエッジを追加する．

まず，Fig. 2.4d や次式で示すように，行動の対象物体に到達可能なノードの位置 $\boldsymbol{p}^r$

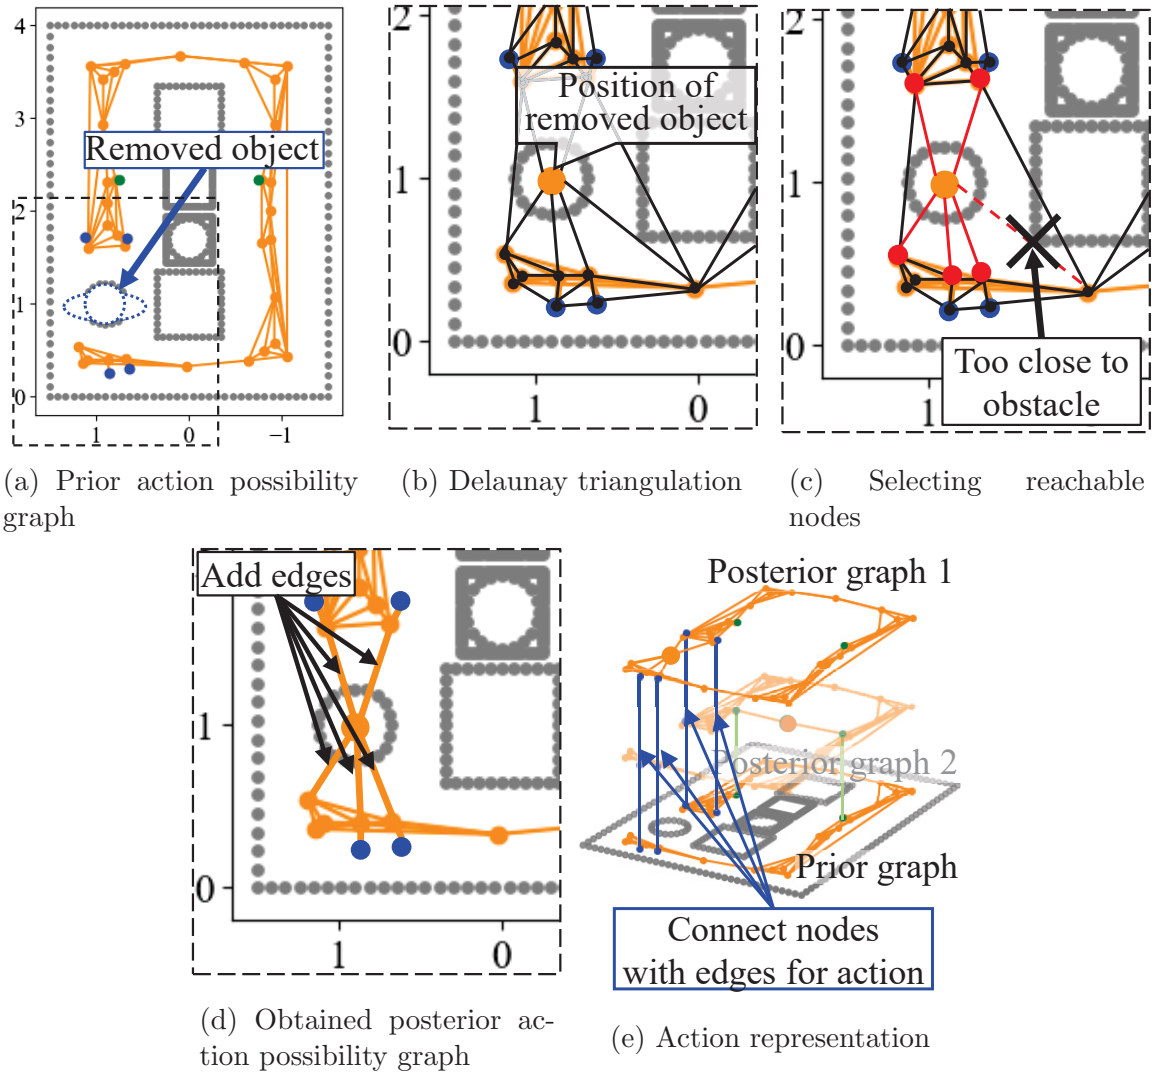


(a) Prior action possibility graph

(b) Delaunay triangulation

(c) Selecting reachable nodes

(d) Obtained posterior action possibility graph

(e) Action representation

Figure 2.5: Construction of action possibility graph after state transition of environment and Representation of actions involving state transition

と行動の対象物体の位置 $\boldsymbol{p}^o$ を結ぶ直線上かつ，$\boldsymbol{p}^r$ から行動を実行するために必要な対象物体との適切な距離 $d^a$ だけ離れた位置を行動の実行位置 $\boldsymbol{p}^a$ の候補とする．

$$\boldsymbol{p}^a = \boldsymbol{p}^o + d^a \frac{\boldsymbol{p}^r - \boldsymbol{p}^o}{\|\boldsymbol{p}^r - \boldsymbol{p}^o\|}, \tag{2.3}$$

次に，Fig. 2.4d に示すように，周辺の障害物とロボットのフットプリントを考慮し，行動の実行位置の候補の中からロボットが行動対象 $\boldsymbol{p}^o$ へ到達可能なものを $\boldsymbol{p}^a$ として採用する．最後に，Fig. 2.4e に示すように，行動の実行位置 $\boldsymbol{p}^a$ に対応するノード $v^a$ と，$v^a$ と $v^r$ を接続するエッジを移動に関する行動空間グラフ $G^m$ へ追加し，行動可能性グラフ $G_0^a$ を取得する．また，行動可能性グラフ $G_0^a$ におけるすべてのエッジの行動名称 $l^a$ には，*movement* 行動が割り当てられ，コスト $c^a$ はエッジの長さとタスクプランニングのコスト設計に基づき算出する．

### 2.3.5 環境変化を伴う行動の表現

#### 概要

物体配置の変化などの環境変化を伴う行動の実行を実行した後には，ロボットが実行可能な行動は変化するそのため，アクショングラフでは，環境変化を伴う行動は，環境変化前後の行動可能性グラフを接続する有向エッジで表現される．

まず，物体に対応付けられた行動の性質に基づき実現可能な環境の状態遷移を把握する．次に，把握した各状態遷移後の事後行動可能性グラフ $G^a_{1\sim N^{\mathcal{A}}}$ を構築する．ここで，$N^{\mathcal{A}}$ は初期の環境状態 $O_0$ に対応付けられた環境変化を伴う行動の数である．最後に，事前の行動可能性グラフ $G^a_0$ と各事後の行動可能性グラフ $G^a_{1\sim N^{\mathcal{A}}}$ を，その環境の状態遷移の原因となる行動を表すエッジで接続し，アクショングラフ $G^a$ を構築する．これにより，*movement* 行動だけでなく，サブシステム構成と事前知識に基づき物体集合に対応付けられた環境の状態遷移を伴う行動を実世界におけるグラフで表現することを実現している．

状態遷移を伴う行動の表現手法の詳細について以下に述べる．

#### 実現可能な環境状態の把握

初期の環境状態 $O_0$ から一度の環境変化で実現可能なすべての環境状態 $O_{1\sim N^{\mathcal{A}}}$ を把握する．具体的には，実現可能な環境状態 $O_{1\sim N^{\mathcal{A}}}$ は，物体に対応付けられた行動と Table 2.2 に示された行動の性質に基づき，行動の作用を受ける物体 $o^a_e$ と行動の効果 $e^a$ の組み合わせとして把握される．

#### 環境の状態遷移を伴う行動後の行動可能性グラフの構築

把握した実現可能な環境状態，すなわち，行動の作用を受ける物体 $o^a_e$ と行動の効果 $e^a$ の各組み合わせに対して，環境変化の事後行動可能性グラフ $G^a_{1\sim N^{\mathcal{A}}}$ を構築する．グラフを構築する際，事前知識の行動の効果 $e^a$ には不確かさはないと仮定する．

一般的には，事後の行動可能性グラフ $G^a_n$ は，初期の環境状態 $O_0$ や各行動の作用を受ける物体 $o^a_e$，行動の効果 $e^a$ に基づき，事前の行動可能性グラフ $G^a_0$ から関連するノードやエッジを追加，削除することで構築する．ここでは，図 5 に示すような，本研究で扱う行動の効果 $e^a$ である *removed* を対象に，より簡易的に事後の行動可能性グラフ $G^a_n$ を構築する手法を述べる．*removed* の効果は，行動の作用を受ける物体 $o^a_e$ が移動させられ，その場が通過可能となることを意味している．そのため，行動の作用を受ける物体 $o^a_e$ の位置が移動可能となったことを表現するように事前の行動可能性グラフ $G^a_0$ へノードとエッジを追加することで事後の行動可能性グラフ $G^a_n$ を構築する．

まず．事前の行動可能性グラフ $G^a_0$ へ行動の作用を受ける物体 $o^a_e$ の位置に新たなノードを追加する．次に．Fig. 2.5b に示すように．事前の行動可能性グラフ $G^a_0$ のノードと $o^a_e$ の位置のノードに対してドロネー三角形分割を適用する．$o^a_e$ の位置へ到達可能なノードの候補は，ドロネー三角形分割の結果における，$o^a_e$ の位置に接続されたノードである．そして，Fig. 2.5c に示すように．その候補の中で．ロボットのフットプリントと周辺の物体を考慮したうえで，新たなノードに到達可能なものを選択する．最後に，Fig. 2.5d に示すように，新たなノードと選択された到達可能なノードをエッジで接続したものを事後の行動可能性グラフ $G^a_n$ として取得する．追加したエッジの行動名称には *movement* 行動を割り当て，コストはエッジの長さとタスクプランニングのコスト設計に基づき決定される．

把握した行動の作用を受ける物体 $o^a_e$ と行動の効果 $e^a$ の各組み合わせに対して，以上の処理を実施し，環境変化後の事後の行動可能性グラフ $G^a_{1\sim N^{\mathcal{A}}}$ を構築する．

事後の行動可能性グラフの個数は，環境状態に対応付けられる行動の個数と一致する．また，環境状態に対応付けられる行動の個数は，環境中の物体集合の配置とアフォーダンス，ロボットが有するサブシステムによって決定される．

#### 環境状態遷移前後の行動可能性グラフの接続

環境変化の事前の行動可能性グラフ $G_0^a$ と事後の行動可能性グラフ $G_{1\sim N^{\mathcal{A}}}^a$ をエッジで接続し，アクショングラフ $G^a$ を構築する．

具体的には，Fig. 2.5e に示すように，事前と事後の行動可能性グラフにおける，その環境の状態遷移を引き起こす行動の実行場所のノード同士を有向エッジで接続する．これらのエッジは，その環境の状態遷移を伴う行動を表現しており，そのアクションの属性やコストが設定される．そのコストは，行動内容とタスクプランニングの評価指標に基づき決定される．

## 2.4 アクショングラフに基づく時空間的ロボットナビゲーション

### 2.4.1 概要

ロボットのナビゲーションタスクを対象とし，アクショングラフを用いた実空間におけるタスクプランニング手法である Action based Spatio-Tempral RObot Navigation（ASTRON）について述べる．ナビゲーションタスクは，ロボットの初期位置と目的地に対応した絶対座標系における 2 次元座標の位置の組み合わせで与えられる．

ASTRON では，アクショングラフに基づき移動タスクをロボットの行動可能性の範囲で解釈することで，ロボットの機能を活用した行動列を取得する．ASTRON のフローチャートを Fig. 2.1 に示す．環境認識とタスクプランニング，アクション列の実行のプロセスを経てロボットシステムは動作する．本研究では，その中でも問題の表現や設定，計画から構成されるタスクプランニングに着目をしており，提案要素は問題の表現や設定に該当する．まず，ロボットの行動可能性に着目して表現するため，2.3 節で述べた手順に従い，環境中の物体集合やロボットのサブシステム構成を考慮してアクショングラフを自動で構築する．そして，構築したアクショングラフにダイクストラ法を適用し，ロボットの初期位置から目的地へ到達するための行動列を計画する．得られる行動列は，アクショングラフに基づきの実行可能な行動の実行場所（node）と行動内容（edge）の配列で構成されるため，実空間においてロボットが実行するために必要な情報を含んでいる．

以下で，アクショングラフに基づくタスクプランニングの詳細について述べる．

### 2.4.2 ロボットナビゲーションのためのタスクプランニングへのアクショングラフの応用

#### アクショングラフにおけるナビゲーションタスクの解釈

アクショングラフをタスクプランニングに適用するため，与えられた初期位置と目的地に該当するスタートノードとゴールノードを決定する必要がある．行動によって引き起こされる環境の状態遷移に対する事前および事後の行動可能性グラフから構成されているため，アクショングラフには同じ位置を示すノードが複数存在する．しかし，その同じ場所を示すノード毎にその場所に到達する上での戦略，すなわち，引き起こす環境変化が異なる．したがって，アクショングラフに基づくタスクプランニングでは，スタートノードに環境変化前の事前行動可能性グラフ $G_0^a$ において現在のロボットの初期位置から最も近いノードが設定される．さらに，各行動可能性グラフ $G_{0\sim N^{\mathcal{A}}}^a$ における目標位置から最も近いノードをゴールノードとする．

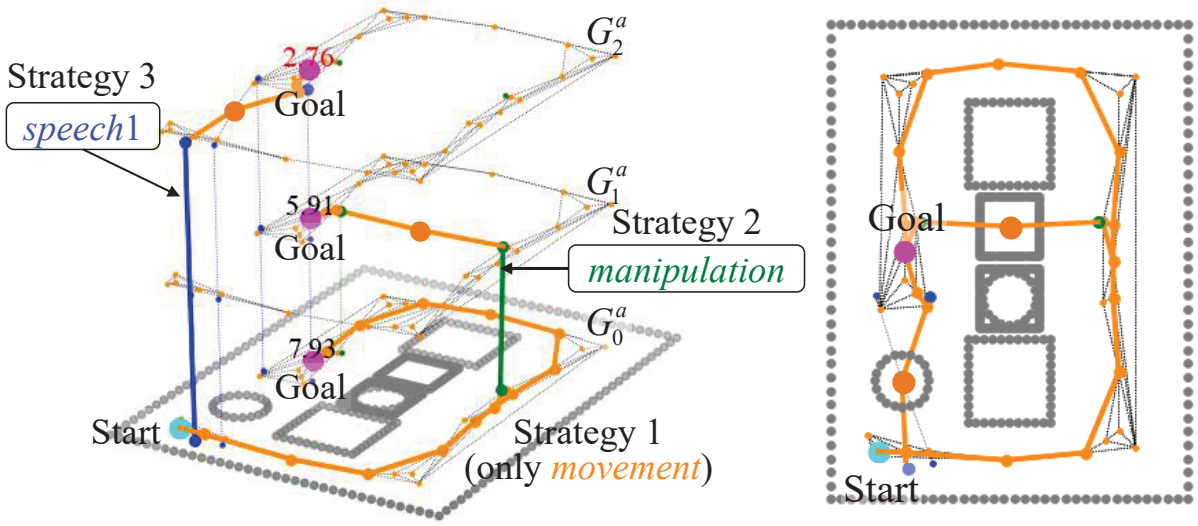


(a) Perspective view

(b) Top view

Figure 2.6: Task planning based on action graph

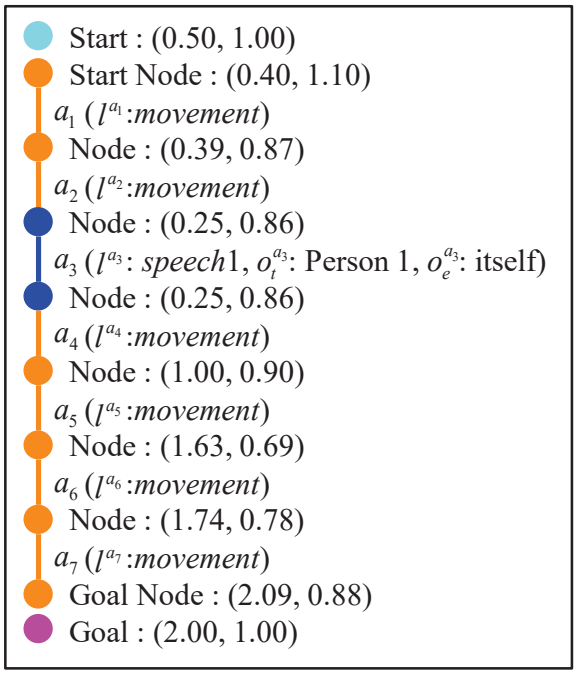


Figure 2.7: Example of action sequence (Strategy 3)

例えば，Fig. 2.2 に示す環境では，Fig. 2.6 に示すように，各戦略に対応する三つのゴールノードを設ける．一つ目は，事前行動可能性グラフ $G_0^a$ におけるノードであり，*movement* 行動のみで目的地へ到達する戦略に該当する．二つ目は，一つ目の事後行動可能性グラフ $G_1^a$ におけるノードであり，*movement* 行動と *manipulation* 行動により，椅子に干渉する戦略に該当する．三つ目は，一つ目の事後行動可能性グラフ $G_2^a$ におけるノードで，*movement* 行動と *speech* 行動により，人に話しかける戦略に該当する．

Table 2.3: Verification contents

| Exp. No. | Sim. or Real | Verification items | | | | | Scenario No. | Env. No. | Robot No. |
|---|---|---|---|---|---|---|---|---|---|
| | | Subsystem-level affordance | Geometric reasoning | Multi-layer | Feasibility | Effective use of functions | | | |
| 1 | Sim. | ○ | ○ | | | | 1.1 | 1 | 3 |
| | | | | | | | 1.2 | | 4 |
| 2 | Sim. | | | ○ | | | \ | 1 | 4 |
| 3 | Real | | | | ○ | ○ | 3.1 | 2 | 1 |
| | | | | | | | 3.2 | | 2 |
| | | | | | | | 3.3 | | 3 |
| | | | | | | | 3.3 | 3 | 4 |

計画

アクショングラフへ最適化アプローチを適用することでスタートノードからゴールノードまで到達するための最適な行動列 $A$ を取得する．本研究では，グラフ上のノード間の最短経路を算出するベーシックなアルゴリズムの一例としてダイクストラ法を採用したが，他の手法も適用可能である．まず，ロボットが選択可能なすべての戦略のスタートノードとゴールノードの組み合わせに対してダイクストラ法を適用する．そして，Fig. 2.6 に示すように，それぞれの戦略に対する最もコストが小さくなる行動列と合計コストを取得する．得られた各行動戦略の合計コストを比較し，コスト関数に応じて最適な行動戦略を決定し，それに対応した行動列 $A$ を取得する．アクショングラフのエッジに埋め込むコストの評価指標には，移動距離や所要時間，エネルギー消費量などが例として考えられる．本研究では，例として移動距離に基づいてコストを計算した．

Fig. 2.6 に示した例題で得られる行動列 $A$ は Fig. 2.7 に示すとおりである．

## 2.5 実験

### 2.5.1 概要

検証内容を Table 2.3 に示す．実験 1 では，Subsystem-level Affordance や幾何推論の双方を考慮することでロボットの行動可能性を正しく把握できることをシミュレーションで検証するアブレーションスタディを実施した．実験 2 では，多層の行動可能性グラフで構成されたアクショングラフでは，多様な行動が表現可能で，環境内で選択可能な戦略を把握できることをシミュレーションで検証するアブレーションスタディを実施した．実験 3 では，提案手法により実世界において実行可能かつ，サブシステムを有効活用可能な行動列を計画可能であることを検証するため，サブシステム構成の異なる複数のロボットを対象とした実機実験を実施した．

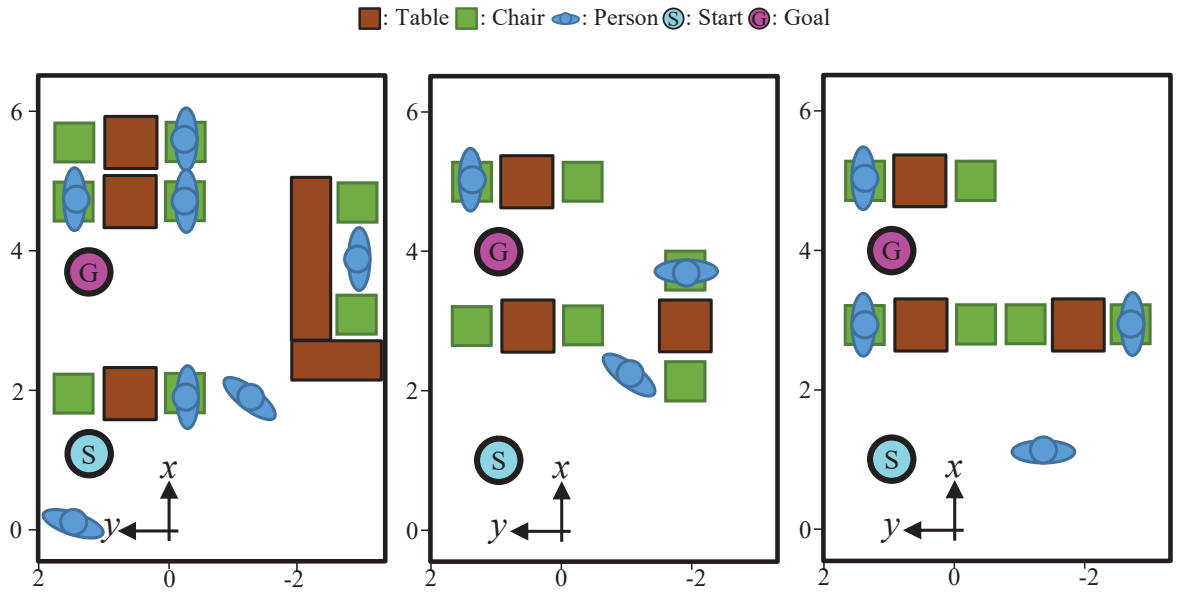


(a) Env. 1 (b) Env. 2 (c) Env. 3

Figure 2.8: Experimental environments

### 2.5.2 実験設定

#### 実験環境

本研究では，Fig. 2.8 に示すようなカフェを模擬した環境においてシミュレーションや実機実験を実施した．ロボットとスタッフが協働しているカフェを想定しており，立っている人はカフェのスタッフとし，ロボットに対して協力的であると仮定する．

#### 使用するロボット

Table 2.4 に示すように 3 種類のロボットを用いて，4 種類のサブシステム構成の条件で実験を実施した．Robot 1 は P-3DX [55] と呼ばれる移動台車であり，有効なサブシステムは，*mobilebase* である．Robot 2 は Pepper [56] と呼ばれる移動可能なコミュニケーションロボットであり，有効なサブシステムは，*mobilebase* に加えて *speaker* である．Robot 3 は HSR [57] と呼ばれるモバイルマニピュレータであり，有効なサブシステムは，*mobilebase* と *manipulator*，*speaker* である．また，Robot 4 は，HSR が *manipulator* で物体を把持している場合を想定し，*manipulation* 行動が無効で，*speech*2 行動が実行可能であるとした．センサに関しては，すべてのロボットに Laser range finder が搭載されており，Robot3 の HSR はカメラも使用可能である．

#### システム構成

ASTRON に基づくロボットナビゲーションシステム設計例として本実験のシステム構成を Fig. 2.9 に示す．また，システムにおけるパラメータの具体的な値を Table 2.5 に示す．ロボットはアクショングラフやそれに基づいて計画された行動列に基づき，環境中の行動列実行に関連する物体を認識する．また，障害物はロボットに搭載された Laser range finder を用いて認識する．ナビゲーションタスクを実施する短い期間では，環境が大きく変化しないことを想定している．

オフライン処理では，まず，システムは事前に構築したセマンティックマップに基づき環境状態 $O_0$ を得る環境中の物体のラベルや位置，大きさは，12 台の RGB-D カメラ（Azure Kinect [58]) から得られる画像に対して物体のインスタンスセグメンテーショ

Table 2.4: Robot list

| Robot No. | | 1 | 2 | 3 | 4 |
|---|---|---|---|---|---|
| Robot | | P-3DX | Pepper | HSR | 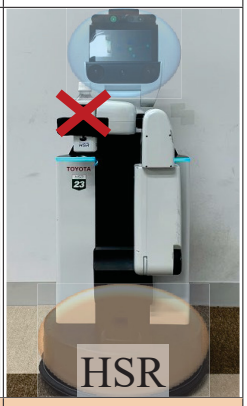 HSR |
| action | *movement* | ◯ | ◯ | ◯ | ◯ |
| | *speech*1 | × | ◯ | ◯ | ◯ |
| | *speech*2 | × | × | × | ◯ |
| | *manipulation* | × | × | ◯ | × |

ン手法である Mask R-CNN [59] を適用して物体情報を推定する環境センシングシステムを用いて取得する．そして，取得した環境状態 $O_0$ や Tables 2.1，2.2 に示す事前知識，Table 2.5 に示すパラメータに基づいて，アクショングラフ $G^a$ を構築する．環境センシングシステムはより効果的な検証のために用いており，アクショングラフの構築には必須ではない．最後に，アクショングラフに基づきタスクプランニングを実施し，行動列 $A$ を取得する．コストの評価指標はロボットの移動距離とした．そのため Table 2.5 に示すように行動のコスト $c^a$ にはアクションの実行に必要な移動距離を設定した．

$$c^a = \left\{ \begin{array}{ll} \|\boldsymbol{p}^{a+1} - \boldsymbol{p}^a\| & (a = movement) \\ 0.3 & (a = speech1, 2) \\ 0.3 & (a = manipulation) \end{array} \right\}, \tag{2.4}$$

ここで，$\boldsymbol{p}^a$ と $\boldsymbol{p}^{a+1}$ はそれぞれ *movement* 行動の始点と終点である．具体的には，*movement* 行動のコストはエッジの長さとし，*speech*1, 2 行動や *manipulation* 行動のコストは行動実行に伴うわずかな移動を考慮して 0.3m で設定される．

オンライン処理では，ロボットが取得した行動列を順に実行する．行動列 $A$ に含まれる各行動 $a_i$ は，行動名称 $l^{a_i}$ に応じて処理を行い，実行される．*movement* 行動では，ファジーポテンシャル法 [60, 61] に基づき，Laser range finder を用いて観測した未知の障害物と次のノードへの移動を統合的に考慮し，速度を決定される．*manipulation* 行動は，椅子に設置された AR マーカのカメラセンシングに基づき，椅子とロボットの相対座標系で椅子を机の方向へ移動させるための動作を計画し，追従することで実行される．

### 2.5.3 実験 1: 行動可能性グラフの検証

#### 実験設定

実験 1 では，Table 2.3 に示すように，様々な物体配置を含む Env. 1 を対象の環境状態とし，ロボットはサブシステム構成が異なる Robot 3,4 を対象として 2 通りのシナリ

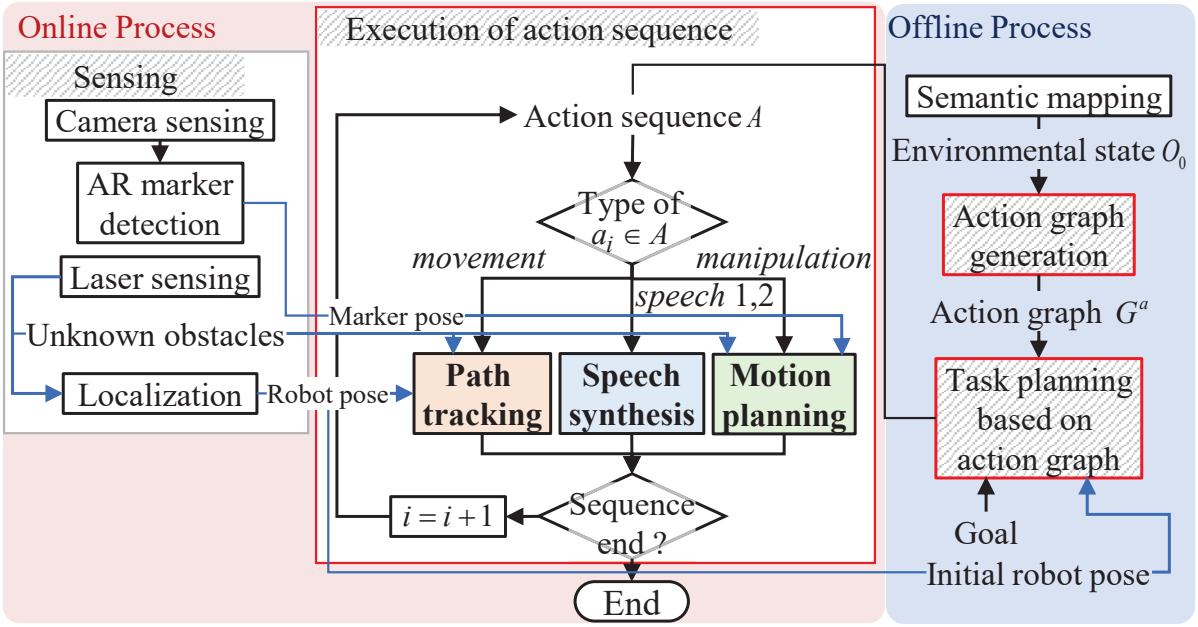


Figure 2.9: System configuration of ASTRON

Table 2.5: System parameters

| Process | Parameter | Value |
|---|---|---|
| Action graph generation | Affordance range of *speech*2 $r^{speech2}$ | 0.5 ∼ 2.0 m |
| | Appropriate distance for *speech*1, 2 $d^s$ | 0.5 m |
| | Appropriate distance for *manipulation* $d^m$ | 1.0 m |
| Task planning based on action graph | Evaluation index of cost | Distance |
| | $c^a$ of *movement* | Edge length |
| | $c^a$ of *speech*1, 2 | 0.3 m |
| | $c^a$ of *manipulation* | 0.3 m |

オで検証を行った．

### 実験結果

実験結果を Tables 2.6，2.7 に示す．Tables 2.6，2.7 における Com. 1.1 の図は，環境状態に対して 2.3.2 項で述べた幾何推論を適用して得た移動のための行動可能性グラフ $G^m$ を示している．オレンジ色のノードやエッジは *movement* 行動を示している．

Tables 2.6，2.7 における Com. 1.2 の図は，Subsystem-level Affordance に基づき，環境状態 $O_0$ のそれぞれの物体に対して行動を対応付けた結果である．Scenario1.1 では Robot 3 を想定しているため，*speech*1 行動や *manipulation* 行動が物体に対応付けられる．また，Scenario1.2 では Robot 4 を対象としているため，*speech*1, 2 行動が物体へ対応付けられる．特に，図中に A と記載されている箇所では，物体間の位置関係に基づくアクションの対応付けの特徴を示している．具体的には，従来の個々の物体に対するアフォーダンスとは異なり，椅子に座っている人は行動を対応付けされていない．また，

Table 2.6: Result of Scenario 1.1 in Exp. 1

| 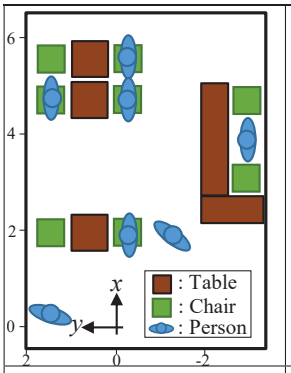 Environment | 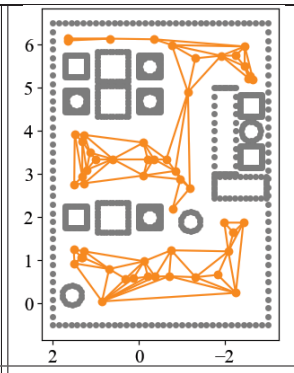 Com. 1.1: Geometric reasoning | 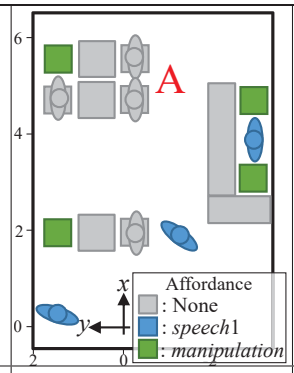 Com. 1.2: Action association | 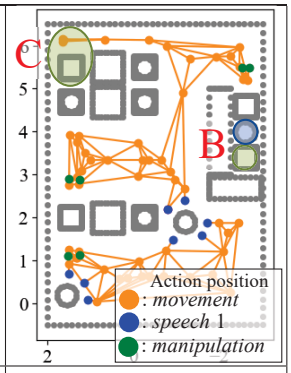 Pro: Action possibility graph $G_0^a$ |
|---|---|---|---|
| Geometric reasoning | ○ | | ○ |
| Subsystem-level affordance | | ○ | ○ |

Table 2.7: Result of Scenario 1.2 in Exp. 1

| 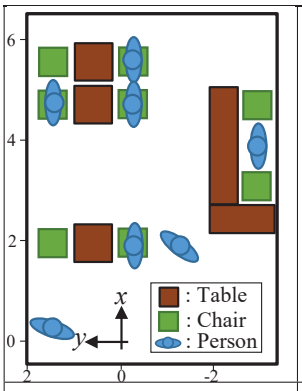 Environment | 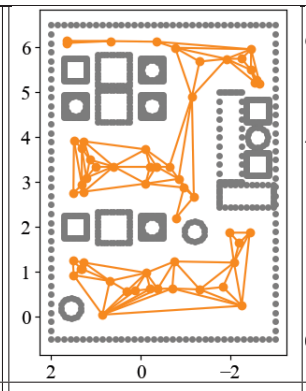 Com. 1.1: Geometric reasoning | 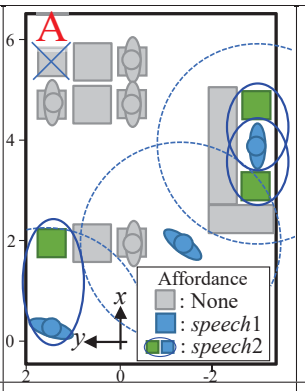 Com. 1.2: Action association | 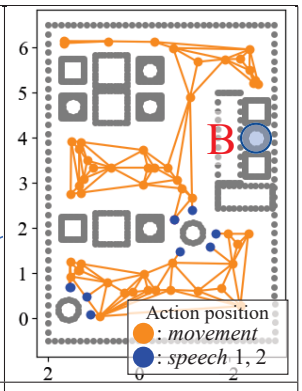 Pro: Action possibility graph $G_0^a$ |
|---|---|---|---|
| Geometric reasoning | ○ | | ○ |
| Subsystem-level affordance | | ○ | ○ |

*speech*2 が実行可能な場合，特定の距離内の人と椅子のペアに対しては *speech*2 を対応付け，範囲外の椅子には行動を対応付けないなど，人と椅子の位置関係に応じて行動が対応付けられている．このように，実空間におけるタスクプランニングのために，ロボットのサブシステム構成や物体集合の配置に応じて物体に行動を対応付け可能であることを確認した．

Table 2.8: Condition of graph representation methods in Exp. 2

| Contents \ Method | Com. 2.1 | Com. 2.2 | Pro. Action graph |
|---|---|---|---|
| prior action possibility $G_0^a$ | ◯ | | ◯ |
| posterior action possibility $G_1^a$ | | ◯ | ◯ |

Tables 2.6，2.7 における Pro. の図では，先述の幾何学的推論と行動の対応付けの両方を考慮し，行動可能性グラフ $G_0^a$ を構築した結果を示している．Scenario1.1 では，青色のノードは *speech*1 行動の実行場所，緑色のノードは *manipulation* 行動の実行場所を示している．また，Scenario1.2 では，青色のノードは *speech*1, 2 行動の実行場所を示している．特に，図中に B，C と記載されている箇所は，幾何学的推論とアクションの対応付けの両方を考慮した行動可能性の理解の特徴を示している．B と記載されている箇所では，物体にはアクションが対応付けられているが，2.3.4 項に述べた幾何推論によりロボットが到達可能な行動の実行場所が存在しないことが認識されため，行動の実行場所のノードが設けられていない．さらに，C と記載されている箇所では，物体にはアクションが対応付けられたが，2.3.4 項に述べた幾何推論によりその物体とロボットの間にアクションの実行に適切な距離を設けることが困難であることが認識されたため，行動の実行場所が設けられていない．以上より，行動の対応付けと物体の位置関係に基づく幾何推論との双方を考慮し行動可能性グラフを構築することで，実空間において実行可能な行動の実行場所の理解が可能であることを確認した．

### 2.5.4 実験 2: アクショングラフの構造の検証

#### 実験設定

本実験では，実験 1 の scenario1.2 と同様に，環境は Env 1，ロボットは Robot 4 を想定した．構築された移動のための行動可能性グラフ $G^m$ や物体に対して行動を対応付けた結果は Table 2.7 の Com. 1.1，Com. 1.2 の図と同様である．

上記の条件において，二つの比較手法と提案方法に基づきアクショングラフを構築し，それぞれのアクショングラフに基づき計画した行動列を比較した．比較のグラフ表現手法の条件を Table 2.8 に示す．比較手法 Com.2.1 は，実空間において干渉可能な物体を把握する手法 [22, 41] と同様に，現在の環境における行動可能性のみを表現する手法である．この手法では，干渉可能な物体位置は通過可能とし，干渉可能な物体の位置を通過する際，物体を除去するためのコストを加算することとした．比較手法 Com.2.2 は，ロボットの行動による変化後の行動可能性，すなわち事後の行動可能性のみを表現する手法とした．この手法では，ロボットの行動により通過可能となる位置を通過可能とし，*movement* 行動以外の行動のノードにつながるエッジに，その行動のコストを設定した．

#### 実験結果

実験結果を Figs. 2.10-2.13 に示す．

与えられた環境状態に基づく事前行動可能性のみを表現する手法である Com. 2.1 に基づき取得したグラフは Fig. 2.10a に示す通りである．得られたグラフにダイクストラ法を適用して得られた行動列は Fig. 2.10b に示すとおりである．計画された行動列は，ロ

ボットは道を塞ぐ人に通してもらうよう依頼したのち，目的地へ向かうことを意味している．

また，ロボットの行動により実現可能な変化後の事後行動可能性のみを表現する手法である Com.2.2 に基づき取得したグラフは Fig. 2.11a に示す通りである．得られたグラフにダイクストラ法を適用して得た行動列は Fig. 2.11b に示すとおりである．得られた行動列は，ロボットが *speech*2 行動が対応付けられている椅子の場所を通過し，目的地へ向かうことを意味している．しかし，このグラフではその環境変化の原因となる行動が明示できていないため，得られた行動列には *speech*2 行動が対応付けられた人へ椅子の移動を依頼する行動が含まれていないため，実行不可能である．

環境変化前後の行動可能性グラフで構成する提案手法に基づき取得したアクショングラフを Fig. 2.12a に示す．そして，得られたアクショングラフに対して提案のタスクプランニング手法を適用した結果を Fig. 2.13 に示す．実現可能な環境状態は，変化なしも含めて 4 種類であるため，選択可能な戦略は 4 種類である．環境変化を起こさない戦略 1 や Fig. 2.12d に示すように (0.20,1.50) に存在する人に通してもらうように依頼する戦略 3 では，目的地へ到達する行動列は得られていない．戦略 2 に対して得られた行動列は，まず (0.20,1.50) に存在する人に接近し，(2.00, 1.40) に存在する椅子の移動を依頼する *speech*2 行動を実行したのちに空いた椅子の位置を通過し，目的地へ向かうことを意味している．戦略 4 に対して得られた行動列は，Com.2.1 で得られた行動列と同様に道を塞ぐ人に通してもらうよう依頼したのちに目的地へ向かうことを意味している．

それぞれの手法に基づき得られた各行動列のコストを Table 2.9 にまとめる．最もコストが低い行動列は Com 2.2 に基づき得た行動列であるが，実行困難な行動列である．実行可能な行動列の中で，コストが最も低いものは，提案手法から得られた戦略 2 の行動列である．この解は，Com 2.1 のグラフでは表現困難な，一見遠回りに見える *speech*2 行動を実行する行動列である．

以上より，より多様なアクションを表現するためには，アクショングラフにおいて行動可能性とそれに伴う行動可能性の変化を明確に記述することが必要であり，多層構造の行動可能性グラフでは選択可能な戦略を正確に表現可能であることが確認できた．

### 2.5.5 実験 3: 実機実験

#### 実験設定

本実験では，Fig. 2.9 に示したシステムを用いて，ロボットを初期位置から目的地へ移動させる行動列を計画し，計画した行動列に従い実際にロボットを動作させる実機実験を実施した．各シナリオの実験条件を Table 2.3, Exp. 3 に示す．Scenario3.1 3.3 では，環境は Env. 3，ロボットはサブシステム構成が異なる 3 種類の Robot 1-3 を対象とした．また，Scenario 3.4 では，環境は Env. 3，ロボットは Robot 4 を対象とした実験を行った．

#### 実験結果

まず，Scenario 3.1-3.3 の結果を Figs. 2.14-2.16 に示す．Figs. 2.14a, 2.15a, 2.16a に，各シナリオにおいて各物体に行動の対応付けた結果を示す．同じ環境においても，各ロボットのサブシステム構成に応じて，物体に対応付けられる行動が異なることが確認できる．さらに，シナリオ毎に構築されたアクショングラフと，行動列の計画結果を Figs. 2.14b, 2.15b, 2.16b に示す．また，選択可能な戦略に対する行動列を Figs. 2.15c, 2.15d and 2.16c to 2.16h に示す．

Figs. 2.14a, 2.14b に示すように，Scenario 3.1 では，移動台車型のロボットを対象としているため，一般的なロボットナビゲーションの戦略と同様に，すべての環境中の物体をすべて障害物としてみなし，回避する行動列が計画されていることが確認できる．こ

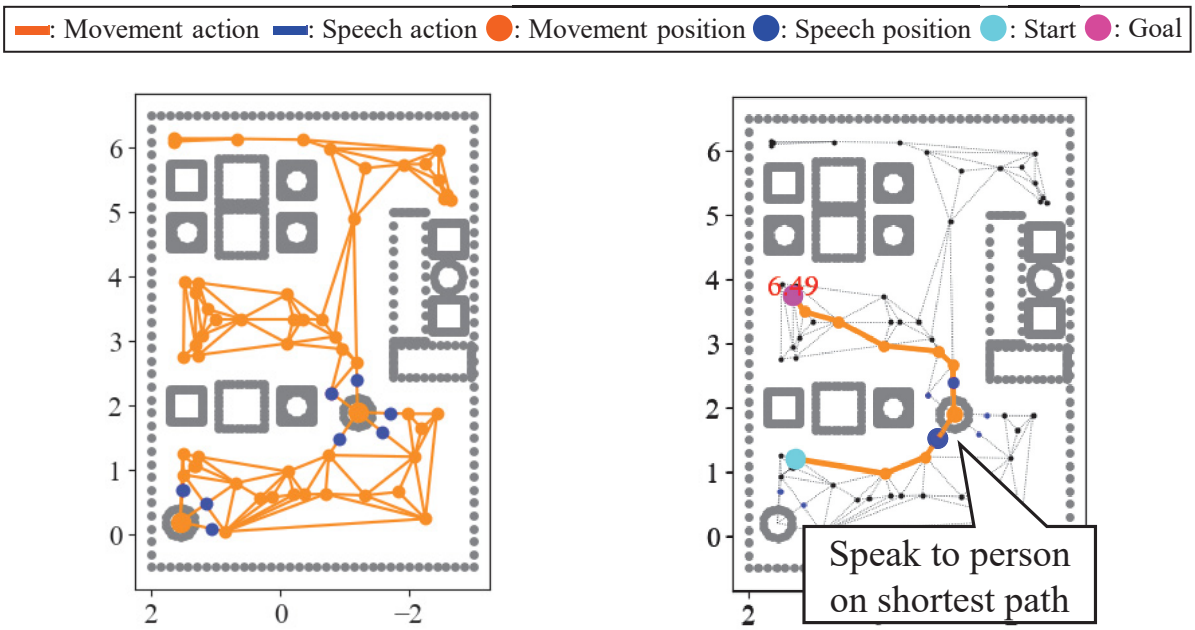


(a) Graph (b) Result of planning

Figure 2.10: Result of Com.2.1 in Exp. 2

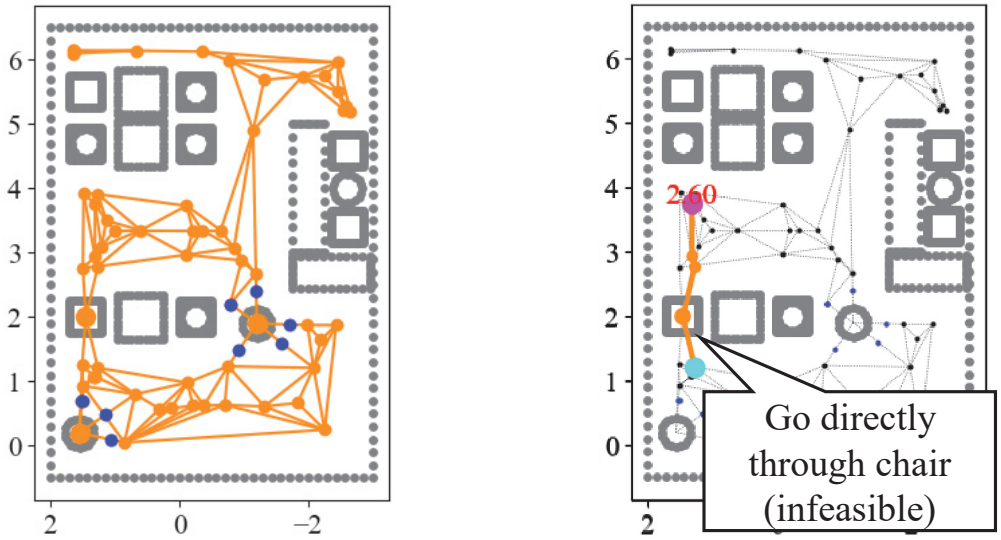


(a) Graph (b) Result of planning

Figure 2.11: Result of Com.2.2 in Exp. 2

の戦略は Scenario 3.1，3.2 の戦略 1 に該当する．一方，Scenario 3.2 では，*speaker* を有したロボットを対象としており，Figs. 2.15a-2.15d に示すように，すべての物体を回避する戦略だけでなく，人に話しかけて移動を要求する戦略に対応する行動列も計画されている．さらに，Scenario 3.3 では，*speaker* や *manipulator* を有したロボットを対象としており，Figs. 2.15a-2.15d に示すように，環境中の物体に *speak* 行動や *manipulation* 行動が対応付けられたアクショングラフが構築されている．選択可能な戦略として，すべての障害物を回避する戦略や，人に話しかける戦略に加えて，四つの移動可能な物体それぞれを移動する戦略から構成される六つの戦略が得られた．Scenario 3.1-3.3 で得られた各戦略に対する行動列のコストを 2.5.5 項にまとめる．ここで，環境センシングシステムの観測ノイズにより，各シナリオでわずかに環境状態が異なることに注意されたい．また，シナリオ毎に選択可能な戦略のなかで最もコストが低い行動列を実空間でロボッ

トが実行した様子を Figs. 2.14c, 2.15e, 2.16i に示す．Scenario 3.1 では，ロボットはどの障害物にも接触せず，目的地へ到達した．Scenario 3.2 では，ロボットは道を塞ぐ人へ能動的に接近し，道を譲ることを依頼した後に，目的地へ到達した．さらに，Scenario 3.3 では，まずロボットは椅子へ接近し，椅子を移動させた後に，目的地に到達した．

以上の結果より，提案手法では，ロボットのサブシステム構成に応じて，選択可能な戦略の中で，ロボットのサブシステムを有効活用できる実行可能な行動列が取得可能であることを確認した．

Scenario 3.4 の結果を Fig. 2.17 に示す．Fig. 2.17a に示すように，行動の対応付けでは人と椅子の位置関係に基づき，$speech1, 2$ が対応付けられた．Figs. 2.17b-2.17d に示すように，得られた戦略には $speech1, 2$ 行動で人に話しかける戦略も含まれる．各戦略に対して計画された行動列のコストを Table 2.11 に示す．すべての障害物を回避する戦略 1 や，人に移動を依頼する戦略 4 では目的地に到達する行動列は得られなかった．最もコストの低い戦略 2 に対する行動列をロボットが実空間で実行した結果は Fig. 2.17e に示すとおりである．ロボットは行動列に従って，能動的に人へ接近し，椅子の移動を要求した後に，空いた空間を通過し目的地に到達した．本シナリオの結果により，ロボットが行動する対象の物体 $o_t^a$ と，変化する物体 $o_e^a$ が一致しない行動も表現可能であり，計画された行動列が実空間において実現可能であることを示した．

また，Fig. 2.17c を確認すると，人に話しかけたのちに目的地へ移動することが考慮され，人に話しかけられる位置の中で最も移動距離が短くなる位置を $speech2$ 行動の実行場所として選択されている．この点も物体配置を考慮可能な実空間におけるタスクプランニングの特徴である．

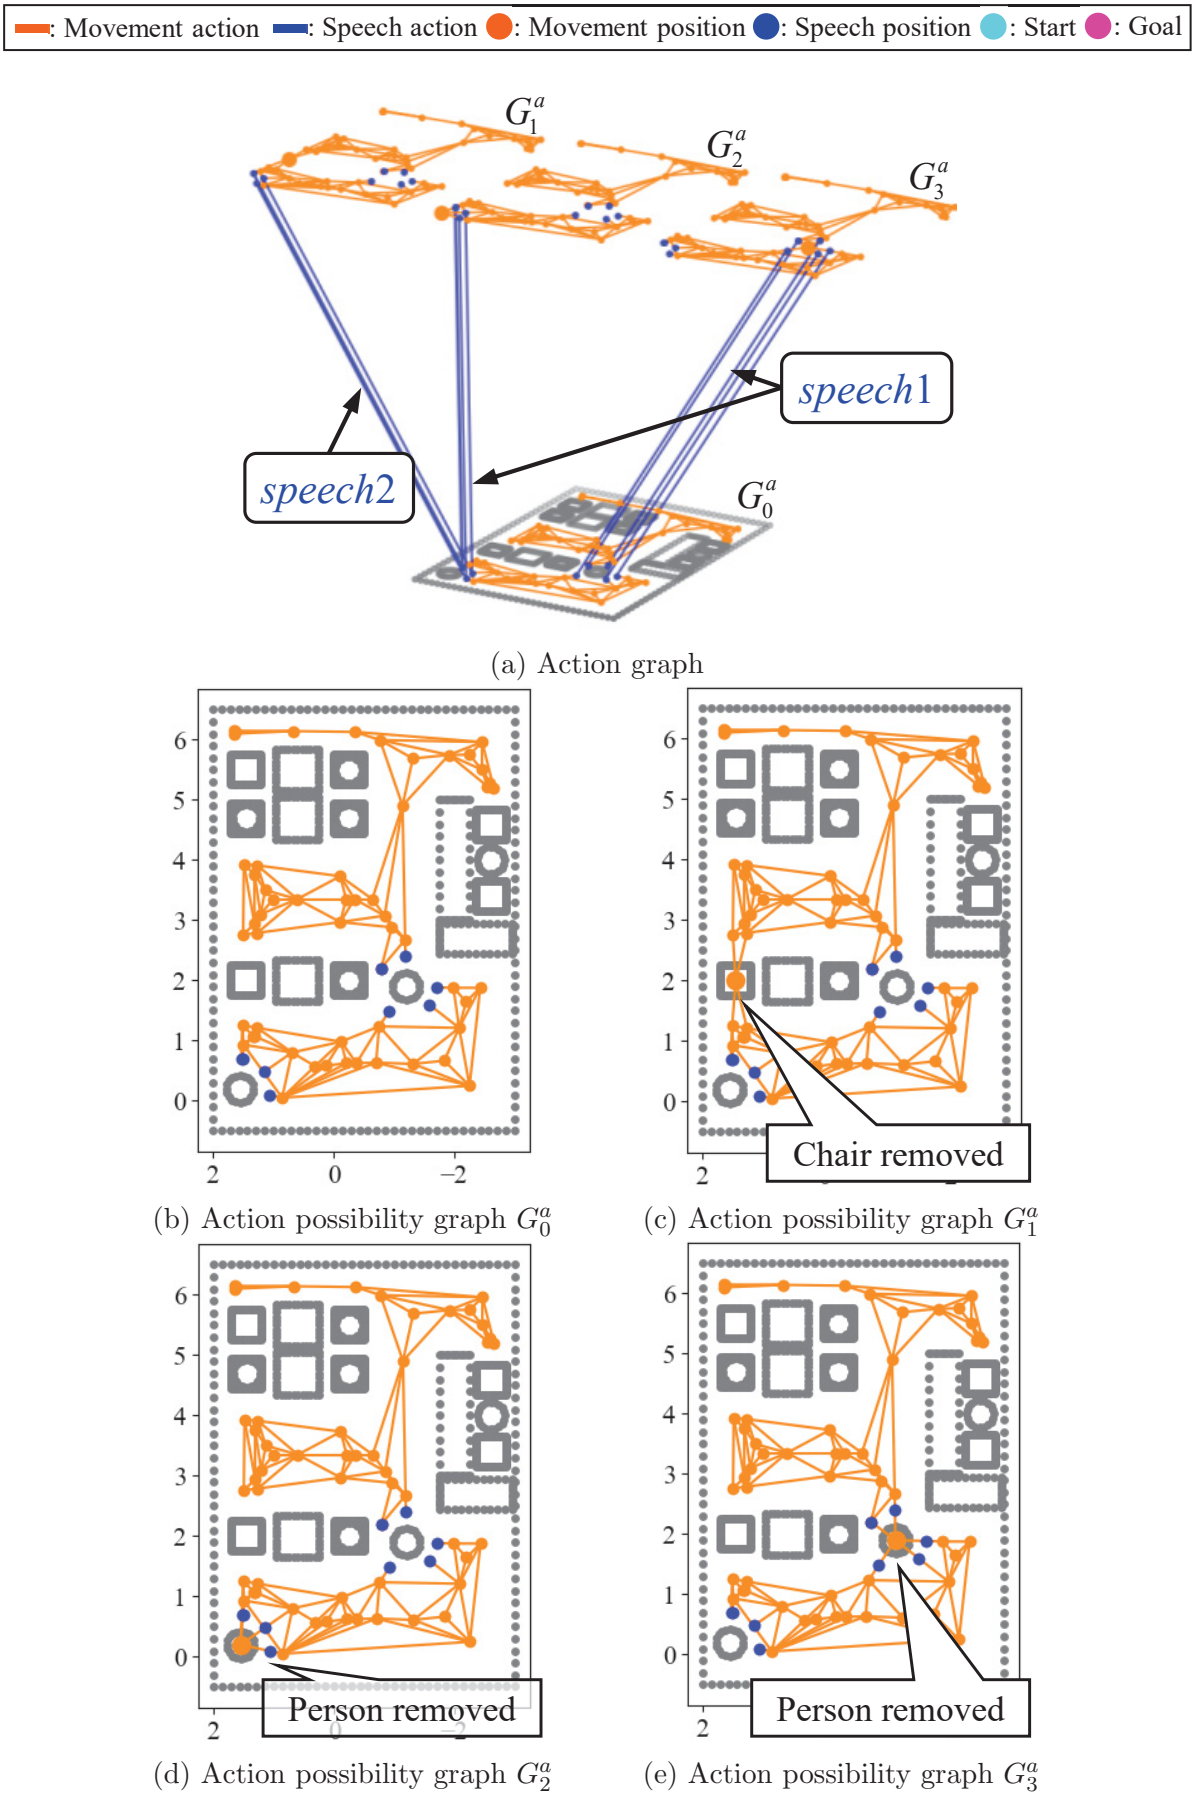


(a) Action graph

(b) Action possibility graph $G_0^a$

(c) Action possibility graph $G_1^a$

(d) Action possibility graph $G_2^a$

(e) Action possibility graph $G_3^a$

Figure 2.12: Action graph constructed based on proposed method in Exp. 2

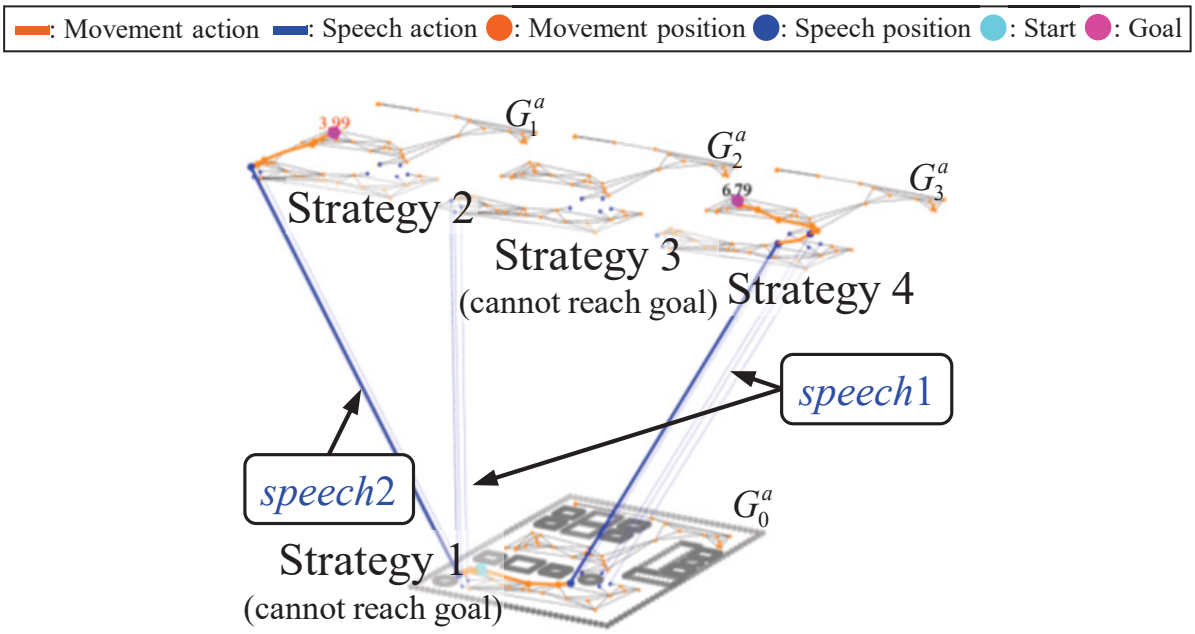


(a) Overview of planning result

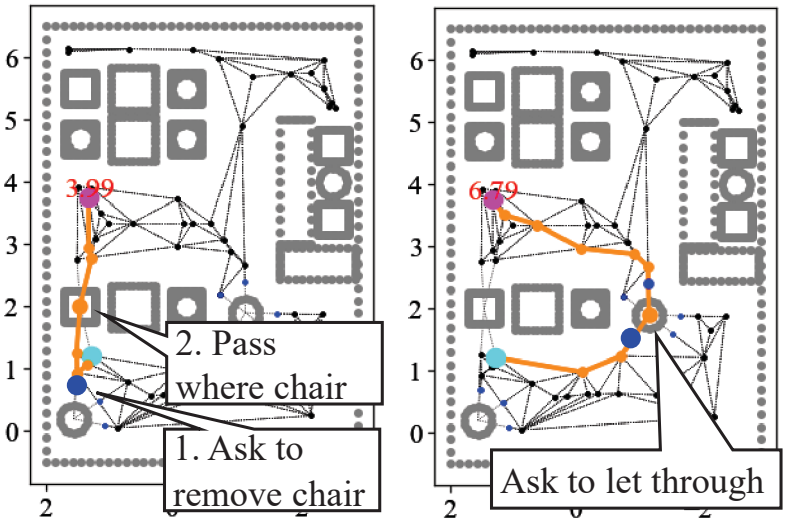


(b) Plan of strategy 2 (c) Plan of strategy 4

Figure 2.13: Planning result based on action graph based on proposed method in Exp. 2

Table 2.9: Cost of planned action sequence in Exp. 2

| Com 2.1 | Com 2.2 | Proposed | | | |
|---|---|---|---|---|---|
| | | Strat. 1 | Strat. 2 | Strat. 3 | Strat. 4 |
| 6.79 | 2.60 (infeasible) | N/A | 3.89 | N/A | 6.79 |

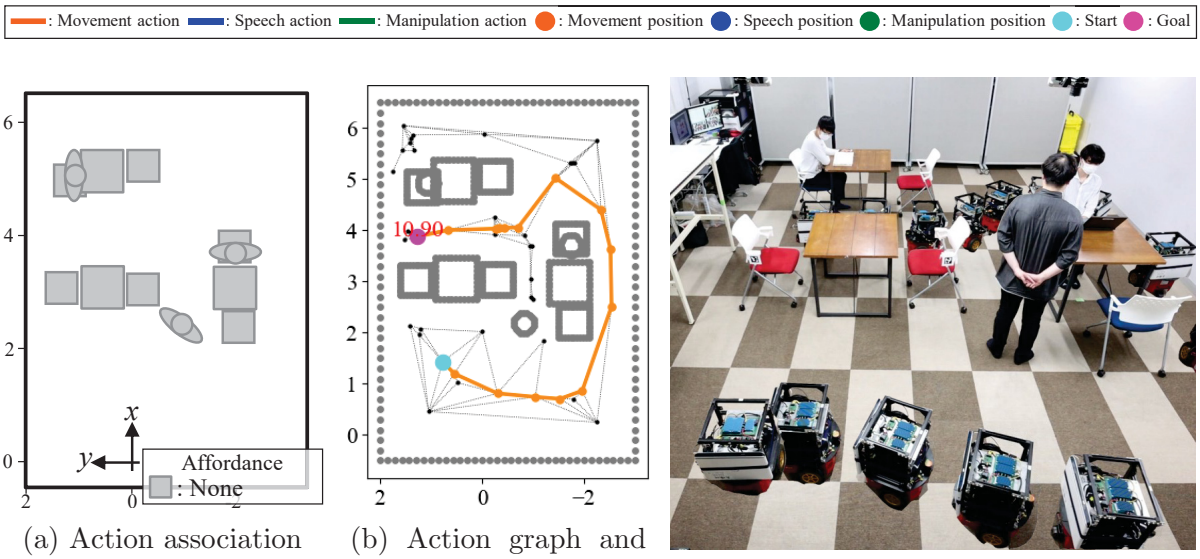


(a) Action association

(b) Action graph and action sequence

(c) Actual movement

Figure 2.14: Result of Scenario 3.1 in Exp. 3

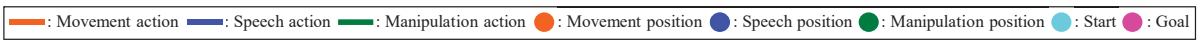


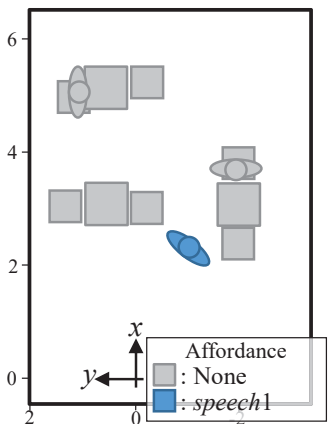


(a) Action association

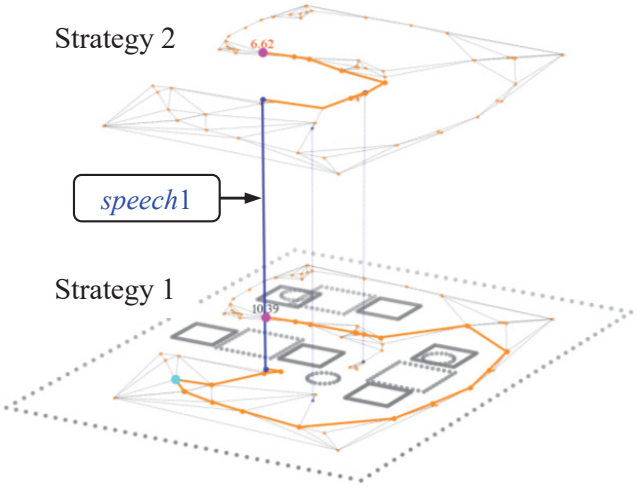


(b) Action graph and action sequences

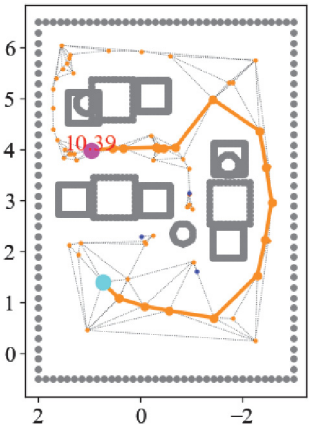

(c) Strategy 1

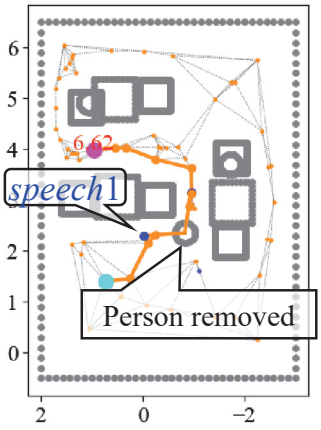


(d) Strategy 2

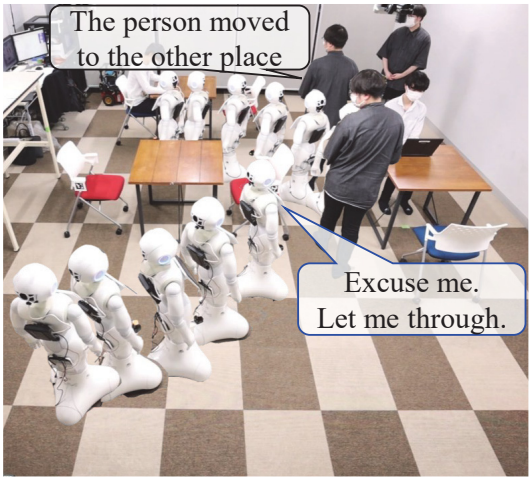


(e) Actual movement of strategy 2

Figure 2.15: Result of Scenario 3.2 in Exp. 3

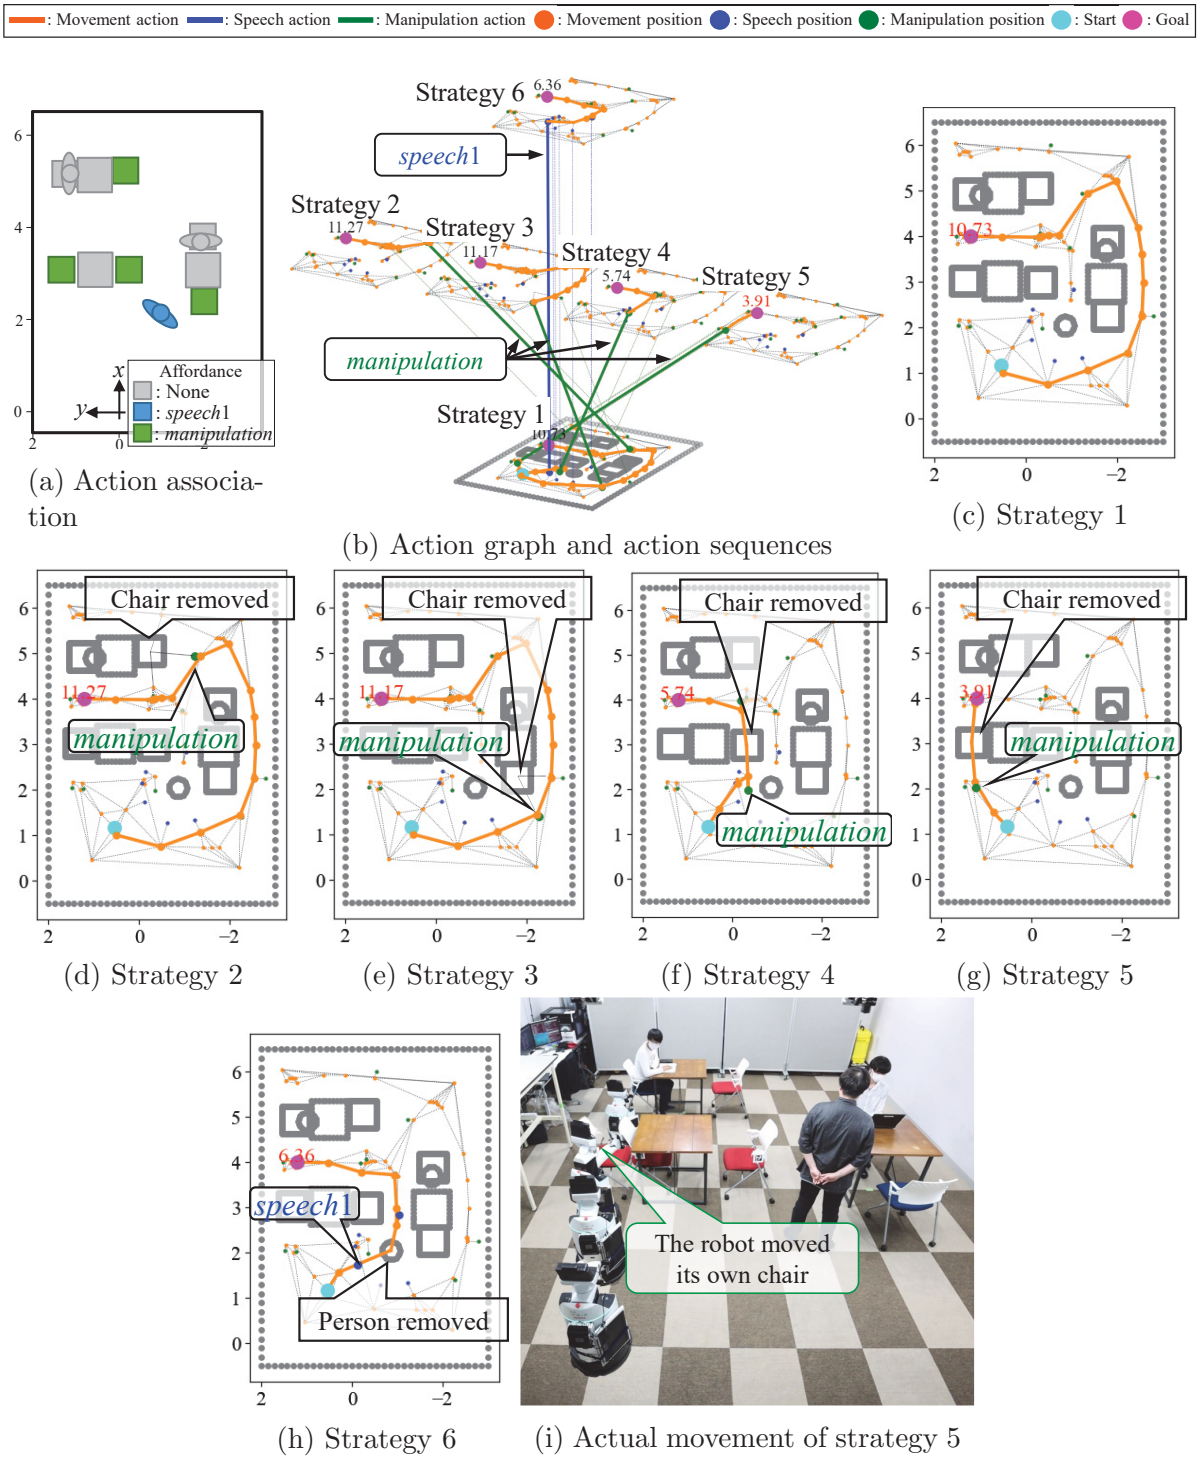


(a) Action association

(b) Action graph and action sequences

(c) Strategy 1

(d) Strategy 2

(e) Strategy 3

(f) Strategy 4

(g) Strategy 5

(h) Strategy 6

(i) Actual movement of strategy 5

Figure 2.16: Result of Scenario 3.3 in Exp. 3

Table 2.10: Cost for each strategies in Scenario 3.1 to 3.3 of Exp. 3

: Movement only : With speech : With manipulation

| Scenario No. | Strat. 1 | Strat. 2 | Strat. 3 | Strat. 4 | Strat. 5 | Strat. 6 |
|---|---|---|---|---|---|---|
| 3.1 | 10.90 | \ | | | | |
| 3.2 | 10.39 | 6.62 | \ | | | |
| 3.3 | 10.73 | 11.27 | 11.17 | 5.74 | 3.91 | 6.36 |

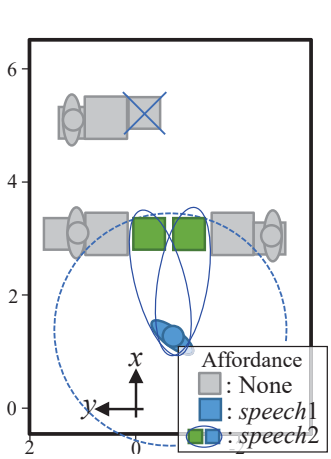


(a) Action association

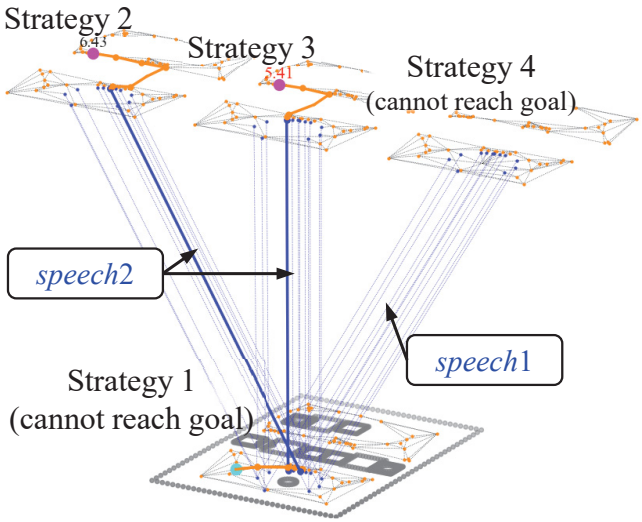


(b) Action graph and planned action sequence

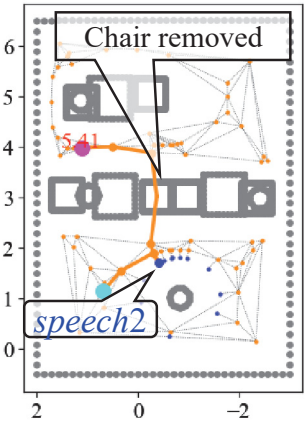


(c) Strategy 2

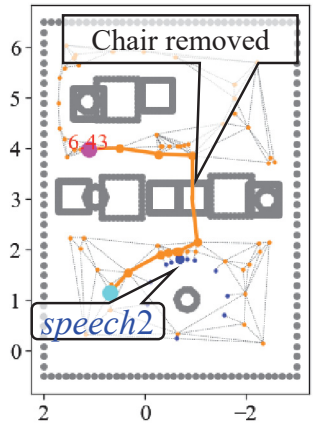


(d) Strategy 3

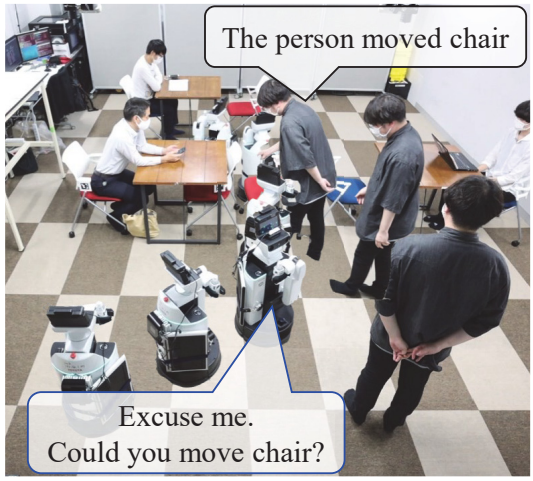


(e) Actual movement of strategy 2

Figure 2.17: Result of Scenario 3.4 in Exp. 3

Table 2.11: Cost of planned action sequences in Scenario 3.4 of Exp. 3

| Strat. 1 | Strat. 2 | Strat. 3 | Strat. 4 |
|---|---|---|---|
| N/A | 5.41 | 6.43 | N/A |

## 2.6 結言

本章では，実空間におけるロボットの行動可能性や，その変化を明確に表現するための新たな環境表現としてアクショングラフと，基本的なアクショングラフの自動構築アルゴリズムを提案した．アクショングラフは，ロボットと物体集合に関する subsystem level アフォーダンスや位置関係に基づき，ノードをアクションの実行場所，エッジをアクションとしたグラフ表現であり，実空間におけるロボットの行動可能性やロボットの行動による行動可能性の変化も同時に表現することが可能である．また，アクショングラフに基づく実空間におけるタスクプランニングの設計例として，ロボットの移動タスクに着目した，Action based Spatio-Temporal RObot Navigation（ASTRON) を提案した．ASTRON では，アクショングラフに基づき，ロボットが選択可能な戦略毎，すなわち，ロボットが指令を達成するために起こす環境変化毎の行動列を理解し，ロボットの機能をより有効活用したゴールへの行動列を取得することを実現した．実験では，まず，行動可能性グラフを構築する際，行動の対応付けと物体の位置関係に基づく幾何学的推論との双方を考慮することが，行動可能性の理解を促進することを確認した．また，アクショングラフを多層の行動可能性グラフで構成することが，ロボットの多様な行動の表現や環境内の選択可能な戦略の把握を促進することを確認した．最後に，複数のサブシステム構成のロボットを対象とした実機実験により，提案手法では，実環境において実行可能かつ，各ロボットのサブシステムを有効活用可能な行動列が計画可能であることを示した．

# Chapter 3

# 世界状態依存アクショングラフに基づくモバイルマニピュレーション計画

## 3.1 緒言

本章では，まず，本研究で取り扱う，実空間における行動可能性の理解と行動の実現可能性を考慮したタスクプランニングに関する関連研究と，関連研究における課題を述べる．そして，世界状態に基づく行動可能性とロボットが実行する行動の相互作用を把握し，有効な行動列の候補より多く獲得することにより，実空間において環境とロボットが有する機能を有効活用したモバイルマニピュレーションを実現するタスク・モーションプランニング手法について述べる．具体的には，以下の二つについて述べる．

- 第 2 章で述べたアクショングラフをモバイルマニピュレーションタスクも扱えるように拡張した世界状態依存アクショングラフ
- 世界状態依存アクショングラフに基づくモバイルマニピュレーションタスクのプランニング手法

最後に，提案手法の有効性についてシミュレーションと実機実験により検証する．具体的には，再帰的多層構造を採用することにより，世界状態に基づく行動可能性とロボットが実行する行動の相互作用が表現可能であることをシミュレーションで検証した．さらに，世界状態依存アクショングラフに基づくタスク・モーションプランニング手法により実世界において実行可能かつ，環境やサブシステムを有効活用可能な行動列を計画可能であることを検証するため，モバイルマニピュレータを対象とした実機実験を実施した．

## 3.2 既存研究とその課題

### 3.2.1 実空間における行動可能性の理解

本研究は，実空間において実行可能な行動を理解する研究に関連している．

実行可能なアクションを理解する方法として，画像中の物体をアフォーダンスに基づき分類する研究が提案されている [48,62]．Affordance Net は，物体の各ピクセルに対してアフォーダンスを対応付ける深層学習に基づくリアルタイム推論のアプローチである [62]．また，Lüddecke らは，画像中の物体集合に基づき行動のもっともらしさを評価する手法を提案している [63]．人の行動予測に関する研究分野では，人の状態を考慮することが行動予測の性能向上に寄与することが報告されている [64,65]．人間の姿勢と周辺環境の状態に基づき人間の行動の分布を予測する手法として，ATCRF [64] が提案されている．しかし，これらの研究では，実空間における行動可能性は考慮されていない．

実空間における行動可能性を考慮する方法として，実環境に行動可能性を対応付ける方法が提案されている [46,66]．特に，環境中の物体の配置やアフォーダンスに基づく移動の可能性が表されたグリッドマップである Multi-layer environmental affordance map が提案されている [66]．人の行動履歴を複数の行動ラベルへセグメンテーションした結果に基づき，移動以外の行動を実空間にマッピングした Action map [46] が提案されているしかし，これらの研究は，エージェントが行動を実行することによる，行動可能性の変化については考慮されていない

本研究に最も関連する研究は，実環境における行動可能性とその変化を表現するアクショングラフである [67]．しかし，この手法では，対象のエージェントの状態は考慮されておらず，モバイルマニピュレーションタスクを扱うことは困難である．

本研究では，未考慮のエージェントの状態を考慮したアクショングラフを提案し，実空間において，世界状態に依存する実行可能な行動の理解を実現する．

### 3.2.2 行動の実現可能性を考慮したタスクプランニング

本研究は，実空間における行動の実現可能性を考慮したタスクプランニングや動作計画に関連している．

関連する研究分野の一つに，記号空間におけるタスクプランニングとコンフィギュレーション空間における動作計画を組み合わせた Task and motion planning(TAMP) がある [22–24,39]．また，他の研究分野として，障害物をよけるだけでなく移動可能な障害物には干渉を試みる手法である navigation among movable obstacles (NAMO) が挙げられる [40,41]．これらの手法では，動作計画を活用し，各行動の実行可能性や各行動の実行に関する依存関係を検証する．行動の依存関係を特定する手法として，動作計画を通じて除去するべき物体を把握する手法がある [22,41]．これらの手法では，まず，干渉可能な物体を除外した環境において，各行動の目標状態に向かう経路を計画する．そして，動作計画で取得した経路に交差する干渉可能物体を除去するべき物体とする．このアプローチは，動作計画を通じて一つずつの行動を検証し，行動の実行可能性や必要な行動を把握する．そのため，複数の行動を考慮したうえで，行動の実行場所や干渉する物体を決定することが困難であり，非効率な行動列を解とする可能性がある．また，FFRob algorithm [24] では，Conditional roadmap を用いた動作計画に基づき高速に各行動の実行可能性を検証することで，実行可能な行動列を取得する．この手法では，同じ世界状態における複数の実行可能な行動を考慮することが可能であるが，世界状態の変化前，変化後の実行可能な行動を同時に考慮することは困難である．一方，提案手法では，実行可能な行動とその再帰的な変化を実空間に埋め込むアクショングラフに基づき，複数の行動の時空間的な関係性を考慮したうえでロボットの機能を活かした行動列を取得することが可能である．

## 3.3 世界状態依存アクショングラフ

### 3.3.1 概要

世界状態依存アクショングラフ $G^a$ とは，世界状態 $W$ におけるエージェントの行動可能性と，行動による行動可能性の変化を表現する環境表現である．

世界状態 $W$ とは，ロボット状態 $R$ と環境状態 $O$ で構成される $N^o$ 個の物体集合である．

$$W = \{o | o \in R \text{ or } o \in O\} \tag{3.1}$$

物体 $o$ に含まれる情報は以下のとおりである．

- $l^o$: 物体のラベル

*3.* 世界状態依存アクショングラフに基づくモバイルマニピュレーション計画

- $\boldsymbol{p}^o$: 絶対座標系の 3 次元空間における物体位置
- $\theta^o$: 絶対座標系の 2 次元平面における物体の向き
- $s^o$: 四角形や円形などの単純な幾何形状と大きさなどの情報から構成される物体の形状情報．人は円形で表現され，椅子や机は四角形で表現される．

ロボット状態 $R$ に含まれる物体は，位置 $\boldsymbol{p}^o$ が $p^R$ であるロボットのサブシステムとそれに関連する物体であり，例えば，マニピュレータやスピーカ，マニピュレータに掴まれた物体などである．

$$R = \left\{ o | \boldsymbol{p}^o = \boldsymbol{p}^R \right\} \tag{3.2}$$

ここで，$p^R$ は，便宜的に，ロボットの位置を表すパラメータである．一方，環境状態 $O$ に含まれる物体 $o$ は，物体の位置 $\boldsymbol{p}^o$ が $\boldsymbol{p}^R$ ではなく，実空間における 3 次元座標であるものである．

$$O = \left\{ o | \boldsymbol{p}^o \neq \boldsymbol{p}^R \right\} \tag{3.3}$$

世界状態アクショングラフ $G^a$ は，ノード集合 $V^a$ とエッジ集合 $E^a$ で定義される．

$$G^a = (V^a, E^a) \tag{3.4}$$

アクショングラフにおける，ノード $v^a$ は実空間においてロボットが行動を実行できる場所を示している．また，エッジ $e$ にはアクション $a$ が割り当てられており，ノード間の移行はエッジに割り当てられたアクション $a$ の実行を意味している．

世界状態依存アクショングラフ $G^a$ は，複数の行動可能性グラフ $G^a_{1\sim NW}$ から構成される．行動可能性グラフ $G^a_i$ は，世界状態 $W_i$ においてロボットが実行可能な行動とその実行場所を示すグラフである．行動可能性グラフ内において，実空間上を移動する移動行動などの世界状態が変化しない行動は，行動可能性グラフ内のエッジで表現される．一方，世界状態の変化を伴う行動は事前の行動可能性グラフ $G^a_i$ と事後の行動可能性グラフ $G^a_j$ 間のエッジで表現される．

世界状態アクショングラフを構築する上で，世界状態に対し実行可能な行動を対応付ける知識推論が必要である．そこで，世界状態の各物体の名称や物体集合の位置関係などの記号情報と各物体の位置などの幾何的な情報の双方の情報が有した表現方法として，記号情報と幾何情報の双方を有したシーングラフを構築し，知識推論に落とし込む．シーングラフ $G^s$ は，ノード集合 $V^s$ とエッジ集合 $E^s$ で定義される．

$$G^s = (V^s, E^s) \tag{3.5}$$

シーングラフ $G^s$ のノード $v^s$ に含まれる情報は，世界状態 $W$ の物体 $o$ の情報に該当する．そして，エッジ $e^s$ に含まれる情報は物体間の位置関係性である．

世界状態依存アクショングラフ $G^a$ の自動構築パイプラインは Fig. 3.1 に示すとおりである．

1. 世界状態 $W$ における物体集合の位置関係などの分類などに基づき，シーングラフ $G^s$ を構築することによる世界状態 $W$ に関する幾何的, 記号的な情報の構造化 (3.3.3 項)
2. 行動の事前知識に基づく，シーングラフ $G^s$ に対する実行可能な行動の対応付け (3.3.2, 3.3.4 項)
3. シーングラフ $G^s$ と対応付けられた行動に基づく事前行動可能性グラフ $G^a_0$ の構築 (3.3.5 項)

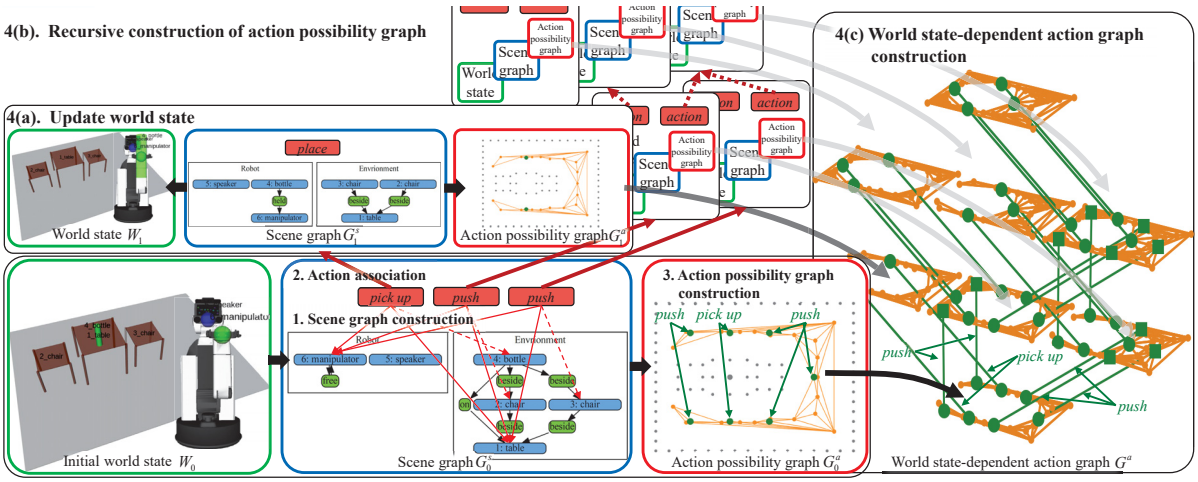


Figure 3.1: Pipeline diagram of WDAG construction

4. 事後行動可能性グラフの再帰的な構築 (3.3.6 項)

   (a) 行動可能性グラフ内の実行可能な行動の効果に基づくシーングラフや世界状態の更新

   (b) 更新後の世界状態に基づく再帰的な事後行動可能性グラフの構築

   (c) 取得した行動可能性グラフを統合することによる世界状態依存アクショングラフ $G^a$ の構築

ステップ 1，2，4(a)，(b) が特に従来のアクショングラフの構築手法から改変，追加された項目である．

### 3.3.2 行動知識の表現

世界状態や記号推論と親和性のあるシーングラフを用いて行動に関する事前知識を記述する．

以下で行動の性質の各項目について述べる．

- $l^a$: 行動のラベル
- $G^s_{a,p}$: アフォーダンスとして，この行動を実現する上での前提条件を示すシーングラフ
- $d^a$: 行動を実行するうえで対象物体からの適切な距離
- $N^{p^a}$: 行動実行場所の個数
- $G^s_{a,e}$: 行動の効果として $G^s_{a,p}$ の変化を示すシーングラフ

行動の目的は，特定の状況を作ることと，特定の行動の可能性を広げることに分けられる．例えば，その場を通過するために障害物を移動させる行動は，移動の可能性を作るための行動である．そのような行動も扱うため，行動の結果，影響を受けた物体が世界状態から除外される場合を *deleted* として考慮する．

例として考慮する行動は，移動を示す *movement* 行動，テーブルからボトルを持ち上げる *pick up* 行動，テーブルにボトルを置く *place* 行動，椅子をテーブルにしまう *push* 行動，人にその場を通してもらえるよう依頼する *speech* 行動，対応付けられた行動を破

Table 3.1: Prior knowledge of action

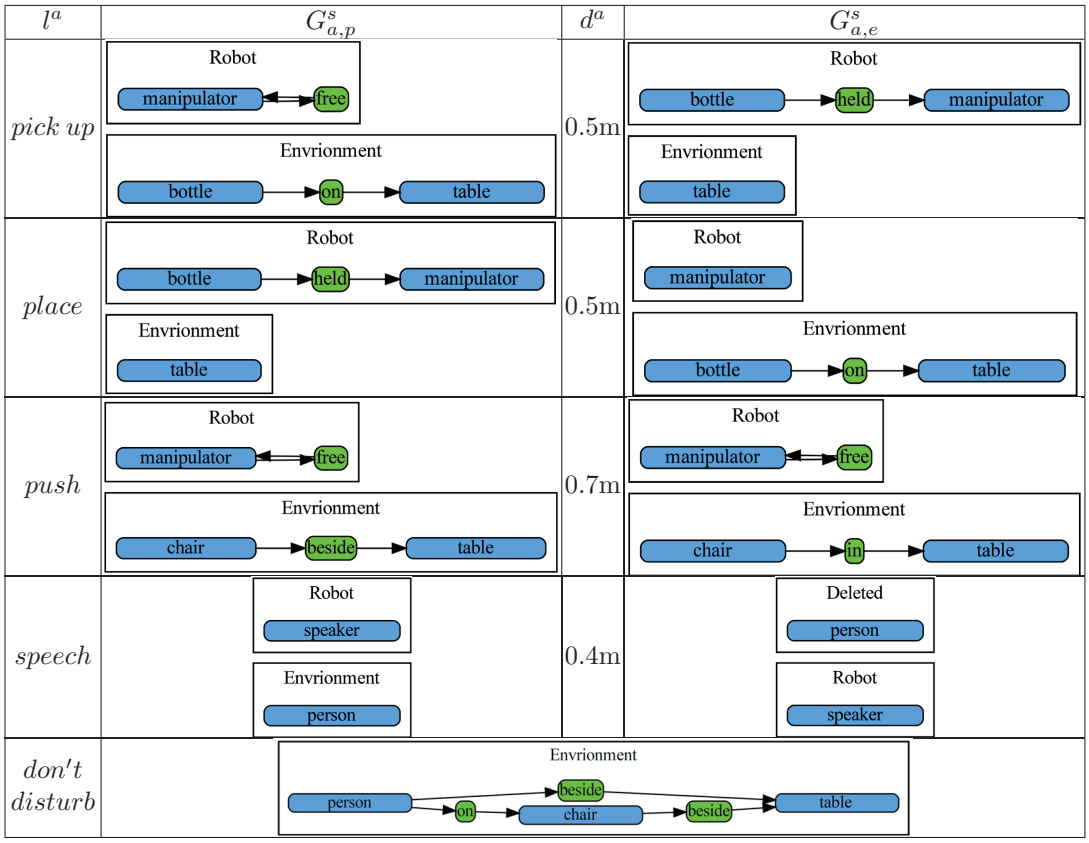


棄する *don't disturb* であり，それらの性質を Table 3.1 に示す．特に,*don't disturb* は丁寧なサービスが求められる着席したお客さんを対象とする状況において対応付けられるものであり，お客さんのいる椅子は動かさないなどのサービスルールを埋め込むための手段の例である．

本研究では，これらの行動に関する事前知識は，シーングラフの変化に着目したアフォーダンス学習や semantic event chain などのアクションモデルの学習手法の進歩により獲得可能となることを想定している [48, 53]．

### 3.3.3 世界状態に基づくシーングラフの構築

Semantic SLAM [68–70] などにより事前に構築された，物体の種類と位置の情報が記述されたセマンティックマップに基づき，推定された世界状態 $W$ に基づき，シーングラフ $G^s$ を構築する．シーングラフ $G^s$ とは，Fig. 3.2 に示すようにノードが世界状態における物体，エッジが位置関係を示す有向グラフである．シーングラフ $G^s$ の隣接行列は，世界状態における物体間の相対位置を位置関係ラベル $e^s$ に分類することで決定する．位置関係ラベル $e^s$ は，基本的にフットプリントが大きいものを基準とした小さいものへの相対位置を分類したものである．

本研究で考慮する位置関係は，*around*（物体 A から物体 B までの距離が 1.0 ∼ 2.0 m の場合）, *beside*（物体 A から物体 B までの距離が 0.0 ∼ 1.0 m の場合）, *in*（物体 B が物体 A の内部に存在する場合）, *on*（物体 B が物体 A の上面に存在する場合）, *held*, *free* である [45, 71]．特に，*held*，*free* は *manipulator* に関する属性，位置関係である．*manipulator* とそのほかの物体 A が同じ位置にある場合，位置関係は *held* と分類され

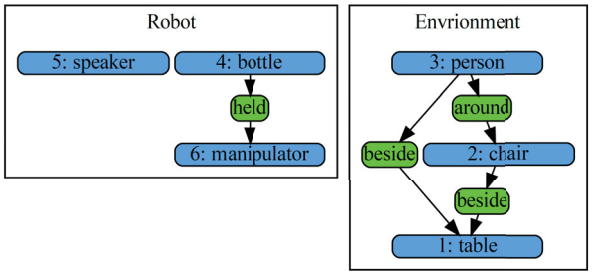


Figure 3.2: scene graph

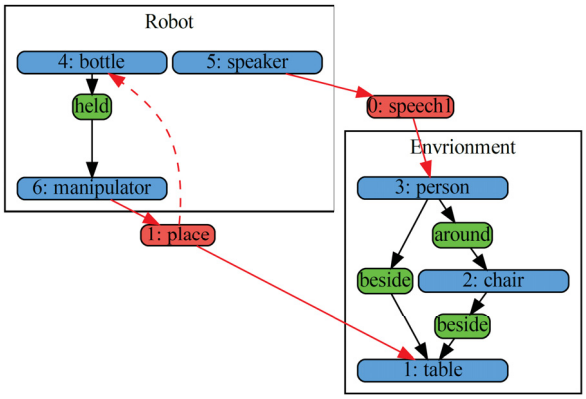


Figure 3.3: action associated scene graph

る．また，マニピュレータがどの物体とも位置関係性を持たない場合には，自己ループのエッジの位置関係ラベルを $free$ とする．

### 3.3.4 シーングラフへの行動の対応付け

エージェントが実行可能な行動は，世界状態 $W$ すなわち環境状態 $O$ とエージェント状態 $R$ に依存して変化する．そこで，世界状態 $W$ に基づき構築したシーングラフ $G^s$ と行動の事前知識におけるアフォーダンスを表現するシーングラフ $G^s_{a,p}$ に基づき，世界状態 $W$ に対して行動を対応づける．すなわち，世界状態における行動の前提条件の存在を検証するためのパターンマッチングを実施する必要がある．

そこで，世界状態における行動の前提条件のパターンマッチングの一つの方法として，シーングラフ $G^s$ 内に行動の前提条件のシーングラフ $G^s_{a,p}$ が部分グラフとして存在するかを検証するという部分グラフ同型問題へ落とし込む．具体的には，VF2 アルゴリズム [72] により，Fig. 3.3 に示すように世界状態 $W$ に対応するシーングラフ $G^s$ から行動の前提条件のシーングラフと同型の部分グラフを検出し，その部分グラフに行動を対応づけることが可能である．ここでは，同じ物体に対して複数の行動が割り当てることを許容する．しかし，割り当てられた行動に $don't\ disturb$ が含まれる物体については，割り当てられたすべての行動を棄却する．

### 3.3.5 行動可能性グラフの構築

#### 到達可能点のスパース表現

$movement$ 行動に着目し，エージェントが到達可能な位置をスパースに表現するノードの位置を取得する．エージェントが到達可能な位置をスパースに表現するための点を取得するアプローチとして，ボロノイ図に基づく方法を述べる．

まず，物体の位置，大きさ，形状の情報に基づき，壁を含めた環境状態 $W$ の各物体のフットプリントを二次元平面上の点集合で表現する．そして，得た点集合を母点とした一般化ボロノイ図を構築する．一般化ボロノイ図にはエージェントが到達できないノードが含まれるため，エージェントのフットプリントを考慮した上で到達困難なノードを削除する．さらに，より効率的に空間を表現するため，近いノード同士を統合し，Fig. 3.4b に示すようなノード集合を得る．

#### 対応付けられた行動の実行場所の追加

Fig. 3.4c に示すように，世界状態に対応付けられた行動の実行に適した位置へノードを追加する．

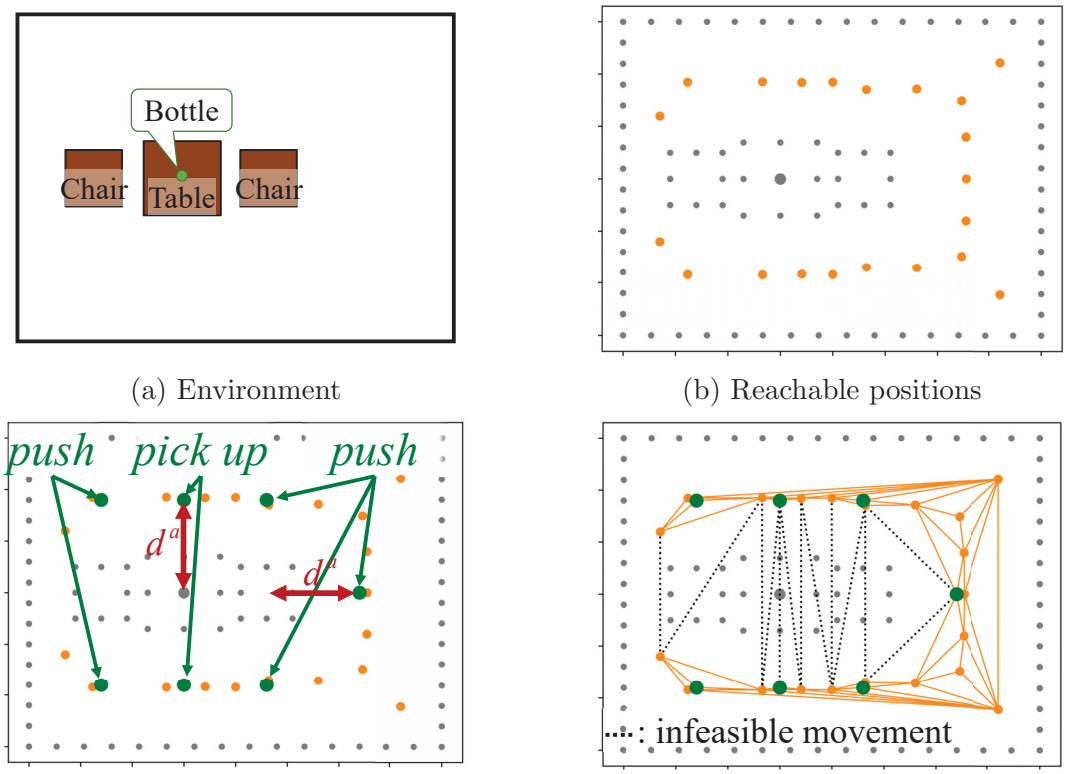


(a) Environment (b) Reachable positions

(c) Add action positions (d) Connecting nodes

Figure 3.4: Construction of action possibility graph

行動の実行位置の条件は，エージェントや周辺物体のフットプリントを考慮したうえで，エージェントがその場所とその場所から行動の対象物体へ到達可能であること，行動の実行に適した距離を確保できることである．まず，行動の実行位置に適した場所の候補点を，行動の事前知識に含まれる行動の実行に適した対象物体との距離 $d^a$ と行動の実行場所の個数 $N^{p^a}$，対象物体の位置，姿勢から決定する．本研究では，Fig. 3.4c に示すように，簡易的に中心を対象物体の位置，行動の実行に適した対象物体との距離 $d^a$ とした円周上の $N^{p^a}$ 点とした．ここで．$N^{p^a} = 4$ とした．そして，候補点のうち，エージェントのフットプリントを考慮したうえで環境中の物体と重ならない点，且つ対象物体との間に障害物が存在しない点を行動の実行位置のノードとして追加する．

#### ノード同士の接続

ノード間を接続するエッジは，幾何学的推論を通じて移動可能性を検証したうえで決定する．

まず，得られたノードを効率的に接続するエッジの候補を取得するため，ノード集合に対してドロネーの三角分割を適用することでエッジの候補を取得する．そして，環境中の物体の配置，フットプリントとエージェントのフットプリントに基づき，通過可能なエッジのみ採用する．そして最終的に Fig. 3.4d のような行動可能性グラフを得る．

### 3.3.6 再帰的な行動可能性グラフの構築

#### 概要

世界状態依存アクショングラフにおいて，世界状態の変化を伴う行動は，変化前後の行動可能性グラフを接続するエッジで表現される．さらに，エージェントの行動可能性

や世界状態とエージェントが実行する行動の相互作用を表現するため，行動可能性グラフのつながりを網羅的に把握する必要がある．

変化後の世界状態における行動可能性グラフの構築と，実行可能な行動の効果に基づく世界状態の更新による変化後の世界状態の把握を再帰的に繰り返すことで，網羅的に行動可能性グラフを把握する．そして，世界状態の変化の原因となった行動を意味するエッジで得られた行動可能性グラフ同士を接続することで世界状態依存アクショングラフを取得する．

行動可能性グラフを再帰的に構築し，世界状態依存アクショングラフを構築する具体的な処理を以下に述べる．

### 行動の効果に基づくシーングラフと世界状態の更新

ここでは，3.3.5 項の処理により得た事前行動可能性グラフ $G_0^a$ を始点とする．

まず，Fig. 3.5 に示すように，得た事前行動可能性グラフに対応付けられている各行動に基づき，行動後の事後シーングラフを把握する．行動に関する事前知識に含まれる行動の効果 $G_{a,e}^s$ に基づき，世界状態のシーングラフ内の行動が対応付けられている部分グラフを $G_{a,e}^s$ に変更する．そして，対応付けられた行動と同じ数の新たなシーングラフを得る．

次に，Fig. 3.5 に示すように，更新されたシーングラフに基づき，シーングラフのノード，すなわち世界状態を更新する．具体的には，行動によって変更されたシーングラフのエッジに割り当てられた位置関係 $r$ に基づき，物体の位置を更新する．更新後の物体の位置には，シーングラフ構築時の位置関係の分類手法に基づき，位置関係 $r$ の代表的な配置を適用する．

### 行動可能性グラフの構築

更新されたシーングラフや世界状態に基づき，事後行動可能性グラフを構築する．基本的に，3.3.4, 3.3.5 項で述べた処理に基づき，行動可能性グラフを構築する．変更点は，考慮するノードが追加された点である．Fig. 3.6 に示すように，ノードに，エージェントが到達可能な点と対応付けられた行動の実行場所に加えて，事後行動可能性グラフに変化する原因となった行動の実行場所を行動結果ノードとして追加したうえで，行動可能性グラフを構築する．変化する原因となった行動の実行場所は，事前の行動可能性グラフから取得可能である．これにより，行動前後の行動可能性グラフをエッジで接続することが可能となる．

### 反復処理

得られた新たな行動可能性グラフに対応付けられた各行動に対して，以上の処理を繰り返し適用し，網羅的に世界状態や行動可能性グラフを取得する．その際，すでに出現していない世界状態や行動可能性グラフのみを採用し，異なる経緯で同じ世界状態が得られた場合はそれらを統合する．そして，把握した行動可能性グラフに対応付けられたすべての行動に対して処理を実行した際，反復処理を終了する．その際，エージェントが実現可能な世界状態や行動可能性グラフをすべて把握したこととなる．

パスカルの三角形を参考に，異なる経緯で得られた同じ世界状態を統合することで，考慮すべき世界状態の数を有限個に制限する．世界状態に対応付けられる行動の数は世界状態によって増減するため，探索的に世界状態を構築することなく，事前の世界状態や行動の事前知識などに基づき事後の世界状態や行動可能性グラフの数を算出することは困難である．実現可能な世界状態やその数の概算については，行動可能性グラフは構築せず，世界状態への行動の対応付けと行動に基づく世界状態の更新の記号推論のみか

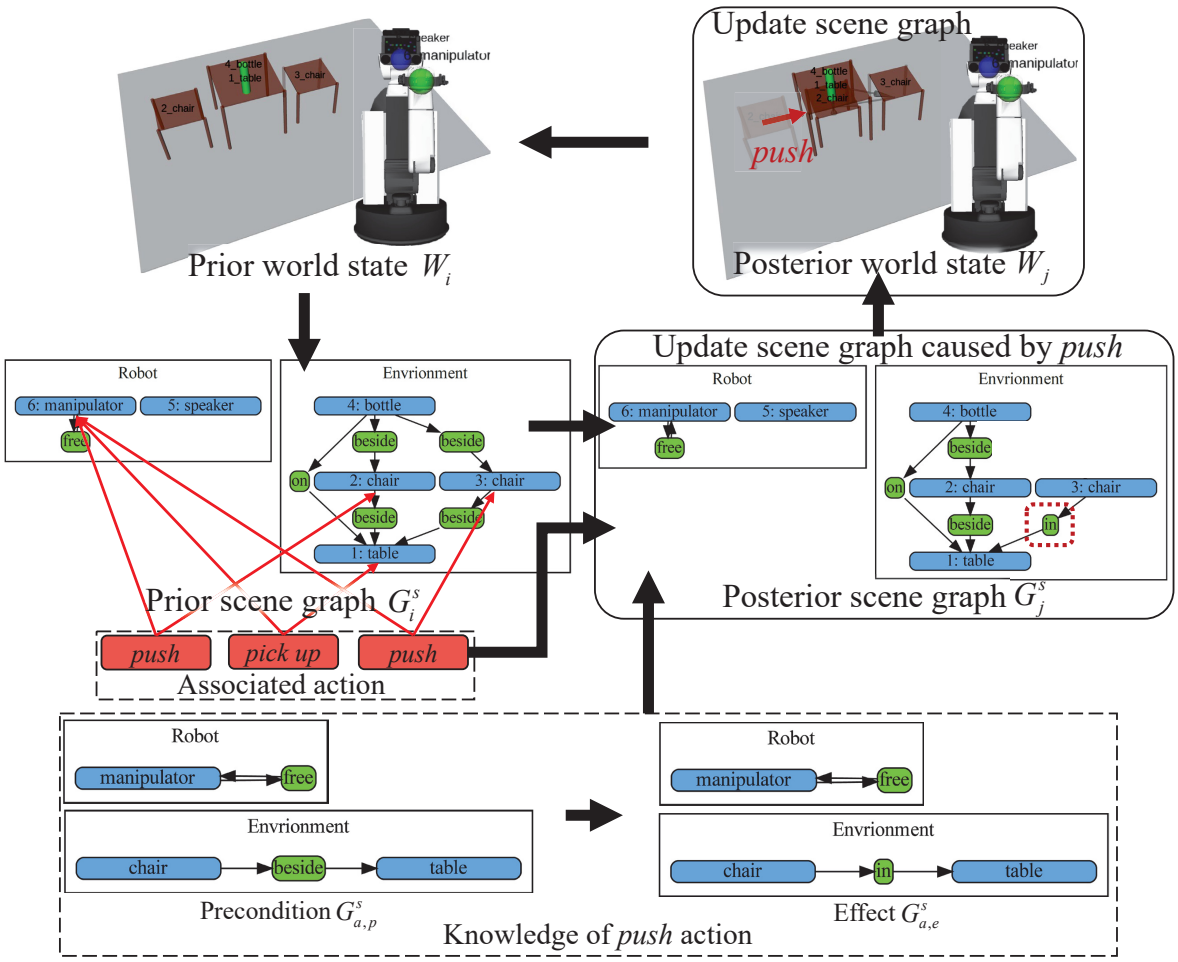


Figure 3.5: Updating scene graph and world state based on action knowledge

ら行うことは可能である．しかし，行動可能性グラフを構築し，幾何的に各行動の実行可能性を検証する過程で実現困難な世界状態は除かれるため，実空間において実行困難な行動が含まれる場合は，記号推論により把握される世界状態の数よりも実空間で実現可能な世界状態の数は減少する．

### 行動可能性グラフの接続

取得した行動可能性グラフをエッジで接続し，多層構造のグラフを構築する．具体的には，Fig. 3.6 に示すように変化前後の行動可能性グラフを，変化の原因のアクションが割り当てられたエッジで接続する．接続するノードは，変化の原因となった行動に関する事前行動可能性グラフ内の実行場所のノードと事後行動可能性グラフ内の行動結果ノードである．また，エッジは変化前から変化後への有向のエッジであり，変化の原因となった行動が割り当てられる．この処理をすべての行動可能性グラフに対して適用し，最終的に得られた多層構造のグラフが世界状態依存アクショングラフである．

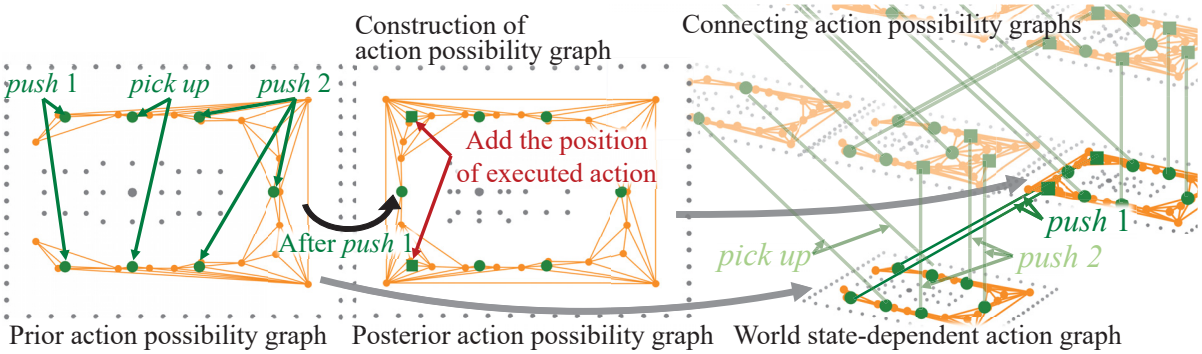


Figure 3.6: Connecting action possibility graphs

## 3.4 世界状態依存アクショングラフに基づくモバイルマニピュレーションタスクの計画

### 3.4.1 アクショングラフにおけるモバイルマニピュレーションタスクの解釈

モバイルマニピュレーションタスクは，初期状態 $init(\boldsymbol{p}_0^R, W_0)$ と目標設定 $goal(\boldsymbol{p}_g^R, G_g^s)$ で指定される．初期状態 $init(\boldsymbol{p}_0^R, W_0)$ は初期のエージェントの位置 $\boldsymbol{p}_0^R$ と初期の世界状態 $W_0$ で構成される．Navigation among movable object (NAMO) に代表されるような移動タスクの場合，目標設定 $goal(\boldsymbol{p}_g^R, G_g^s)$ は目標の位置 $\boldsymbol{p}_g^R$ とロボットが初期状態と同様であることを示すシーングラフ $G_g^s$ で指定される．一方，運搬や片付けタスクであれば，目標設定 $goal(G_g^s)$ は世界状態の必要条件を表すシーングラフ $G_g^s$ のみで指定される．

3.3 節で述べた手順に従い，世界状態依存アクショングラフを自動で構築し，得られたアクショングラフに計画手法を適用することで $init$ から $goal$ への行動列を得る．世界状態依存アクショングラフを計画手法に適用するためには，$init$ と $goal$ に基づきスタートノードとゴールノードをアクショングラフ内から決定する必要がある．世界状態依存アクショングラフには，同じ位置を示すノードが複数存在するが，それぞれのノードによって対応する世界状態が異なる．そして，そのノードへ到達するまでの行動もそれぞれ異なる．そこで，環境変化前の事前行動可能性グラフ $G_0^a$ において初期のエージェントの位置 $\boldsymbol{p}_0^R$ に最も近いノードをスタートノードとして設定する，ゴールノードに関しては，まず $goal$ が目標位置 $\boldsymbol{p}_g^R$ だけで指定された場合，世界状態依存アクショングラフを構成する各行動可能性グラフにおいて，目標位置 $\boldsymbol{p}_g^R$ から最も近いノードをそれぞれゴールノードとして設定する．$goal$ がシーングラフ $G_g^s$ のみで指定される場合，まず，世界状態依存アクショングラフを構成するそれぞれ行動可能性グラフに対応する世界状態のシーングラフに部分グラフとして $G_g^s$ が含まれるものを取得する．そして，取得した世界状態に対応する行動可能性グラフに含まれる行動結果ノードをそれぞれゴールノードとする。最後に，$goal$ に含まれる情報が目標位置 $\boldsymbol{p}_g^R$ とシーングラフ $G_g^s$ の両方の場合には，同様にまず世界状態依存アクショングラフを構成するそれぞれ行動可能性グラフに対応する世界状態のシーングラフに部分グラフとして $G_g^s$ が含まれるものを取得する．そして，取得した世界状態に対応する各行動可能性グラフにおける目標位置 $\boldsymbol{p}_g^R$ から最も近いノードをそれぞれゴールノードとする．

### 3.4.2 計画

グラフ上の最短経路探索における基本的なアルゴリズムの一例としてダイクストラ法を適用し，世界状態依存アクショングラフ上のスタートノードからゴールノードへの最

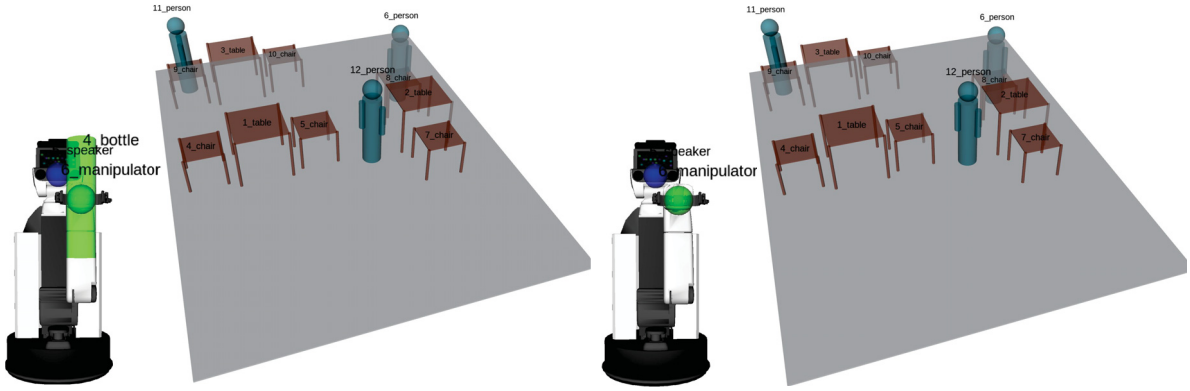


(a) Experiment 1.1 (b) Experiment 1.2

Figure 3.7: World state of Experiment1

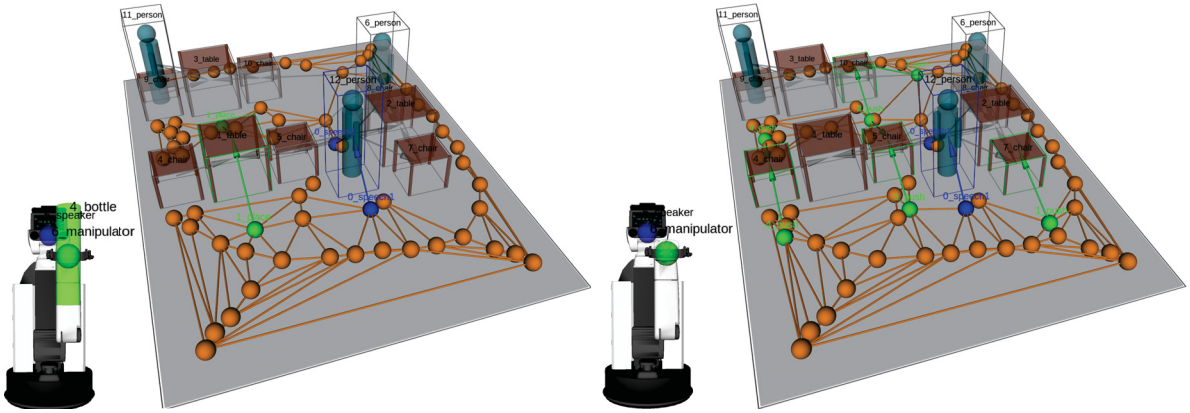


(a) Action possibility graph for world state in Experiment 1.1

(b) Action possibility graph for world state in Experiment 1.2

Figure 3.8: Difference of action possibility graph depending on agent's state

適な行動列 $A$ を算出する．すべての行動戦略すなわちスタートノードと把握したゴールノードのすべての組み合わせに対して，ダイクストラ法により各行動戦略（スタートノードとゴールノードの組み合わせ）の最小コストを取得する．得られた各行動戦略のコストを比較し，コスト関数に応じた適切な行動戦略とそれに対応した行動列を決定する．

世界状態依存アクショングラフのエッジに埋め込むコストの評価指標としては，移動距離や所要時間，エネルギー消費量などが例として考えられる．本研究では，一例として移動距離に基づいてコスト関数を設計した．具体的には，*movement* 行動のコストはエッジの長さ，*push* 行動や *pickup* 行動, *place* 行動, *speech* 行動など他の行動のコストに関しては，行動の実行に必要な移動距離を設定する．

## 3.5 実験

### 3.5.1 実験 1: 世界状態依存アクショングラフの検証

#### 実験設定

世界状態依存アクショングラフの有効性を検証するため，以下の項目を定性的に評価した．

1. 世界状態依存アクショングラフでは，エージェントの状態に依存した行動可能性を捉えられること

3. 世界状態依存アクショングラフに基づくモバイルマニピュレーション計画

2. 世界状態依存アクショングラフでは，エージェントの行動による行動可能性の変化を捉えられること

本実験では，エージェントとしてモバイルマニピュレータの HSR [57]，環境としてカフェを模擬した環境を想定した．対象とする世界状態は，Fig. 3.8 に示すようなエージェントの状態が異なる二つの世界状態である．世界状態 1 では，エージェントがボトルを握っており，世界状態 2 ではエージェントは何も握っていない．

#### 実験結果

まず，二つのエージェントの状態が異なる世界状態に基づき構築した行動可能性グラフを Fig. 3.8 に示す．行動可能性グラフでは，実空間においてエージェントが実行可能な行動とその位置が表現されている．Fig. 3.8a によると，世界状態 1 において，実行可能な行動は，テーブルにボトルを置くこと，人に話すことが可能であることが把握できている．その一方で，Fig. 3.8b によると，世界状態 2 では，椅子を押すことや人に話すことが可能であることが把握できている．このように，提案手法では，エージェントのマニピュレータの状態に応じた行動可能性を把握することが可能である．

次に，世界状態 1 に基づき構築した，世界状態依存アクショングラフを Fig. 3.9 に示す．この世界状態依存アクショングラフは，64 個の行動可能性グラフで構築されているため，ロボットが実現可能な世界状態は 64 通りである．この世界状態依存アクショングラフにおいて，初期状態から，*place*，*push* を実行した場合の行動可能性グラフの変化を Fig. 3.10 に示す ($G_0^a \Rightarrow G_2^a \Rightarrow G_6^a$)．Figs. 3.8a, 3.10a に示した $G_0^a$ と $G_2^a$ を比較すると，*place* 行動によりボトルを机に置いたことにより，椅子を押す *push* 行動が新たに選択可能となっていることがわかる．また，Figs. 3.10a, 3.10b に示した $G_2^a$ と $G_6^a$ を比較すると，エージェントが *push* 行動により椅子を移動させる後に，その椅子があった場所が移動可能となっていることがわかる．さらに，行動可能性グラフのつながりにより，$G_0^a$ の初期状態では，干渉が困難な椅子で遮蔽されていた通路が，世界状態の変化を経ることで，通過可能となることを把握することが可能である．以上より，再帰的な多層構造を採用することにより行動可能性とエージェントが実行する行動の相互作用を捉えることが可能であることを示した．

世界状態依存アクショングラフにおける個々の行動可能性グラフでは，幾何推論に基づき実空間における実行可能な行動や実行場所が表現されている．さらに，世界状態依存アクショングラフにおける行動可能性グラフのつながりは，従来のシンボリックな表現と同様にアクションの実行することで実現可能な世界状態を表現している．このように，世界状態依存アクショングラフは記号的推論と幾何学的推論の両方を兼ね備えており，実空間における実現可能な行動列を包括的に捉えることができるため，世界状態依存アクショングラフに基づくタスクプランニングは，評価指標に応じてより適切な行動列を導出できることが期待される．

### 3.5.2 実験 2: 世界状態依存アクショングラフに基づくタスクプランニングの検証

#### 実験設定

本実験は Laser range finder やカメラを有したモバイルマニピュレータの HSR [57] を用いて実施した．オフライン処理にて，システムは事前に得られた世界状態に基づき構築した世界状態依存アクショングラフに基づき行動列を得る．そして，オンライン処理にて，モバイルマニピュレータは得られた行動列を順に実行した．*movement* 行動では，ファジーポテンシャル法に基づき，Laser sensing により観測した障害物を考慮して速度を決定した [61]．*push*, *pick up*, *place* 行動については，椅子や机に設置された AR マー

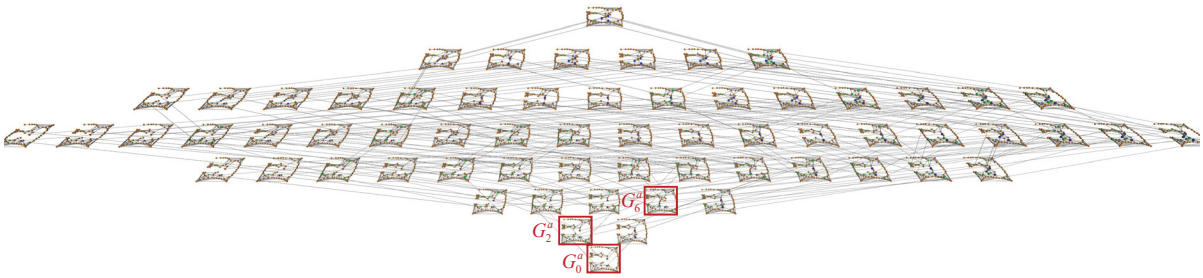


Figure 3.9: World state-dependent action graph based on world state in Experiment 1.1

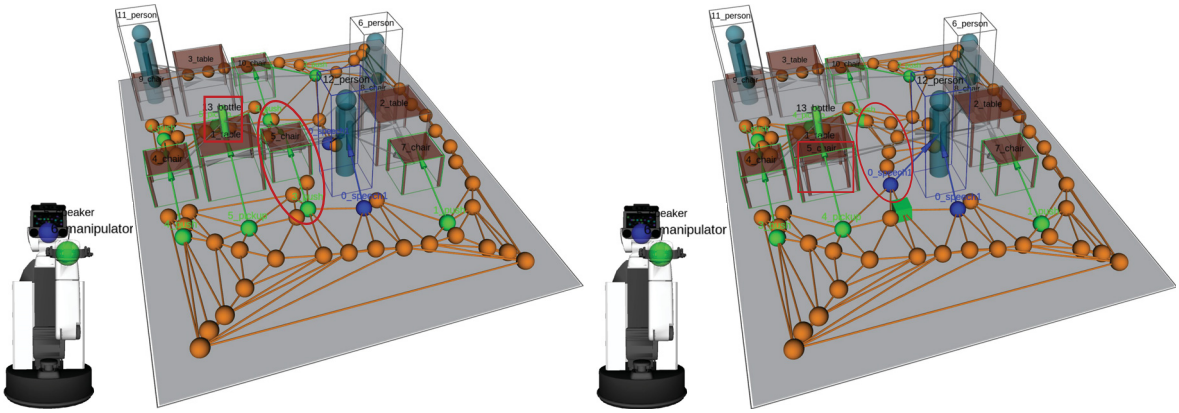

(a) Action possibility graph $G_2^a$ (b) Action possibility graph $G_6^a$

Figure 3.10: Mutual interaction between action possibility and action

カのカメラセンシングに基づき，物体とモバイルマニピュレータの相対座標系において動作を計画し，追従した．

考慮した行動は *movement* 行動に加えて，Table 3.1 に示す行動である．また，各エッジに対応付けられる行動に伴うコストは，*movement* 行動の場合はエッジの長さに基づき決定し，それ以外の行動の場合は行動に伴う移動として 0.3 とした．

従来の二つの設計思想に基づき構築されたアクショングラフを用いて計画された行動列と提案手法を比較した．比較手法 1 は，動作計画によって行動の実行可能性を検証する手法 [23, 24] を想定した手法とする．具体的には，行動列の探索と動作計画による各行動の実行可能性の検証を交互に実施し，行動列を構成する行動の数が少なく実行可能な行動列を取得する手法である．アクショングラフを用いた設計法として，事前の行動可能性グラフに基づく各行動の実行可能性の検証や行動の実行場所の決定により，行動列を取得する手法とした．比較手法 2 は，動作計画によって移動すべき移動可能物体を把握する手法 [22, 41] を想定した手法とする．具体的には，各行動の実行可能性を検証する際，移動可能な物体を除いた上で動作を計画し，移動可能物体との干渉を検出することで，その行動を実行する前に実行するべき行動を特定する手法である．そこで，アクショングラフを用いた設計法として，移動可能物体を除いた事後の行動可能性グラフに基づく各行動の実行可能性の検証や行動の実行場所の決定により，行動列を取得する手法とした．また，提案手法では実行可能な行動列が計画可能であることを示すため，実機実験において計画された行動列の実現可能性を検証した．カフェにおけるモバイルマニピュレーションタスクの例として，実験 1 では NAMO シナリオを想定し，Fig. 3.11a に示すようにスタート位置 $p_0^R$ でボトルを握ったモバイルマニピュレータを初期の世界状態 $W_0$ を初期状態 *init* とした．目標設定 *goal* は，エージェントのゴール位置 $p_g^R$ とボトルを握ったエージェントの状態 $G_g^s$ で指定した．実験 2 では，物体の片づけシナリオを想定した．Fig. 3.11b に示すようにスタート位置 $p_0^R$ とボトルを握ったモバイルマニピュレータを初期の世界状態 $W_0$ を初期状態 *init* とした，目標設定 *goal* は，テーブル 4 の上

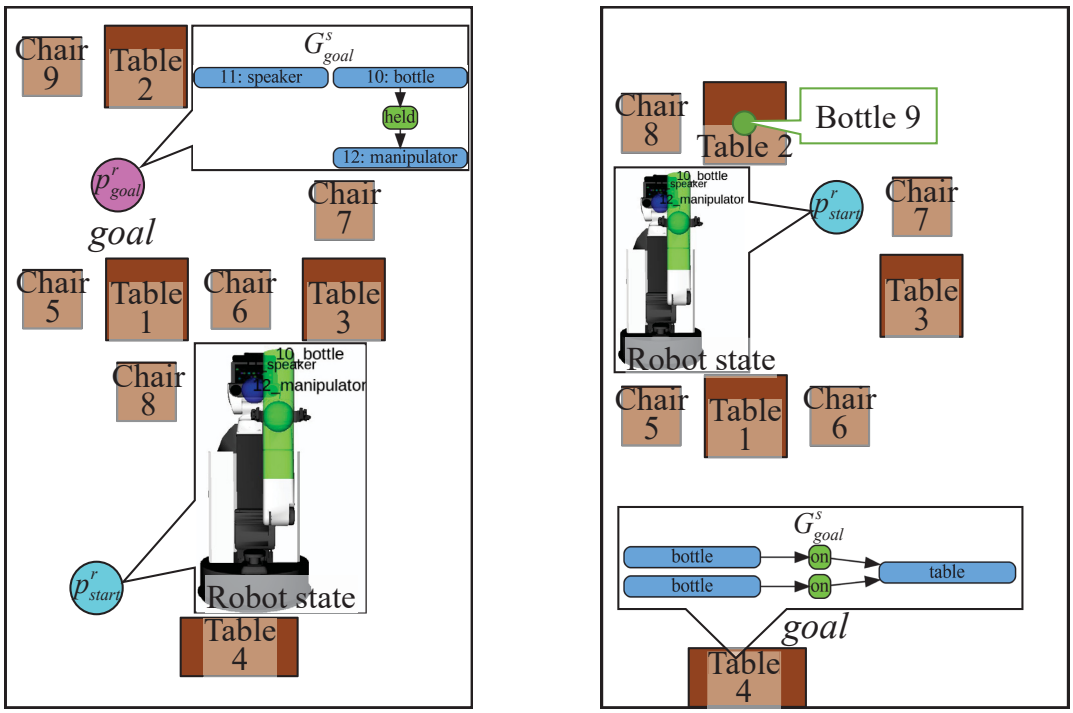


(a) Experiment 2.1 (b) Experiment 2.2

Figure 3.11: Initial state *init* and goal specification *goal* of Experiment 2

に二つのボトルが乗った部分的な環境状態を表すシーングラフ $G^s_g$ により指定した．

### 実験結果

実験 1 の結果を Fig. 3.12 に示す．Fig. 3.12a に示された行動列は，動作計画により各行動の実行可能性を検証する比較手法 1 により得た行動列である．比較手法 1 により，すべての障害物を回避しつつ，スタート地点から，ゴール地点へ到達する行動列が取得された．Fig. 3.12b に示された行動列は，動作計画により移動するべき移動可能物体を特定する比較手法 2 により得られた行動列である．比較手法 2 では，移動可能物体を除いた状態での最短経路上の物体である椅子 5 が移動するべき物体として特定された，そのため，まず，テーブル 4 にボトルを置いたのちに，椅子 5 を移動させ，テーブル 4 に置いたボトルを再度把持し，ゴールへ向かう行動列が得られた．Fig. 3.12c に示された行動列は，提案手法により得られた行動列である．得られた行動列は，テーブル 3 にボトルを置いたのちに，椅子 6 を移動させ，椅子 6 が存在した位置からテーブル 4 に置かれたボトルを把持した後にゴールへ向かうことを意味している．提案手法は，各行動をそれぞれ検証する比較手法と異なり，実行可能な行動の時間的空間的関係性表現したグラフ上で計画するため，椅子 6 を移動させる移動効率がより良い行動列が得られた．また，Fig. 3.12d は，提案手法で導出した行動列を実際のモバイルマニピュレータで実行した結果であり，行動列は実世界において実行可能であることを示している．

実験 2 の結果を Fig. 3.13 に示す．Fig. 3.13a に示す比較手法 1 から得た行動列は，ロボットがすべての障害物を回避しつつ，まず始めから把持しているボトルをテーブル 4 に置いたのちに，テーブル 2 に置かれたボトルをテーブル 4 に置くために往復することを意味している．また，Fig. 3.13b に示す比較手法 2 では，椅子 6 が移動するべき物体として特定された，そのため，ロボットはまずテーブル 3 にボトルを置き，椅子 6 を押した後に，テーブル 3 に置いたボトルを再度把持する．そして，テーブル 4 にボトルに置いたのちに，テーブル 2 に置かれたボトルをテーブル 4 を置くため椅子 6 の位置を通

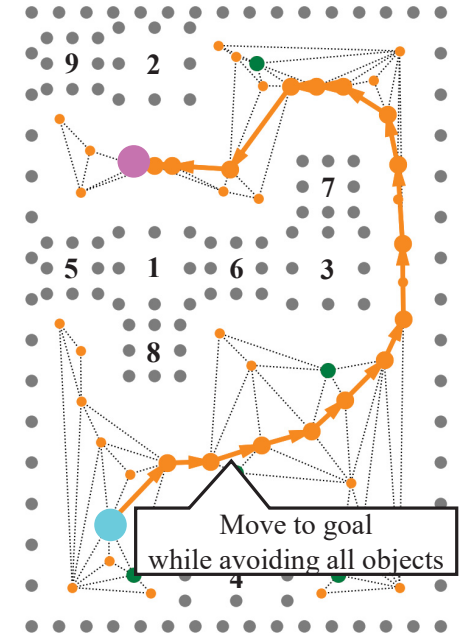


(a) Comparison method 1
(Cost: 8.67)

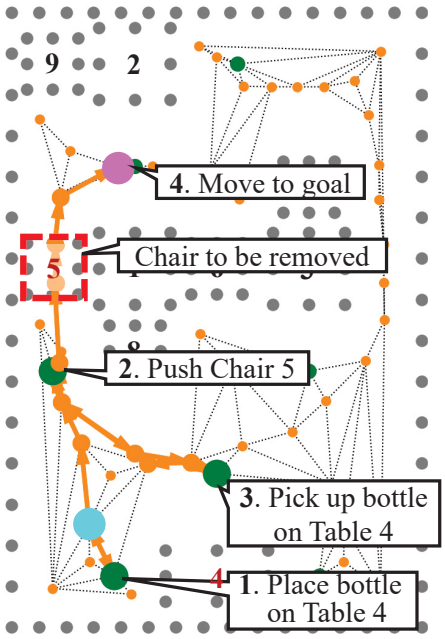


(b) Comparison method 2
(Cost: 10.24)

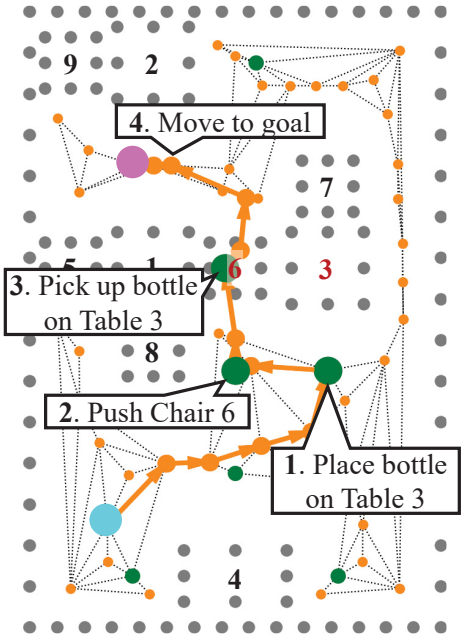


(c) Proposed method
(Cost: 7.89)

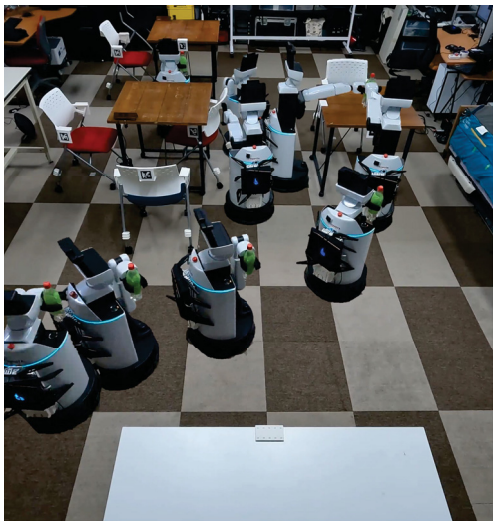

(d) Actual movement

Figure 3.12: Result of Experiment 2.1

過する経路で往復するという行動列が導出された．提案手法により導出された行動列は Fig. 3.13c に示すとおりである．まず，ボトルをテーブル 1 に置いて椅子 5 を移動させたのちに，先にテーブル 2 に置かれたボトルをテーブル 4 へ運搬し，最後にテーブル 1 に置かれたボトルをテーブル 4 の近くから持ちテーブル 4 へ運搬した．このように提案手法では，机の配置を考慮したうえで，最初から把持していたボトルよりも先にテーブル 2 に置かれたボトルを運搬するという，従来手法とは異なる行動の順番の効率的な行動列が得られた．また，Fig. 3.13d は提案手法で導出した行動列を実際のロボットで実行した結果であり，行動列は実行可能であることを示している．

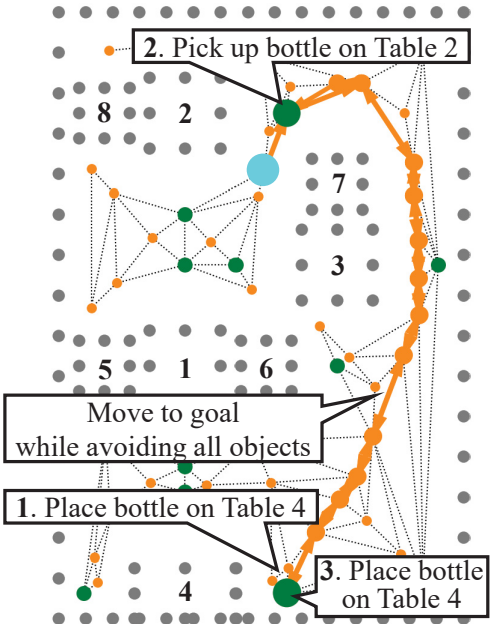


(a) Comparison method 1
(Cost: 8.67)

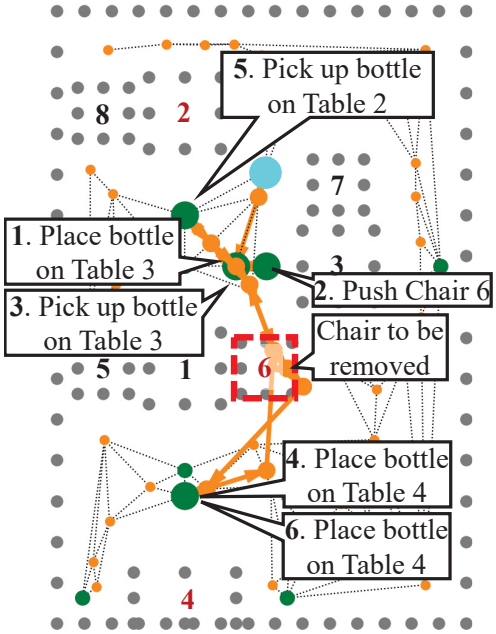


(b) Comparison method 2
(Cost: 10.24)

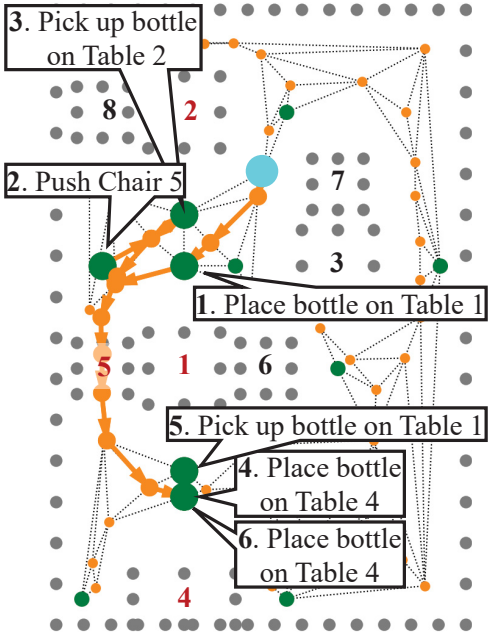


(c) Proposed method
(Cost: 7.89)

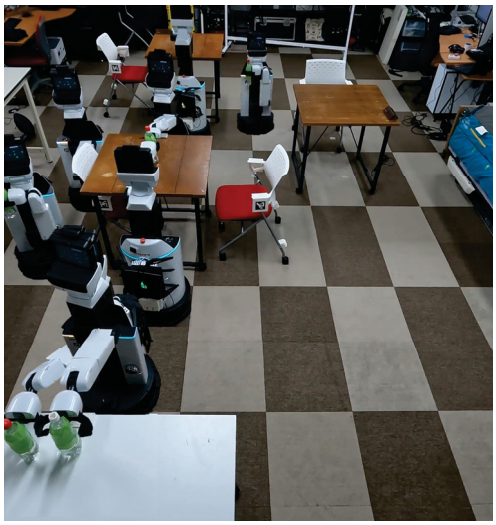

(d) Actual movement

Figure 3.13: Result of Experiment 2.2

コスト設計に依存するが，移動距離に基づく各行動列のコストを比較すると，提案手法で導出した行動列が最も低コストであることが明らかになった．以上の結果より，提案手法では，行動可能性とその網羅的な変化を一つのグラフで表現する世界状態依存アクショングラフに基づき計画することで，より多様な候補の中から行動の種類とその実行場所を同時に時空間的に最適化することで，実空間においてより効率的な行動列を取得することが可能であることを示した．また，実機実験により．提案手法により得られた行動列は実行可能であることが示された．

## 3.6 結言

本章では，まず世界状態におけるロボットが実行可能な行動の時空間的な繋がりを把握する環境表現である世界状態依存アクショングラフを提案した．世界状態依存アクショングラフでは，シーングラフを用いた知識表現や再帰的な多層構造を採用し，世界状態に基づくロボットが実行可能な行動の時空間的関係性の把握を実現した．世界状態依存アクショングラフに基づく，モバイルマニピュレーションの計画手法を提案した．網羅的に把握した行動の時空間的関係性に基づき計画することで，タスクの達成に有効な行動列の候補をより多く把握することを実現した．カフェを想定した環境におけるシミュレーションや実機実験を通じて提案手法の有効性を評価した．シミュレーションでは，従来のアクショングラフと提案の世界状態依存アクショングラフを比較し，提案手法がより行動可能性に関する正確で豊富な情報を提供できることを示した．具体的には，世界状態に基づき行動可能性が理解できること，再帰的多層構造を採用することでロボットの行動による行動可能性の変化が理解できることを示した．世界状態依存アクショングラフに基づくモバイルマニピュレーションの計画における実機実験では，提案手法により有効な行動列の候補をより多く取得することで，従来手法に比べてより経路が短い行動列を取得することが可能であり，実空間において実行可能でロボットの機能を有効活用できることを示した．

# Chapter 4

# マルチモーダルポテンシャル場に基づく接近行動のアクションモデリング

## 4.1 緒言

本章では，ロボットに搭載されているセンサを活かしHRI行動を促進するため，人への接近行動のアクションモデリング手法を提案する．そして，HRI行動を実行する際，特に重要となる情報として人の画像情報や音声情報に着目し，それぞれの必要性に応じてカメラやマイクを取得可能な位置へ接近することでHRI行動を促進する．その際，カメラやマイクなどのセンサ特性や障害物情報，HRI行動の内容や人の情報など，次元の異なるマルチモーダル情報に基づき，ロボットの移動先を決定する必要がある． そこで，本研究ではマルチモーダル情報を同じ情報空間へ統合するための手法を提案したうえで，それに基づきロボットのナビゲーションやアクショングラフ構築へ適用する手法を提案する．

まず，本研究に関連するコストマップに基づく経路計画と人への接近行動に関する既存研究と，既存研究における課題を述べる．次に，本研究における人の認識手法と新たに提案する人の認識の信頼度に関する評価指標について述べる．さらに，ロボットに搭載されているセンサを用いた姿勢や音声などの人のセンシングに関する実験とその結果に基づくセンサ特性の定式化について述べる．そして，ロボットに搭載されているセンサを活かしHRI行動を促進するための人への接近行動のアクションモデリング手法を述べる．具体的には，センサ特性や人の情報など，次元の異なる情報を実空間におけるポテンシャル場を用いて同じ情報空間へ統合するための方法について述べる．さらに，接近行動のアクションモデルに基づくロボットナビゲーション手法とアクショングラフへの導入方法について述べる．最後に，提案手法の有効性についてシミュレーションと実機実験により検証する．具体的には，提案の接近行動のアクションモデルではタスク内容や人の配置，動的な配置の変化に応じて，ロボットを必要なセンサ情報が取得しやすい位置へ移動させることが可能であることを検証した．さらに，提案の接近行動のアクションモデルに基づくアクショングラフの構築手法の有効性を，複数の手法と比較することで検証した．

## 4.2 既存研究とその課題

本研究は，コストマップに基づく経路計画手法に関連している．特に，障害物だけでなく，人とロボットのインタラクションを考慮したコストマップは，強く関連する．また，HRI行動をより容易にするための接近行動のモデル化手法にも関連している．

### 4.2.1 コストマップに基づくナビゲーション手法

障害物に衝突しないロボットナビゲーションは，各値が障害物の存在確率を表現するコストマップを考慮した経路計画で実現されてきた [73–75]. さらに，社会的に受け入れられるナビゲーションを扱うため，ソーシャルマッピングが提案されている [76, 77]. 先述のコストマップは障害物回避と目的地到着のために使用されていたのに対し，ソーシャルマップは人間要因も考慮したナビゲーションを扱うための環境表現である. Sisbot らは，人間の視野，ロボットの視認性，安全性などを追加的に考慮したソーシャルマップを提案した [78]．この手法では，各個人の姿勢や壁などの障害物によって遮蔽される領域に基づいてソーシャルマップが算出される．また，Rios-Martinez らは，複数人のコミュニケーションにおける人の配置を考慮したコストマップに基づくロボットナビゲーション手法を提案している [79, 80]．平川らは人間の行動を参照するアプローチとして，意味的なシーンコンテキストと観察された人間の行動に基づきコストマップを構築するための手法を提案した [81]．よりセマンティックで時間依存性の高い情報を表現するための多層コストマップも提案されている [82, 83]．しかし，これらの手法は，主に予め設定された目的地に移動する際の経路に着目している．一方，Gómez らは，人とのすれ違いだけでなく，人の接近も考慮した経路計画法を提案している [84]．また，本手法は，人の多様な配置に対応することができる．

これらは人との共存環境において円滑に移動するために主に人間を中心とした要素を考慮した研究である．一方，提案手法では，人とのインタラクションを円滑にするため，センサの特性に基づきロボットがインタラクションを行いやすいように目的地と経路を計算する．

### 4.2.2 接近行動のモデリング手法

特定の HRI タスクを達成するため，ロボットが人に接近する際の移動を設計する研究が行われている [85–89]．Dautenhahn ら [85] は，座っている人に物を渡すために，ロボットが様々な方向から接近させ，適切な目的地を検証した．その結果，ロボットが物を渡すためには左右からではなく，正面から近づいた方が被験者に安心感を与えることを明らかにした．また，佐竹らは，紙媒体の広告物を人に配布することを目的にしたロボットの移動のモデリング方法を提案した [87]．具体的には，ロボットがターゲットとなりうる人物の行動を考慮して接近する人物を決定し，選択された人物に正面から接近して対話を開始するという移動のモデリングを実現している．さらに，人を警告するための接近行動についても研究がなされている [89]．人を警告するための接近行動は，実際の警備員の動きに基づきモデル化された．

上記の既存研究では，特定のインタラクションタスクを対象としているが．サービスロボットは様々なインタラクションタスクを達成できることが求められる．そのため本研究では，それぞれのタスクの遂行に重要な感覚モダリティを考慮することで，複数のインタラクションタスクをそれぞれ円滑に進めるために必要な自律移動を実現する．

## 4.3 人の認識

### 4.3.1 人の位置と向きの推定

人の認識方法として，RGB-D カメラを用いた画像センシングにより人の検出と姿勢推定を行う．人の位置 $\boldsymbol{p}^{\boldsymbol{h}}(t)$ は関節位置の重心として算出する．

まず, RGB 画像に対して OpenPose [90,91] を適用し, 人の姿勢を推定する．OpenPose では Fig. 4.1a に示すように体の一部に隠れが生じている場合にも人の検出や関節位置推定が可能である．次に，得られた RGB 画像中の関節位置と RGB-D カメラから得られる

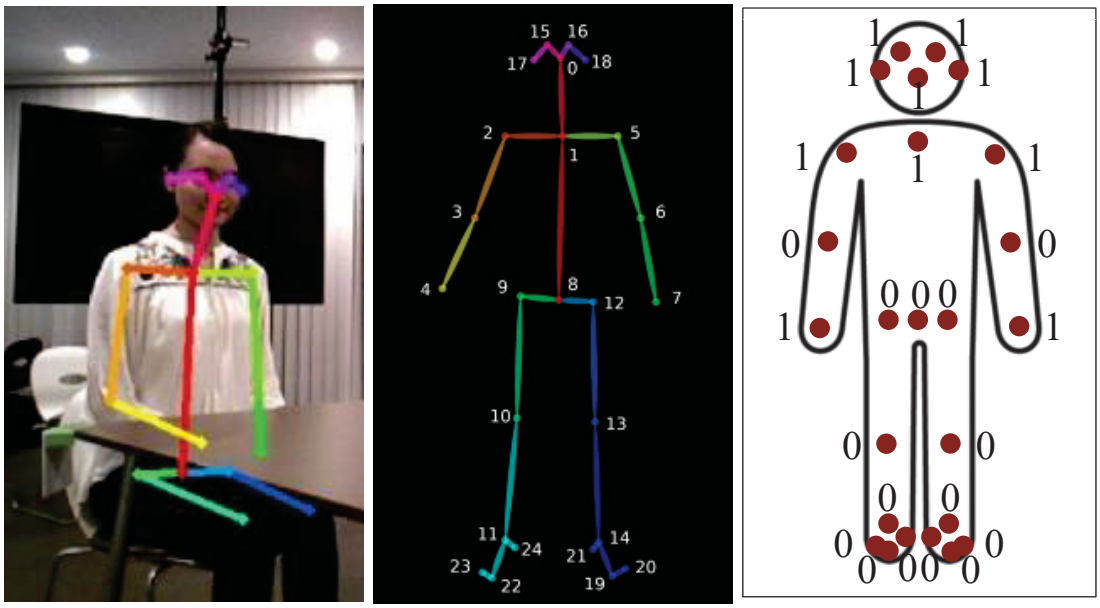


(a) Analyzed image (b) Joints (c) Weights

Figure 4.1: Joint position estimation using OpenPose

深度画像を組み合わせることで関節の 3 次元位置を取得する．最後に，人の位置の観測値 $\boldsymbol{p}^{\boldsymbol{h}}(t)$ は推定された関節の 3 次元位置の重心として算出する．

人は机の方向を向いて着席していると仮定し，人の位置のフィルタリングや人の向きの推定をする．人の位置 $\boldsymbol{p}^{\boldsymbol{h}}(t)$ は，静止モデルに基づくカルマンフィルタで推定する．また，人の向き $\theta(t)$ は机の位置と人の位置から算出する．

### 4.3.2 認識信頼度

RGB-D カメラを用いた人の認識の信頼度はセンシング条件によって変化する．対象の人を正確に認識するためには，評価した信頼度に基づき，ロボットが積極的にセンシング条件を改善することが求められる．そこで，本研究では，人の認識の信頼度を認識信頼度 $r^{I}_{All,i}(t_{\mathrm{obs}})$ と呼ばれるパラメータとして定義し，センシングデータに基づき算出できるよう定式化する．人を認識した時間 $t_{\mathrm{obs}}$ における認識信頼度 $r^{I}_{All,i}(t_{\mathrm{obs}})$ は以下の二つの要素で評価する．一つ目は RGB 画像における関節位置推定の検出信頼度 $r_{All,i}(t_{\mathrm{obs}})$ で，二つ目は深度センシングの精度 $r_i^{Depth}(t_{\mathrm{obs}})$ である．OpenPose では，Fig. 4.1b に示すような 25 個の関節位置の推定結果とそれぞれの関節位置の推定信頼度が取得可能である．全身に対する検出信頼度 $r_{All,i}(t_{\mathrm{obs}})$ は，Fig. 4.1c に示した重みに基づく各関節の検出信頼度の重み付け平均で得られる．ヒューマンロボットインタラクションには上半身の情報が重要であるため，上半身の関節の重みを高く設定した．さらに，深度カメラの観測精度は距離の二乗に比例して低下する [92]．そのため，深度カメラの観測精度は，深度カメラの特性と推定した人までの距離に基づいて評価する．

$$r^{I}_{All,i}(t_{\mathrm{obs}}) = r_{All,i}(t_{\mathrm{obs}})\; r_i^{Depth}(t_{\mathrm{obs}}) = \frac{\sum_{k=1}^{25} r_{k,i}(t_{\mathrm{obs}})\; w_k^{J}}{\sum_{k=1}^{25} w_k^{J}} \frac{1}{(1 + C^{Depth}\, d_i^2)} \qquad (4.1)$$
$$\left(C^{Depth} = 2.85 \times 10^{-1}\right).$$

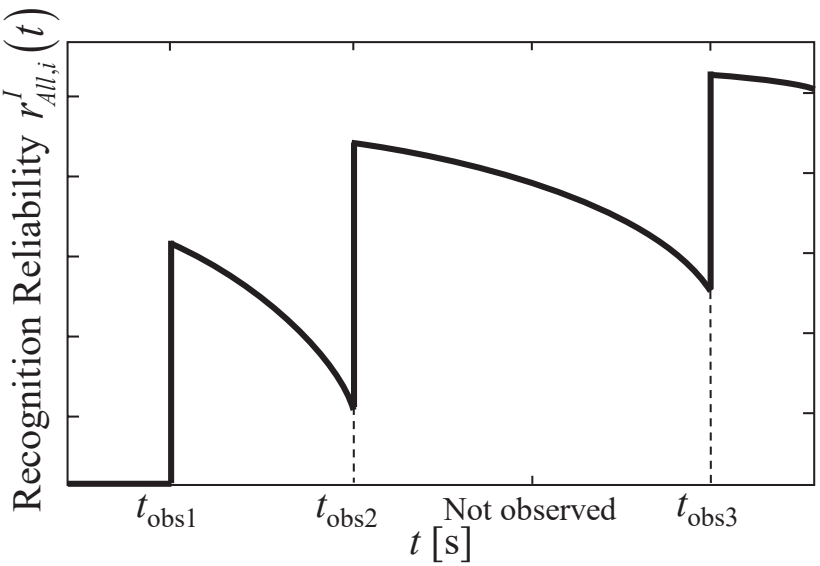


Figure 4.2: Example of updating the recognition reliability

ここで，$t_{\mathrm{obs}}$ は人を観測した時間であり，$d_i$ は $i$ 番目の人との距離，$r_{k,i}(t_{\mathrm{obs}})$ はそれぞれの関節の検出信頼度，$w_k^J$ は $k$ 番目の関節の重み，$C^{Depth}$ はデプスカメラの特性の係数である．

### 4.3.3 認識信頼度の更新則

全時刻において連続的に人を観測し続けることは困難であるため，観測値は保持される．しかし，古い観測値は信頼度が低いため，観測値の認識信頼度は経過時間に応じて下げる必要がある．そのため，高い信頼度の観測値は長く保持し，低い信頼度の観測値は早く破棄するため，信頼度は以下の式の更新則に従って更新する．

$$\dot{r}^I_{All,i}(t) = -\frac{1}{r^I_{All,i}(t)}C^r \qquad \left(C^r = 4.00 \times 10^{-1}\right) \tag{4.2}$$

ここで，$C^r$ は更新則に関する係数である．また，新たな観測値を得た際，新たな認識信頼度が保持していた認識信頼度を上回る場合には，観測値と認識信頼度を更新する．

以上で述べた認識信頼度の更新則に基づき更新した認識信頼度の時系列の例を Fig. 4.2 に示す．動的かつ離散的に更新される人の認識結果に基づき，認識信頼度は評価される．そして，人の認識結果が更新されない間は認識信頼度を減衰させつつ観測値を保持する．この際，認識信頼度の更新則に基づいて，信頼度が高い観測値は長い期間保持され，低い場合は短い期間で破棄される．

## 4.4 センサの特性

### 4.4.1 概要

人の情報を正確に取得するうえで重要となる要素の一つにセンサ特性がある．センシングの信頼度は対象の人とセンサの相対位置関係に依存して変化する．そこで，対象の人とセンサの相対位置関係とセンシングの信頼度の関係性をセンサ特性として定義する．本章では，人の画像センシングと人の音声センシングの特性を，実験的検証を通じて定式化する．

### 4.4.2 姿勢推定のための人の画像センシング特性

姿勢推定における人の画像センシングの信頼性が人とカメラの相対位置関係によってどのように変化するかを検証するために，認識信頼度 $r^I_{All,i}(t)$ の評価実験を実施した．

実験では，Fig. 4.3a に示すように，椅子に座った人を中心に，円弧上の様々な位置から人を RGB-D カメラで撮影した．撮影点は，Fig. 4.3b に示すとおりであり，各撮影点につき 100 枚の画像を取得した．次に，取得したそれぞれの画像に対して，先述の人の認識手法を適用し，Eq. (4.1) に似たがって認識信頼度を評価した．各撮影点と認識信頼度の平均値をマッピングした結果を Fig. 4.3c に示す．実験結果によると，もっとも認識信頼度が高い人の画像センシングに適した位置は人の前方 1.1m 付近であり，その地点の認識信頼度の平均値は 0.46 であることが明らかになった．

実験結果に基づき，人とカメラの相対位置関係と認識信頼度の関係性を表す人の画像センシング特性 $r^I$ を定式化する．本研究で用いる人の姿勢推定手法の精度は，RGB-D カメラのデプスセンサの精度，RGB 画像における姿勢認識精度に依存するため，人の画像センシング特性のモデルは RGB-D カメラの深度センサの距離特性，人の姿勢推定精度に関する距離特性，角度特性の項から構成した．そして，実験により得られた各撮影点における認識信頼度の平均値に基づき，最小二乗法を用いて，人の画像センシング特性の各パラメータを決定した．その際，最大値が 1 となるように正規化した．実験により得られた認識信頼度の平均値のマップを近似した結果は以下のとおりである．

$$
\begin{aligned}
r^I(d,\phi) = \frac{1}{1+C^{Depth}d^2}\left(\frac{\log C_1^{RGB,D}d}{C_2^{RGB,D}d}+C_3^{RGB,D}\right)\left(C_1^{RGB,A}\phi+C_2^{RGB,A}\right) \\
\left(C_1^{RGB,D}=1.09\times10^{-3}, C_2^{RGB,D}=3.16\times10^{-2}, C_3^{RGB,D}=1.94, \right. \\
\left. C_1^{RGB,A}=3.60\times10^{-3}, C_2^{RGB,A}=1.00\right)
\end{aligned}
\tag{4.3}
$$

ここで，$d$ は RGB-D カメラから人までの距離，$\phi$ は人の正面に対する RGB-D カメラの位置の角度，$C^{RGB,D}_{1\sim3}$ は距離特性の係数，$C^{RGB,A}_{1\sim2}$ は角度特性の係数である．

### 4.4.3 人の音声センシング特性

人はロボットに向かって話すと仮定すると，音声認識率は人からロボットまでの距離に依存する．先行研究により，Fig. 4.4a に示すように音声認識率は SNR（Signal to Noise Ratio）に依存することが解明されている．そこで，音声認識率の距離依存に関する特性を調査するため，マイク (SONY, PlayStation®Eye) を用いて，SNR の距離依存性を調査した．スピーカとマイクの距離とマイクへの入力音量の依存関係を明らかにするため，定常音を発するスピーカとマイクの距離を変化させつつマイクへの入力音量を計測する実験を行った．距離は 0.2m から 5.0m まで 0.3m 刻みで変化させた．さらに，周辺騒音によるマイクへの入力音量を計測し，それに基づき SNR を算出した．周辺騒音の平均音量はおよそ 50.0dB であった．スピーカの定常音はマイクの感度測定に標準的な基準入力信号である 1kHz の正弦波を使用した [93]．スピーカの音量はマイクからスピーカまでの距離が 0.2m の時に 75.0dB となるように設定した．計測実験に基づく SNR の算出結果は Fig. 4.4c に示すとおりである．また，音声認識率と距離の依存関係は Fig. 4.4d に示すとおりである．そして，実験から得られた認識率と距離の関係性に基づき音声認識率は人からマイクまでの距離の二乗に比例して低下するとして定式化し，実験結果に基づき最小二乗法を用いて各パラメータを推定した． 以下の式が人の音声センシング特性 $r^S$ の定式化結果である．

$$
r^S(d) = \frac{1}{1+C^Sd^2} \qquad \left(C^S=5.80\right) \tag{4.4}
$$

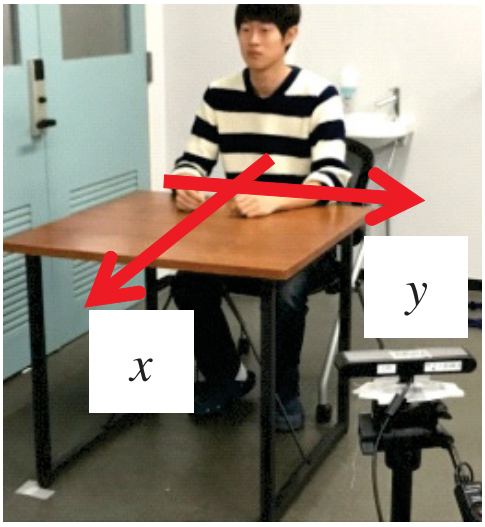


(a) Environment

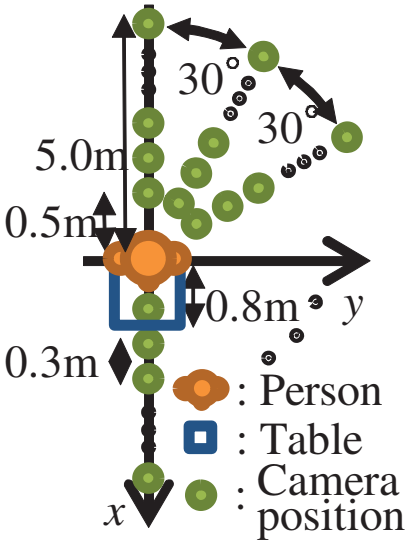


(b) Camera position

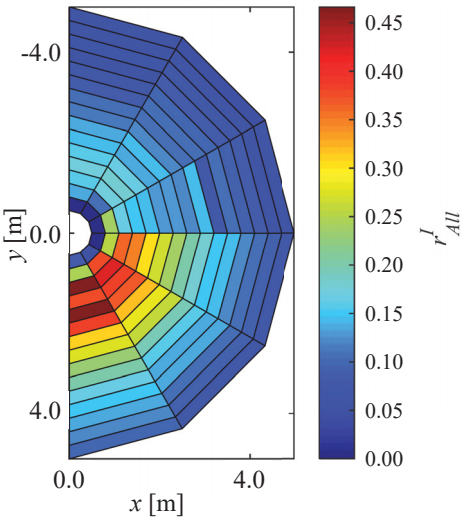


(c) Map of $r^I_{All}$

Figure 4.3: Measurement of recognition reliability

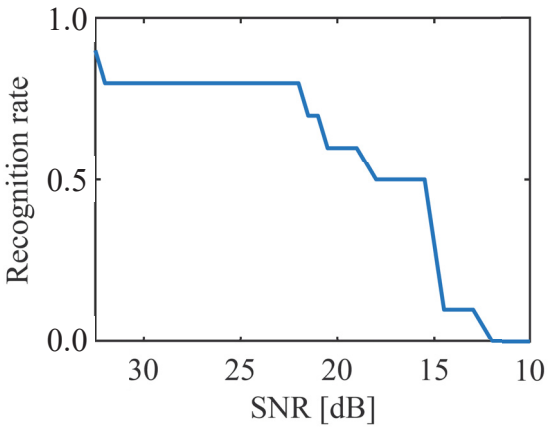


(a) Recognition rate and SNR

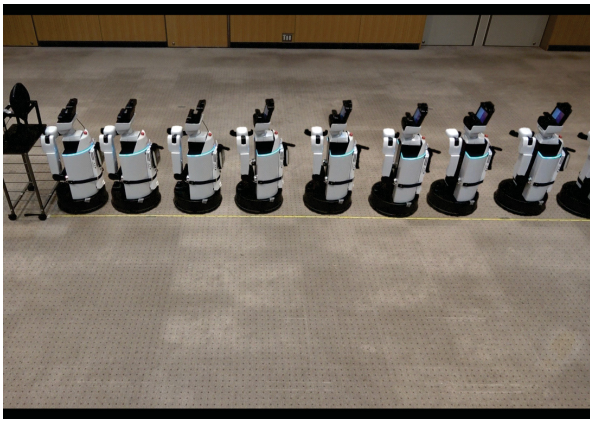

(b) Measurement environment

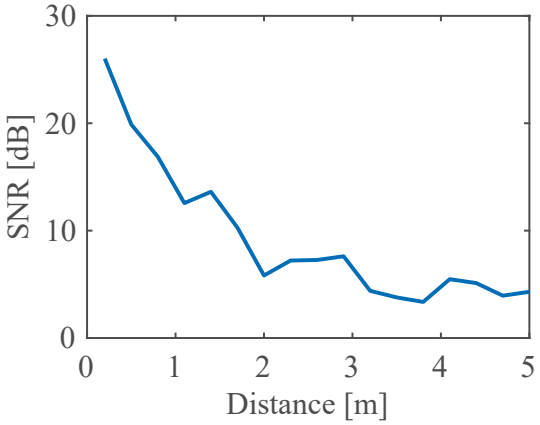


(c) Measured SNR

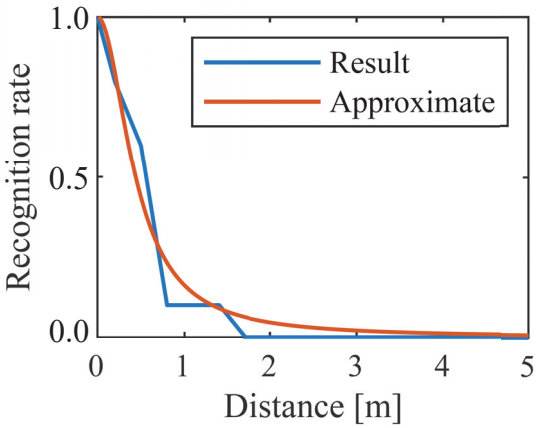


(d) Recognition rate and distance

Figure 4.4: Measurement of microphone input

## 4.5 マルチモーダルポテンシャル場を用いた接近行動のアクションモデリング

### 4.5.1 概要

本節では，マルチモーダルポテンシャル場を用いた接近行動のアクションモデリングの詳細を示す．人への接近行動，すなわち，ロボットがHRIタスクに必要な人の情報を取得できる位置への移動を実現するためには，タスクの内容，人の配置，複数のセンサの特性に基づき目的地や経路を決定する必要がある．また，ロボットは事前に人の配置の情報を持っていないうえ，動的に変化する可能性があるため，リアルタイムの人の認識結果と認識信頼度を組み合わせて，ロボットの動作を適応させる必要がある．そこで，異なる次元の情報を統合するために，2次元平面におけるポテンシャル場を用いる．まず，接近行動のアクションモデリングのため，人の画像センシングのため接近行動として人の画像ポテンシャル，人の音声センシングのため接近行動として人の音声ポテンシャルを定式化する．この定式化は，4.4節の実験結果に基づいて実施する．各ポテンシャル場は，ロボットが各センサから信頼度の高い観測値を取得できる位置を人物との相対的な位置関係で算出する．次に，各センサの重要度はHRIタスクや人の認識状況に依存して変化するため，タスクの内容や認識の信頼度に基づいてポテンシャル場を重み付けして統合することで，接近行動のアクションモデルを統合する．統合されたポテンシャル場をマルチモーダルポテンシャル場と呼ぶ．

### 4.5.2 ポテンシャルの設計

#### 人の画像ポテンシャルの設計

人の画像ポテンシャルは，4.4.2項で述べた人の画像センシング特性に基づいて定式化されている．人の画像センシング特性は距離特性と角度特性から構成される．角度特性に基づき，ロボットは人の前方に移動する必要がある．しかし，認識信頼度が低い場合には，人が観測した情報の信頼性が低く，特に人の角度は不明確な情報となる．そのため，認識信頼度が低い場合は，角度特性を重視しないようなポテンシャル設計が必要である．また，複数の人とインタラクションする場合，それぞれの人の認識信頼度を向上させる必要があるため，認識信頼性が低い場合には各人の認識を向上させるようなポテンシャル場の設計が必要である．これらの要求を満たすため，認識信頼度 $r^I_{All,i}(t)$ に依存した人の画像ポテンシャルを設計する．そこで，人物画像センシング特性 $r^I$ と認識信頼度 $r^I_{All,i}(t)$ に基づき，$i$ 番目の人の画像ポテンシャル $\boldsymbol{P}^I_i(t)$ は，観測した人の位置 $\boldsymbol{p}^h_i(t)$ や向き $\theta_i(t)$ に基づき得られる人とセンサの距離 $d_i$ と成す角度 $\phi_i$ に依存した以下の式で定式化される．また，定式化されたポテンシャル場の描画結果はFig. 4.5に示すとおりである．

$$P^I_i(t, d_i, \phi_i) = -\left(1 - r^I_{All,i}(t)\right) r^I(d_i, \phi_i) \tag{4.5}$$

#### 人の音声ポテンシャルの設計

人の音声ポテンシャルは，4.4.3項で述べた人の音声センシング特性に基づいて定式化されている．人がロボットに向かって話すと仮定すると，ロボットからの距離の二乗に比例して音声認識率が低下する．人の音声センシング特性に-1を乗じたものに基づき，$i$ 番目の人の音声ポテンシャル $\boldsymbol{P}^S_i(d_i)$ は，観測した人の位置 $\boldsymbol{p}_i(t)$ に基づき得られる人とセンサの距離 $d_i$ に依存した以下の式で定式化される．また，定式化されたポテンシャ

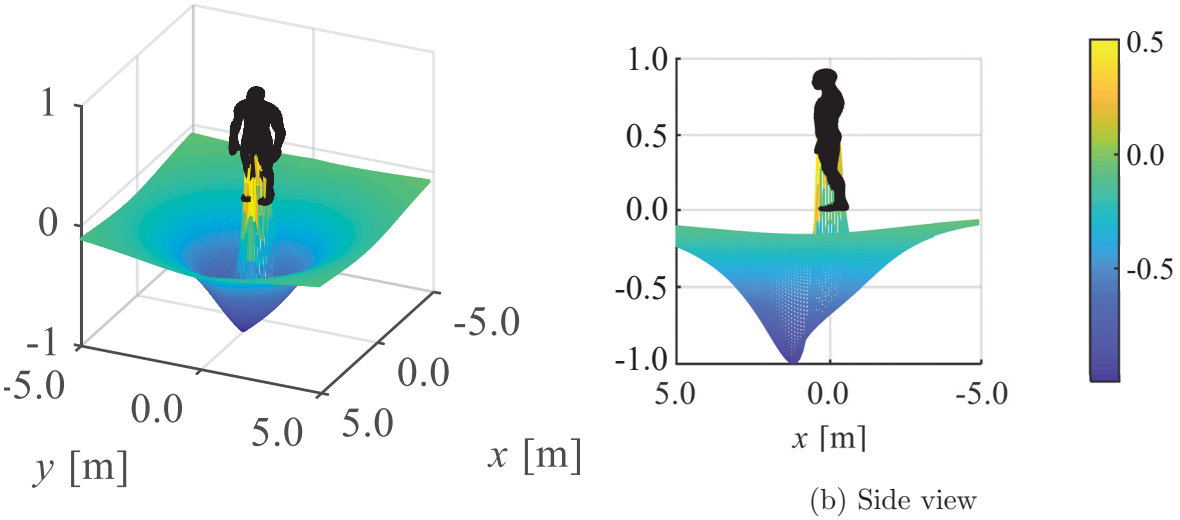


(a) Perspective view

(b) Side view

Figure 4.5: Human image potential

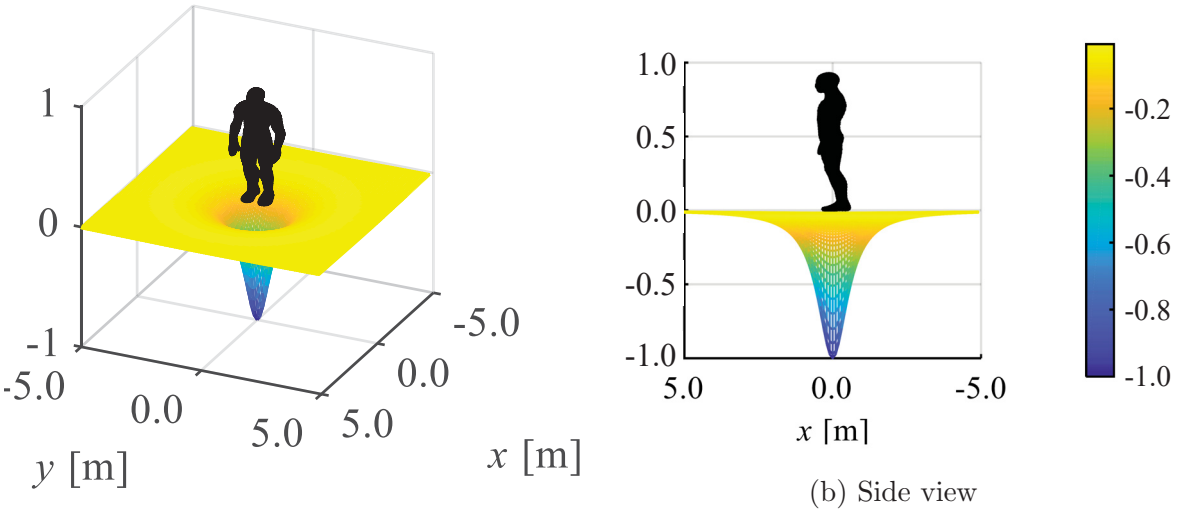


(a) Perspective view

(b) Side view

Figure 4.6: Human voice potential

ル場の描画結果は Fig. 4.6 に示すとおりである．

$$P_i^S\left(d_i\right) = -r^S\left(d_i\right) \tag{4.6}$$

### 障害物形状ポテンシャルの設計

家具や人間などの典型的な障害物の形状に関する情報は事前にロボットに与える情報とする．また，家具などの静的障害物の位置も同様に事前に与える．一方，人のような既知の動的障害物の位置に関しては，画像センシングにより認識する情報とする．

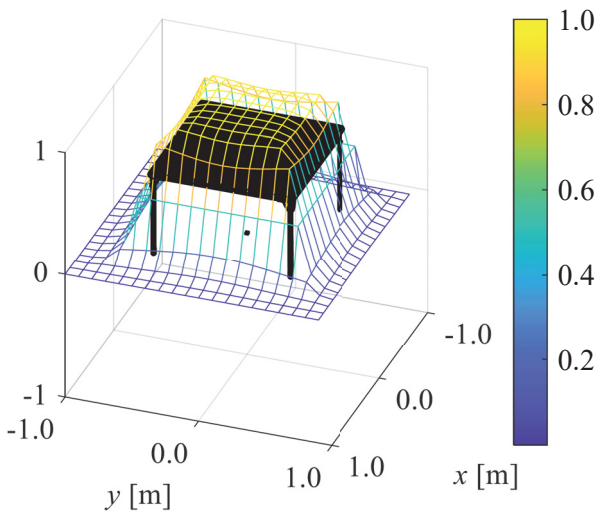


Figure 4.7: Obstacle shape potential

把握している既知障害物との衝突を回避するため，$i$ 番目の障害物の障害物形状ポテンシャル $P_i^O(t)$ を定式化する．障害物の領域にロボットが入らないようにするため，障害物領域のポテンシャルが増加するように，障害物の形状ポテンシャル $P_i^O(t)$ を設計した．また，ポテンシャル場の連続性を保つため，障害物形状ポテンシャル $P_i^O(t)$，シグモイド関数と既知の障害物の形状に基づき決定されることとした．机を障害物とした場合，その対応する障害物形状ポテンシャル $P_i^O(t)$ は Fig. 4.7 に示すとおりである．未知の動的障害物については，経路追従におけるローカルパスプランナで考慮する．

### 4.5.3 マルチモーダルポテンシャル場

#### ポテンシャル場の重みづけと重ね合わせ

本項では，認識信頼度 $r_{All,i}^I(t)$ とタスク内容に基づくアクションモデルの統合手法について述べる．アクションモデルの統合として，人の画像ポテンシャル $P_i^I(t)$ と人の音声ポテンシャル $P_i^S(t)$ を人間の認識信頼性とタスク内容に基づいて重み付けし，障害物形状ポテンシャル $P^O(t)$ と統合したものを $i$ 番目の人のマルチモーダルポテンシャル $P_i(t)$ とする．ポテンシャル場の重み付けの設計コンセプトは Fig. 4.8 に示すとおりである．実運用を考えると，インタラクションタスクに有用な人の情報を得るためには，ロボットが人に接近する前に，まず対象の人の配置を認識する必要がある．そのため，認識信頼度 $r_{All,i}^I(t)$ が低い間は，人を認識することを考慮しつつ計画された経路に沿って人に接近する必要がある．そして，認識信頼度 $r_{All,i}^I(t)$ が向上した後には，インタラクション行動に重要となるセンサ情報を観測することを考慮した移動へ移行する必要がある．そこで，新たに定義する認識ポテンシャル $P_i^R(t)$ とインタラクション行動ポテンシャル $P_i^H(t)$ の重みづけと統合に基づき，$i$ 人目のマルチモーダルポテンシャル場 $P_i(t)$ を次式のように定義する．

$$P_i(t) = \left(1 - r_{All,i}^I(t)\right) \boldsymbol{P}_i^R(t) + r_{All,i}^I(t)\, \boldsymbol{P}_i^H(t) + \sum_{j=1}^{m} \boldsymbol{P}_j^O(t) \tag{4.7}$$

人の認識は RGB-D カメラを用いて行われるため，認識ポテンシャル $P_i^R(t)$ は人の画像ポテンシャル $P_i^I(t)$ と同様である．

$$P_i^R(t) = P_i^I(t) \tag{4.8}$$

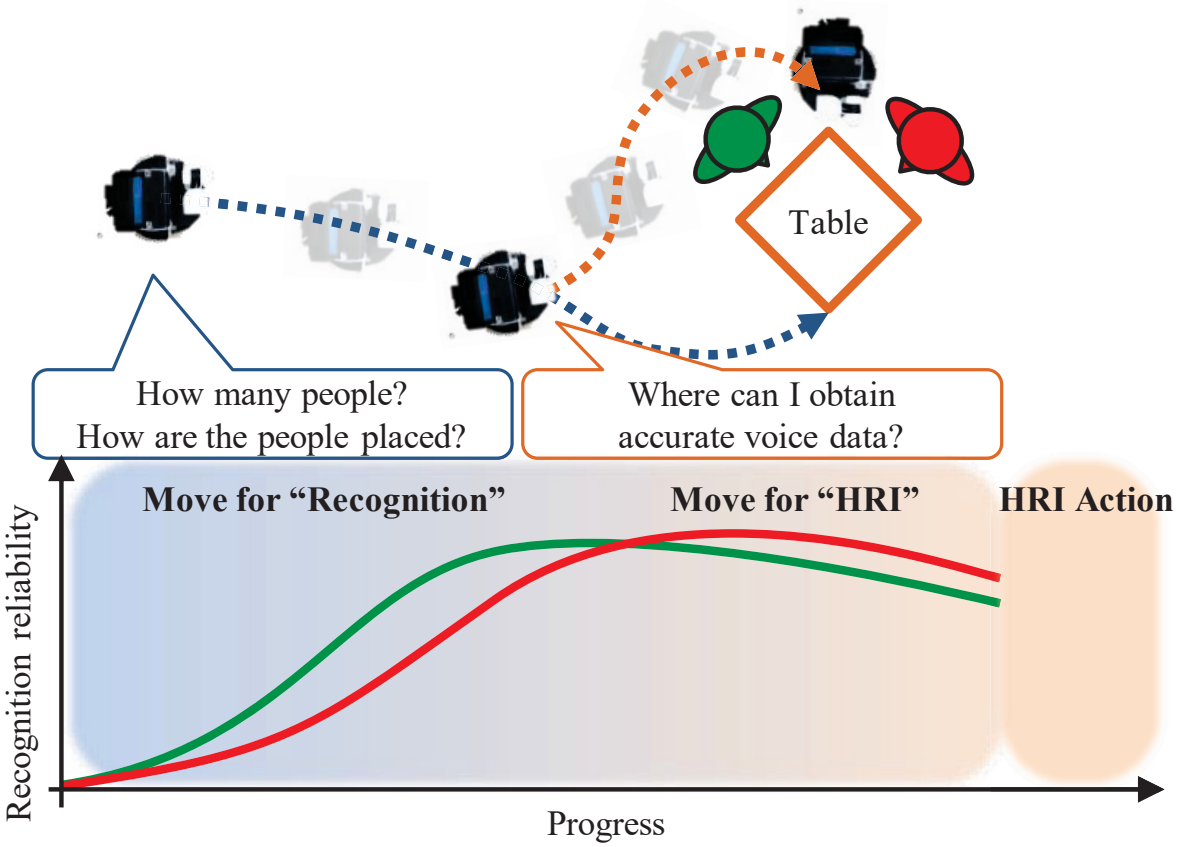


Figure 4.8: Design concept of potential fields weighting

インタラクション行動ポテンシャル $P_i^H(t)$ はタスク内容に依存する．ロボットが人とインタラクションする際の重要な感覚モーダルとして画像や音声の観測情報は大きな割合を占める．さらに，インタラクションタスクには，様々な種類が存在し，それぞれのタスクの内容によって各センサの重要度が変化する．例えば，タスクに対して画像情報の重要度が高い場合は，人間の画像ポテンシャル $P_i^I(t)$ を重視する必要がある．一方，人間の声のポテンシャルである $P_i^S(t)$ は，音声情報の方が重要である場合に重視する必要がある．タスクの内容に応じてロボットの移動を変化させるために，人の画像センシングのための移動行動と人間の音声センシングのための移動行動のアクションモデルを，それぞれの情報の重要度に基づいて統合する必要がある．そこで，音声重要度 $w^S$ を定義する．そして，各タスク内容における音声情報の重要度を音声重要度 $w^S$ の値によって表現する．タスクにおいて音声情報が重要である場合，音声重要度 $w^S$ は高い値に設定され，最大値は 1，最小値は 0 である．音声重要度 $w^S$ を用いたポテンシャル場の重み付けと統合により，インタラクション行動ポテンシャル $\boldsymbol{P}_i^H(t)$ を以下の式のように定義する，

$$\boldsymbol{P}_i^H(t) = \left(1 - w^S\right) \boldsymbol{P}_i^I(t) + w^S \boldsymbol{P}_i^S(t) \tag{4.9}$$

Eqs. (4.7) to (4.9) を整理すると，マルチモーダルポテンシャル場 $P_i(t)$ は以下の式で定義できる．

$$P_i(t) = \left(1 - r_{All,i}^I(t)\, w^S\right) P_i^I(t) + r_{All,i}^I(t)\, w^S P_i^S(t) + \sum_{j=1}^{m} P_j^O(t) \tag{4.10}$$

**複数人を対象としたシナリオへの対応**

複数人を対象としたインタラクションを扱うため，それぞれの人のマルチモーダルポテンシャル場を統合して複数人のためのマルチモーダルポテンシャル場を生成する．この統合により，それぞれ人の配置とポテンシャル場から，ロボットが移動するべき場所のポテンシャルは一般的に低くなる．また，ロボットは対象となる人を全員認識する必要があるため，認識信頼度の平均値に基づいて各マルチモーダルポテンシャル場が統合される．以上より，複数人のマルチモーダルポテンシャル場を以下の式で定義する．

$$P(t) = \sum_{i=1}^{n} \left[ \left(1 - r^{I}_{All,ave}(t)\, w^{S}\right) P^{I}_{i}(t) + r^{I}_{All,ave}(t)\, w^{V} P^{S}_{i}(t) \right] + \sum_{j=1}^{m} \boldsymbol{P}^{O}_{j}(t) \qquad (4.11)$$

ここで，$n$ は対象の人の人数，$r^{I}_{All,ave}(t)$ は対象の人の認識信頼度の平均値である，

## 4.6 接近行動のアクションモデルに基づくマルチモーダル経路計画

### 4.6.1 システム概要

提案システムのフローチャートを Fig. 4.9 に示す．ロボットは，HRI を含むタスクを取得し，動作を開始する．その際，ロボットには対象のテーブルの位置やタスクの内容が与えられる．

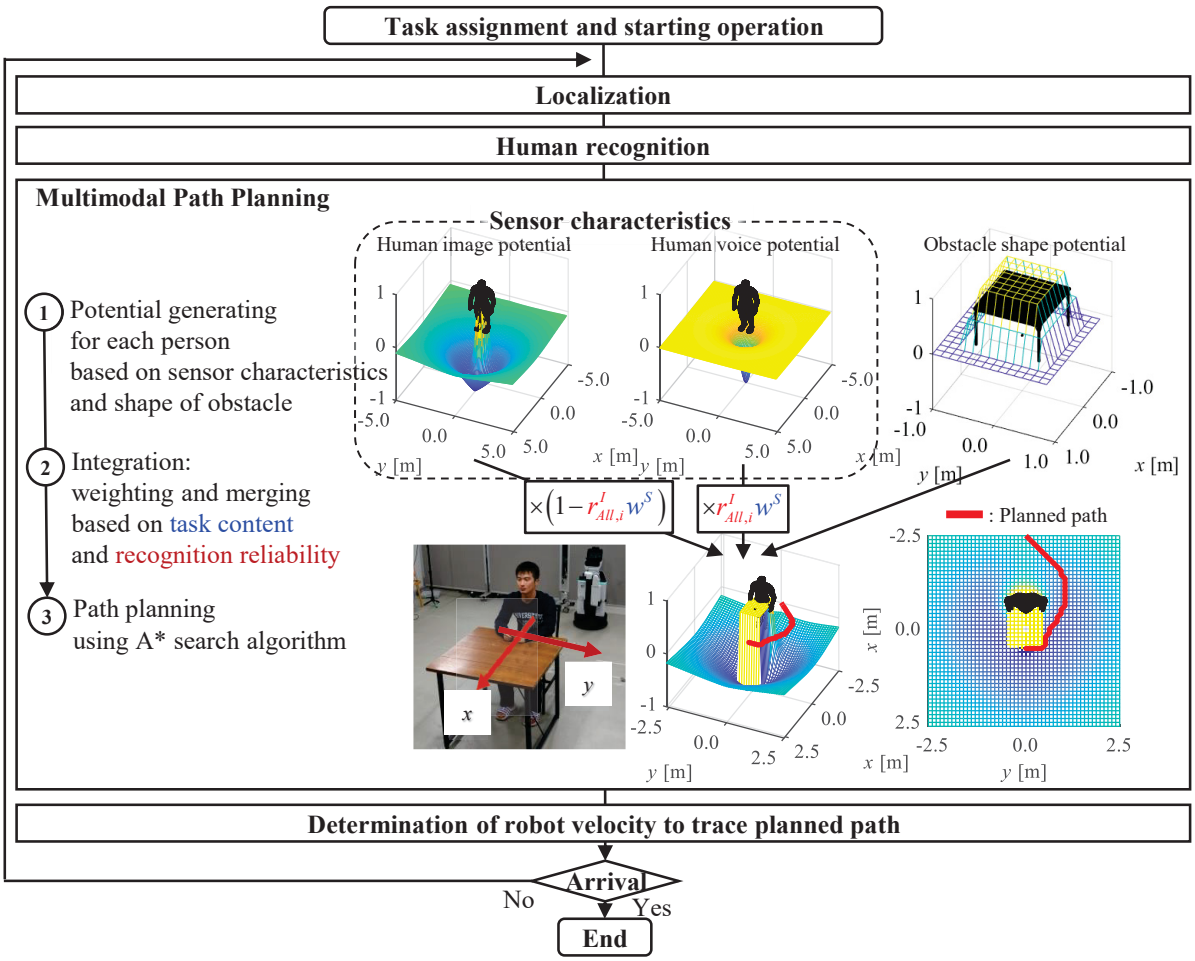


Figure 4.9: Flowchart of navigation based on multimodal path planning

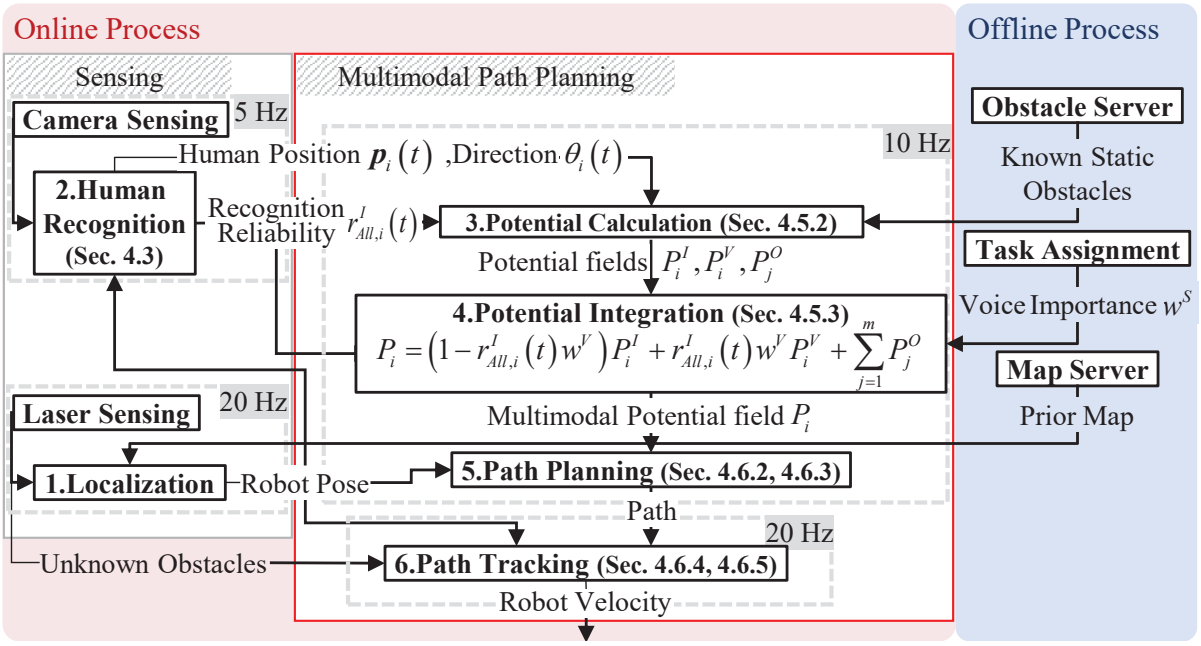


Figure 4.10: Pipeline of parameter update

ループ処理内では，まず，自己位置推定と人の認識を行う．人の認識では，ロボットに搭載された RGB-D カメラを用いて，対象となる人物の位置や向きを推定するとともに，認識信頼度を評価する．次に，4.5.3 項に基づき算出したマルチモーダルポテンシャル場に基づき，目的地とロボットの初期位置から目的地への経路を算出するマルチモーダル経路計画を行う．人が認識できない場合は，目的地を机の位置とする．最後に，未知障害物を回避しつつ経路に追従するための経路追従手法に基づきロボットの速度を決定する．目的地に到達するまでこの処理を繰り返し，リアルタイムにポテンシャル場と経路を更新することで，人の位置など目的地における状況の変化に対応する．

具体的なパラメータ更新のパイプラインを Fig. 4.10 に示す．この図では，次の項以降で述べる各処理において，どのパラメータに基づきどのパラメータが更新されるのかの入出力関係を明らかにする．ロボットの動作前に与えられるパラメータは，事前地図や家具などの静的な障害物の情報．ロボットが行うインタラクションタスクにおける音声情報の重要度を表す音声重要度である．動的なセンシングにより更新されるパラメータは，人の位置や向き，認識信頼度などの認識結果やロボットの自己位置推定結果，未知障害物に関する情報である．これらの情報に基づきマルチモーダルポテンシャル場や経路，ロボットの速度が更新される．

以降では，マルチモーダルポテンシャル場に基づき，ロボットの目的地や経路，速度を決定する手法について述べる．

### 4.6.2 目的地の決定

ロボットが移動すべき位置のポテンシャルが低くなるようにポテンシャル場を設計した．そのため，ロボットの目的地は，2 次元平面の中で最もポテンシャルが低い位置である．最も低い位置が複数ある場合は，よりロボットの位置に近い位置を目的地として選択する．

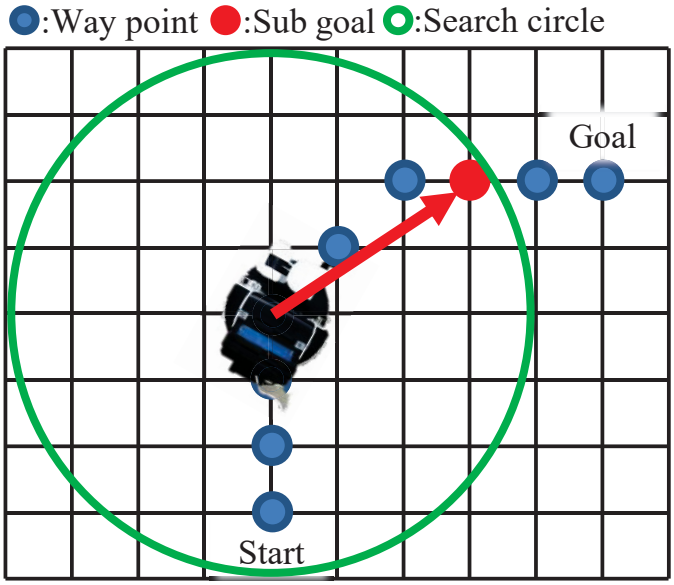


Figure 4.11: Sub goal on the planned path

### 4.6.3 経路計画手法

ロボットの初期位置から目的地までの経路は，計算されたポテンシャル場と目的地までの距離を考慮できる大域的な経路計画法の一つである A*探索アルゴリズムを用いて計画する．勾配に基づくアプローチなどの局所的な経路計画ではローカルミニマムに陥ることが問題となるが，大域的な経路計画を採用することでローカルミニマムに陥ることを回避することが可能である．A*探索アルゴリズムでポテンシャル場を処理するため，ノード $n$ からノード $m$ の移動コスト $cost\,(n,m)$ には，次式のようにポテンシャル場の勾配が設定される．

$$cost(n,m) = C^P\left(P\left(t,m\right) - P\left(t,n\right)\right) \tag{4.12}$$

ここで，$P\left(t,n\right)$ は，ポテンシャル場 $P\left(t\right)$ におけるノード $n$ の位置のポテンシャル値であり，$C^P$ は A*探索アルゴリズムに関する設計パラメータである．

### 4.6.4 経路追従手法

得られた経路を安全に追従するために，経路追従法にはファジィポテンシャル法 [60,61] を採用する．ファジィポテンシャル法では，経路追従と周囲障害物の回避を統合的に考慮しながら速度を決定することが可能である．また，経路追従では，Fig. 4.11 に示すように，ロボットを中心とした円に含まれる点のうち，目的地に最も近い点がサブゴールとして設定される．円の半径は試行錯誤により，0.9m に設定した．周囲の障害物の位置によっては，経路追従の過程でローカルミニマムに陥る可能性がある．ローカルミニマムに陥った場合，サブゴールの位置に障害物形状ポテンシャル $\boldsymbol{P}^O\left(t\right)$ をポテンシャル場に追加し，経路を再計画することでローカルミニマムを脱することが可能である．

### 4.6.5 姿勢制御手法

RGB-D カメラを用いて対象の人を撮影する際，カメラを対象の人の方向へ向ける必要がある．対象の人が複数人の場合，ロボットの注視点 $p^g\left(t\right)$ は，認識信頼度が低い人を撮影できる点である必要がある．そこで，重みを認識信頼度の逆数とした複数人の位

置の重心を注視点 $p^g(t)$ として設定する．

$$\boldsymbol{p^g(t)} = \frac{\sum_{i=1}^{n} \frac{1}{r^I_{All,i}(t)} \boldsymbol{p^h}_i(\boldsymbol{t})}{\sum_{i=1}^{n} \frac{1}{r^I_{All,i}(t)}} \tag{4.13}$$

ここで，$\boldsymbol{p^h}_i(t)$ は $i$ 番目の人の位置とする．また，ロボットに搭載された RGB-D カメラは，上記の式で決定された注視点へ向かうように比例制御に基づき制御する．

## 4.7 接近行動のアクションモデルに基づくアクショングラフの構築

### 4.7.1 概要

4.6 節では，次の HRI 行動を促進するため，マルチモーダルポテンシャル場に基づき HRI 行動に必要な人の情報を取得できる位置へ移動する人への接近行動の経路計画法について述べた．本節では，複数回の移動行動やマニピュレーション行動，HRI 行動で構成されるタスクの行動列を決定するうえで，接近行動のアクションモデルを活用する手法について述べる．

実空間においてロボットの機能やおかれた環境を有効活用してタスクを遂行するためには，計画された行動列が実空間においてより短い経路で構成され，個々の行動は次の行動を促進するものである必要がある．このような行動列を計画するための手法として世界状態依存アクショングラフがあげられる．世界状態依存アクショングラフでは，再帰的多層構造を用いてロボットが実行可能な行動の時空間的な関係性を表現する．この世界状態依存アクショングラフを構築するうえで，個々の行動の目標状態の情報であるアクションモデルを用いることで行動を実空間に落とし込む．そして，行動の時空間的な関係性に基づきタスクを達成するための行動列の内容と行動の実行場所を決定する．そのため，マルチモーダル経路計画では，マルチモーダルポテンシャル場が最小値となる場所が接近行動の目的地として決定される一方で，行動列中における接近行動の目的地，すなわち HRI 行動の実行場所は，マルチモーダルポテンシャル場だけでなく，他の行動との位置関係も考慮したうえで決定される必要がある．

そこで，本研究では，人への接近行動のアクションモデルに基づき，アクショングラフを構築するため，ポテンシャル場から HRI 行動の実行場所の候補を決定する．具体的には，アクショングラフの行動に関する事前知識へのアクションモデルの導入方法と，アクションモデルに基づく目標状態の分布から候補点を抽出するアプローチの例について述べる．また，本研究では HRI 行動の例として，手渡し行動を扱う．行動を実空間に落とし込むためのアクションモデルを，コストマップや分布で表現する手法は複数存在し，提案手法は他の行動へも適用可能である [94–96].

### 4.7.2 行動知識の表現

本節で扱う HRI 行動の手渡し行動に関する事前知識を Table 4.1 と Fig. 4.12 に示す．行動の事前知識は Fig. 4.12 に示すような JSON フォーマットのファイルでシステムに入力される．Fig. 4.12a はアクションモデルを用いず，人を中心，半径を 1.0m とした円周上 4 点を行動の実行場所とした場合の知識である．行動の実行場所の円周の半径と個数を与えるという方法では，簡便に行動の実行場所の情報を与えることが可能であるが，詳細なサブシステムの特性を表現するには表現力が乏しい課題がある．一方，Fig. 4.12b では，マルチモーダルポテンシャル場の式をアクションモデルとして与えている．実空間における行動の実行場所に関する情報として数式を与えることで，表現力を担保すること，周辺物体の配置などの実空間の情報と統合することが可能である．事前知識で与

Table 4.1: Prior knowledge of handover action

| $l^a$: label | $G^s_{a,p}$: precondition | $G^s_{a,e}$: effect |
|---|---|---|
| *handover* | 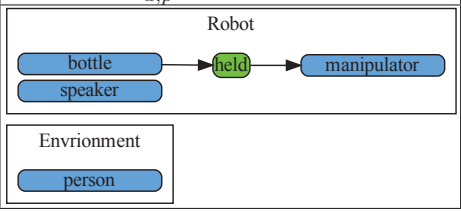 | 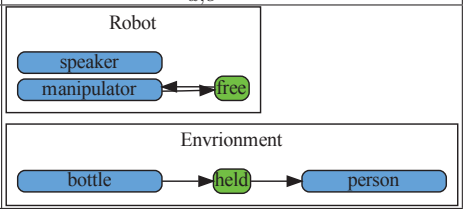 |

```
{
  "label": "handover",
  "cost":0.3,
  "related_objects":[
    "bottle", "speaker", "
       manipulator", "person"
  ],
  "precondition":[
    ["Robot", 0, "held", 0],
    [0, "Robot", 0, 0],
    [0, 0, "Robot", 0],
    [0, 0, 0, 1]
  ],
  "effect":[
    [1, 0, 0, "held"],
    [0, "Robot", 0, 0],
    [0, 0, "free", 0],
    [0, 0, 0, 1]
  ],
  "appropriate_distance":1.0,
  "number_of_action_position":4
}
```

(a) Action knowledge without action model

```
{
  "label": "handover",
  "cost":0.3,
  "related_objects":
  [
    "bottle", "speaker", "
       manipulator", "person"
  ],
  "precondition":
  [
    ["Robot", 0, "held", 0],
    [0, "Robot", 0, 0],
    [0, 0, "Robot", 0],
    [0, 0, 0, 1]
  ],
  "effect":
  [
    [1, 0, 0, "held"],
    [0, "Robot", 0, 0],
    [0, 0, "free", 0],
    [0, 0, 0, 1]
  ],
  "action_model":
  "(log(0.00109*d)/0.0316*d+1.94)/(
     1+0.485*d**2)*(-0.0036*((abs(
     theta))/3.141592*180)+1)"
}
```

(b) Action knowledge with action model

Figure 4.12: Detailed action knowledge of handover action for implementation

えられる式の情報は，Python にて記号計算を行うライブラリである SymPy [97] を用いることを想定している．

### 4.7.3 接近行動のアクションモデルに基づくアクショングラフの構築

接近行動のアクションモデルに基づきアクショングラフを構築する．

3.3 節にて世界状態依存アクショングラフの構築方法をもとに新たに与えられたアクションモデルを扱えるように拡張する必要がある．具体的には，3.3.5 項にて述べた行動可能性グラフの構築処理のうち，環境中の物体に対応付けられた行動が実行可能な位置を追加する **GetFeasiblePositionsForActions** の処理においてアクションモデルを扱う必要がある．

*4.* マルチモーダルポテンシャル場に基づく接近行動のアクションモデリング

アクショングラフ構築のため，アクションモデルと実空間の情報に基づいて，行動が実行可能な位置を決定する手法への要求は以下のとおりである．

- アクションモデルと周辺物体の配置に基づき，行動が実行可能な場所を集約する複数の代表点を選択できること

  アクショングラフは，エッジを行動の実行，ノードを行動の実行場所として，行動の時空間的な関係性のグラフ表現であるため，多岐にわたる行動を表現できることと各行動の空間的な関係性をより正確に表現できる必要がある．そのため，各行動を必要最低限のノードとエッジで表現できることが望ましく，アクションモデルと周辺物体に基づき得られる分布を表現する必要最低限の代表点を決定する必要がある．

- 計算コストを抑えたうえで行動が実行可能な場所を決定できること

  アクショングラフでは，多岐にわたる行動を表現できることが要求される一方で，サービスロボットにはシステムの応答性が要求されるためアクショングラフの構築時間より短いほうが望ましい．行動が実行可能な場所を決定する処理は，考慮する行動毎に必要となる処理であるため，より低計算コストであることが望ましい．

上記の要求を満たす，行動が実行可能な位置を決定方法を以下に示す．まず，ロボットが到達可能な範囲の中で行動を実行しやすい場所を把握するため，アクションモデルにより得られる各位置の評価のうち，フットプリントを考慮しロボットが到達困難な障害物領域の評価を下げるように，アクションモデルにより得られるポテンシャルと障害物ポテンシャルを統合する．次に，得られた統合マップに基づき，行動の実行場所を表現する必要最低限の代表点を決定する．マップから代表点を取得する方法として，マップをヒストグラムと捉え EM アルゴリズムを用いて混合正規分布モデルでフィッテイング [98] し正規分布の平均点を代表とする方法，評価値に基づき重みづけをした $k$ 平均法を用いる方法，輝度勾配に基づき重みづけしたボロノイ図に基づきグレースケール画像を点描で表現する手法 [99] などが考えられるが，計算コストの観点から適用は困難である．そこで，本研究では，統合ポテンシャル場の極小点のうち評価が閾値を下回っている点を行動の実行場所とする．ここで極小点の決定方法は，最小値フィルタを施した統合ポテンシャル場とフィルタを施す前の統合ポテンシャル場の評価を比較し，同じ評価の点を極小値とする方法を採用した．また閾値は，行動の実行に要求される観測精度に基づき決定される．複数の環境を例に，手渡し行動の実行場所を決定した結果を Fig. 4.14 に示す．行動の実行場所が周辺の障害物の配置とアクションモデルに応じて決定可能であることが確認できる．

Fig. 4.13a に示す環境状態を例に，アクションモデルに基づき行動可能性グラフを構築する過程（Fig. 4.13）を示す．まず，Fig. 4.13b に示すように環境中の物体を表現する点を母点としたボロノイ図に基づきロボットが到達可能な点を取得する．次に，各物体に対応づけられた行動の実行位置を決定し，ノードとして追加する．アクションモデルとしてポテンシャル場が与えられている場合，Figs. 4.13c, 4.13d に示すように環境中の物体に基づく障害物ポテンシャルと統合した統合ポテンシャルの極小点に基づき行動の実行場所を決定する．また，ポテンシャル場が与えられていない行動に関しては，物体を中心とした円周上の点を行動の実行場所として決定する．そして，得られた行動の実行場所を Fig. 4.13e に示す．最後に，ドロネーの三角分割に基づき，得られた行動の実行場所を接続するエッジを決定する．ドロネーの三角分割に基づき，得られたエッジの候補の内，環境中の物体を考慮した上でロボットが移動可能なエッジのみを採用する．また，エッジと接続されないノードは棄却する．最終的に得られる行動可能性グラフは Fig. 4.13f に示す通りである．

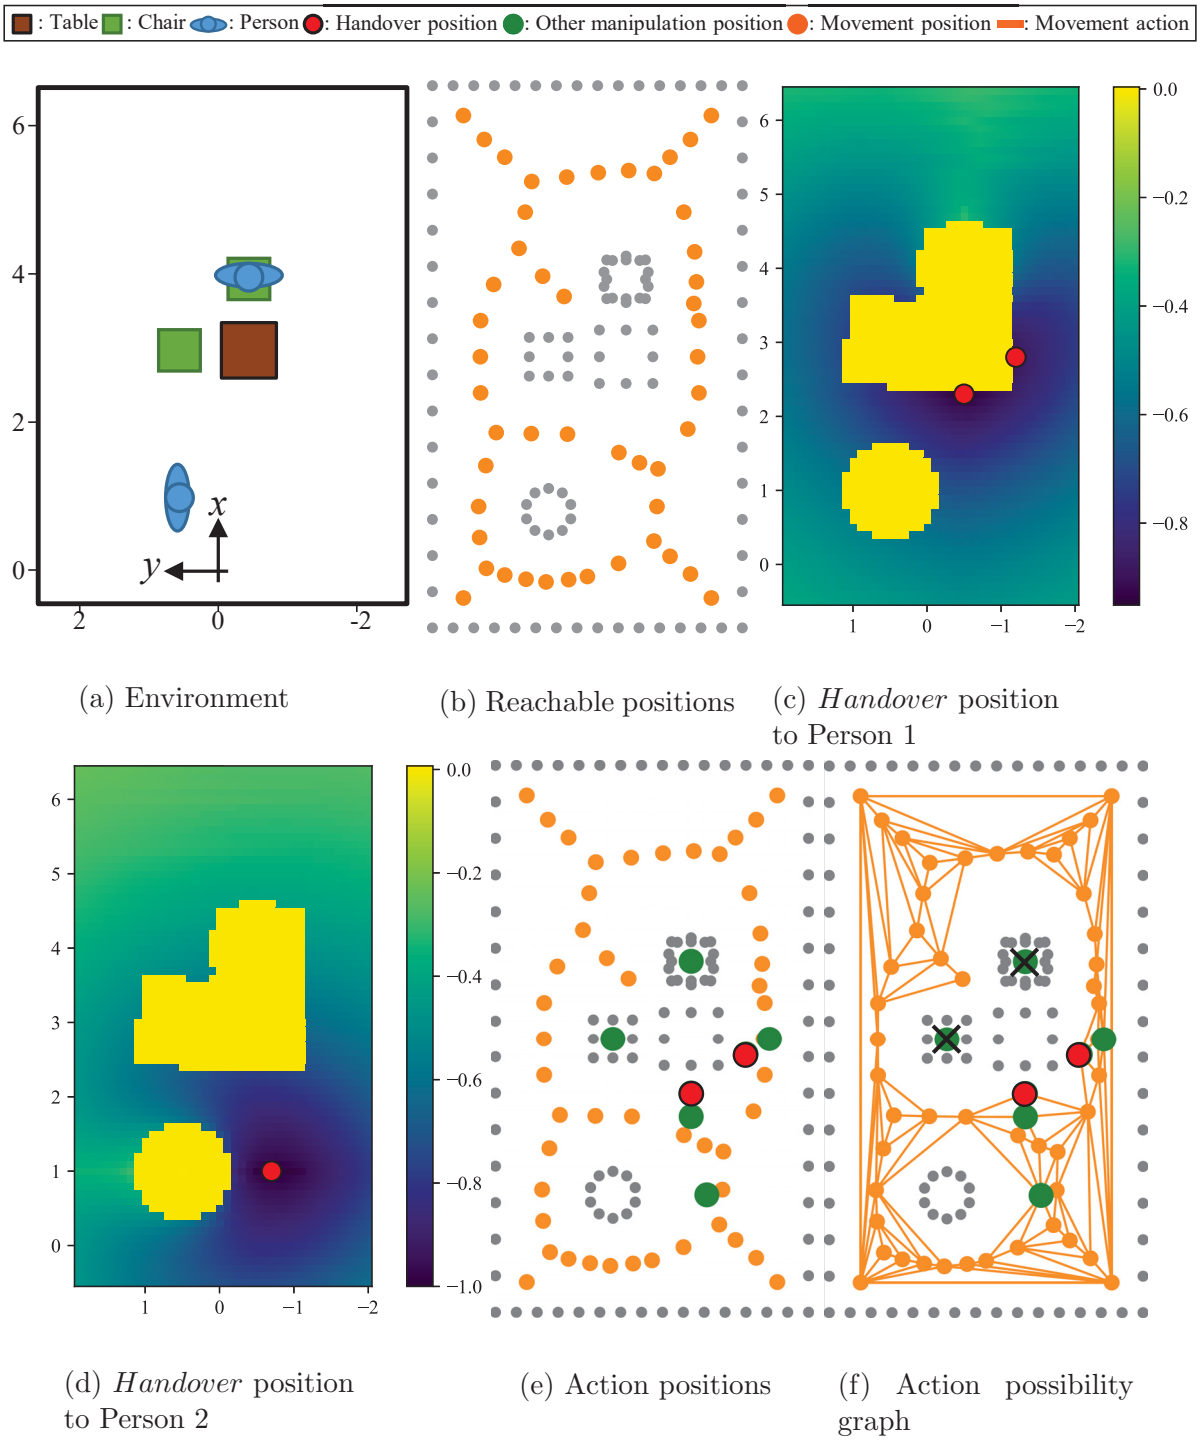


(a) Environment

(b) Reachable positions

(c) *Handover* position to Person 1

(d) *Handover* position to Person 2

(e) Action positions

(f) Action possibility graph

Figure 4.13: Construction of action possibility graph based on multimodal potential field

## 4.8 実験

### 4.8.1 実験 1: マルチモーダル経路計画の検証

#### 実験設定

マルチモーダル経路計画は，タスクの内容やセンサの特性に基づき，人とのインタラクション動作に重要なセンサデータを正確に取得できる目的地へナビゲーションを行うことを目的としている．提案手法の有効性を検証するために，ロボットと喫茶店環境

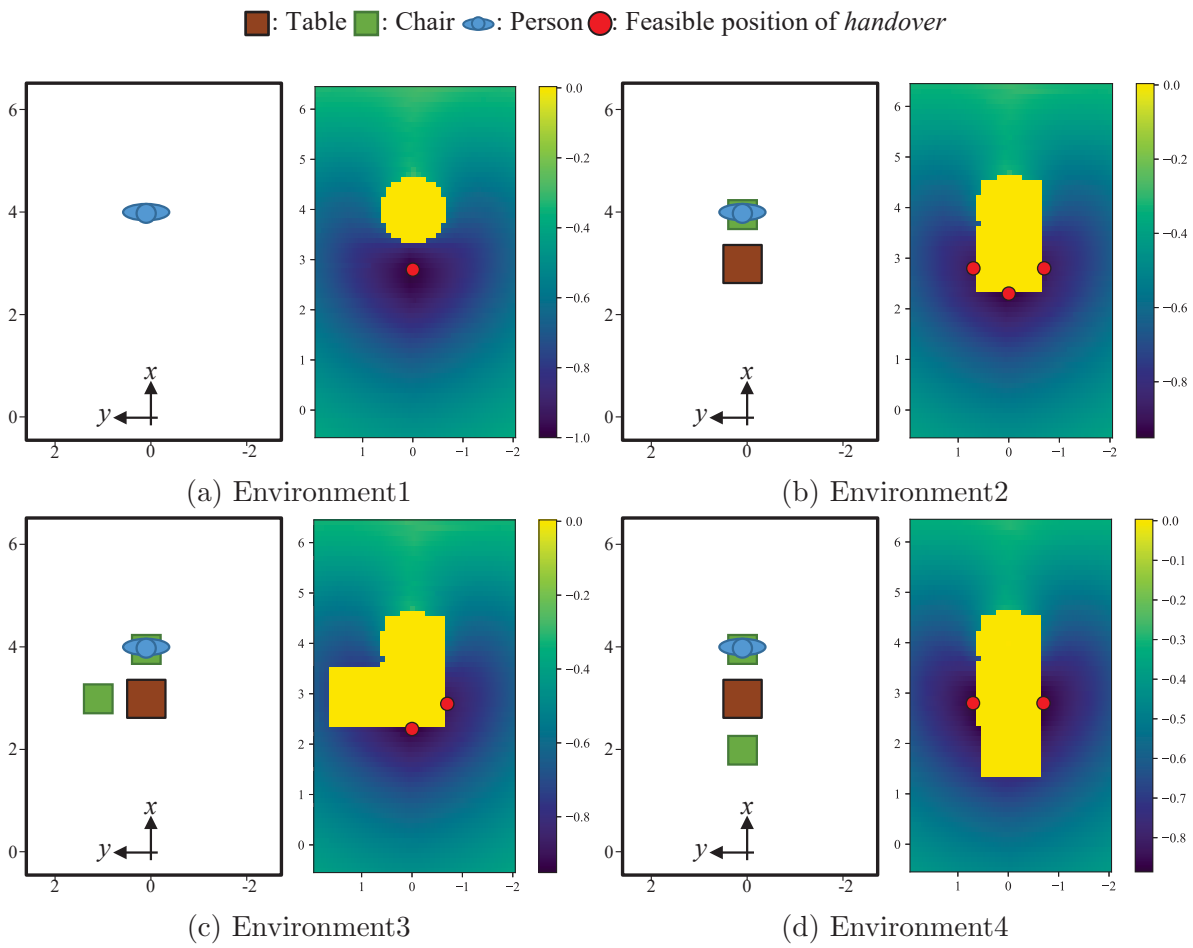


Figure 4.14: Determination of action position based on multimodal potential field (Left: Assumed environment, Right: Calculated potential field and action positions)

での実験を行った．実験環境は Fig. 4.15 に示すとおりである．実験では，ロボットは Fig. 4.16 で示した人とのインタラクションタスクとそれに伴うアクションが割り当てられたうえで，テーブルに着席している人へ接近した．本実験における HRI のシナリオとして，音声の重要度が高い対話行動と音声の重要度が低い手渡し行動を対象とした．実験シナリオは Table 4.2 に示すとおりである．

まず，タスクの内容による目的地や経路の変化を検証するために，Fig. 4.15a のように環境 1 の人に対して注文取りタスクと飲み物提供タスクを行う場合を想定し，シナリオ 1.1，1.2 の実験を行う．次に，複数の配置で着席している複数人を対象とした場合における，提案手法の有効性を検証するため，Figs. 4.15b, 4.15c のように 2 人と 3 人を対象としたシナリオ 2.1，2.2，3.1，3.2 の実験を行った．最後に，ロボットが接近中に人の位置が変化する場合の有効性を検証するために，シナリオ 4.1 と 4.2 について実験を行った．シナリオ 4.1 では，ロボットが接近中に 1 人離席する環境 4 において，ロボットが注文取りタスクを行うことを想定している（Fig. 4.15d）．シナリオ 4.2 では，ロボットが移動中に人が着席する環境 5 で，ロボットが飲み物提供タスクを行うことを想定している．

また，インタラクション行動の内容に応じて，ロボットが有用なセンサデータを取得できる位置まで移動できたことを検証するため，移動先でのセンシング信頼度を評価した．注文取りタスクの場合，ロボットから人までの距離を算出し，その距離と 4.4.3 項で定式化した人の音声センシング特性から，期待される認識信頼度を評価した．また，飲み物配膳タスクでは，ロボットが人を 10 枚撮影し，認識信頼度を評価した．ロボットがその場で RGB-D カメラを回転させ，人が視野の中に入っている場合に撮影を行うこ

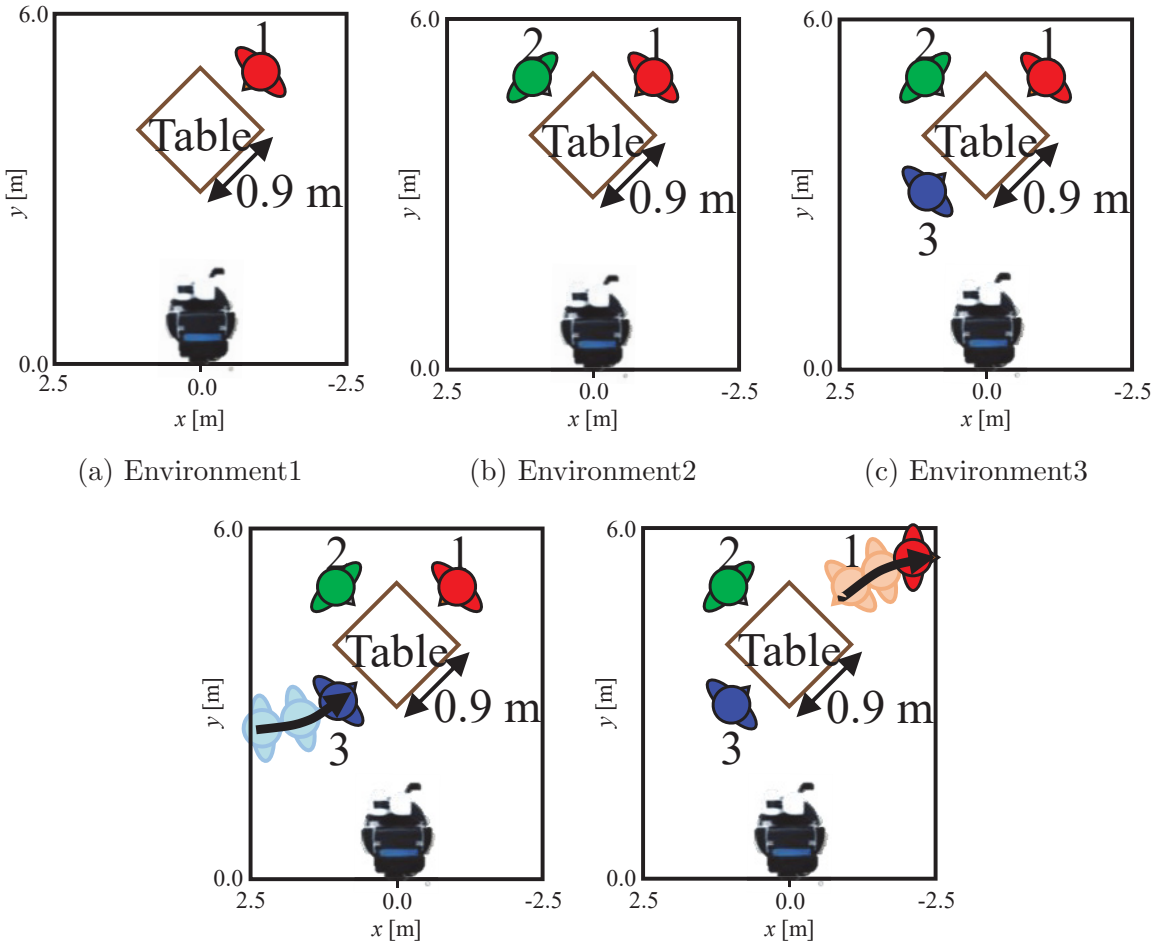


(a) Environment1 (b) Environment2 (c) Environment3

(d) Environment4 (e) Environment5

Figure 4.15: Experimental environment

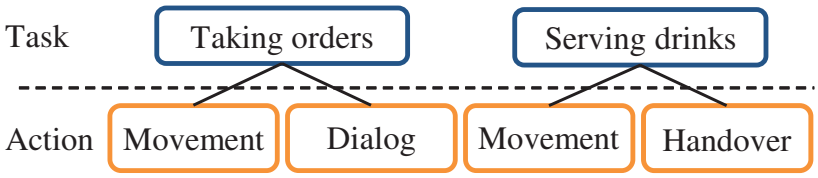


Figure 4.16: List of tasks and actions

とで視野の制約はないこととした．RGB-D カメラの回転角度は，60°，30°，0°，-30°，-60°とした．

ロボットシステムのパラメータは Table 4.3 に示すように設定した．また，人との衝突を避けるため，テーブルと同様に人も障害物に含めて考慮した．さらに，gmapping パッケージ [100] を使用して作成した環境地図と，適応型モンテカルロ位置推定アプローチ [101] を使用し，ロボットの自己位置を推定している．

### シナリオ 1: 一人の人への接近における検証

一人の人へ接近した結果を Figs. 4.17, 4.18 に示す．Fig. 4.17 は，シナリオ 1.1 においてロボットが人のより近い位置へ移動したことを示している．シナリオ 1.1 では，人の音

Table 4.2: Environmental scenarios of Experiment 1

| Scenarios | Environments | Number of people | Task | $w^S$ |
|---|---|---|---|---|
| 1.1 | 1 | 1 | Taking orders | 0.9 |
| 1.2 | 1 | 1 | Serving drinks | 0.1 |
| 2.1 | 2 | 2 | Taking orders | 0.9 |
| 2.2 | 2 | 2 | Serving drinks | 0.1 |
| 3.1 | 3 | 3 | Taking orders | 0.9 |
| 3.2 | 3 | 3 | Serving drinks | 0.1 |
| 4.1 | 4 | 2⇒3 | Taking orders | 0.9 |
| 4.2 | 5 | 3⇒2 | Serving drinks | 0.1 |

Table 4.3: Robot system parameters

| | |
|---|---|
| OpenPose frequency | 5 Hz |
| Path planning frequency | 10 Hz |

声情報が重要であるため，人の音声ポテンシャルを重視したマルチモーダルポテンシャル場が算出され，人の周囲のポテンシャルが低くなった．そのため，人により近い位置へ到達するように経路が計画され，ロボットはその場所へ移動した．一方，Fig. 4.18 は，シナリオ 1.2 においてロボットが人の正面側へ移動したことを示している．シナリオ 1.2 では，人の姿勢情報が重要であるため，人の画像ポテンシャルを重視したポテンシャル場が算出され，人の正面のポテンシャルが低くなった．

Figs. 4.17c, 4.18c は，認識信頼度の時系列変化を示している．実線は，経過時間に応じて認識信頼度を低下させる更新則を適用した認識信頼度を示しており，その数値を基にポテンシャル場を算出している．一方，点線は，観測された認識信頼度を示している．シナリオ 1.2 においては，Fig. 4.18c に示すように認識信頼性が継続的に改善されている．一方，シナリオ 1.1 では，Fig. 4.17c に示すように，最終的に人の音声ポテンシャルが重視され，ロボットが人に近づきすぎたため，認識信頼度は低下している．一人の人への接近する実験結果から，ロボットはタスクの内容に応じて計画する経路を変更しつつ，決定した目的地に移動できることが確認できた．

(a) Actual movement

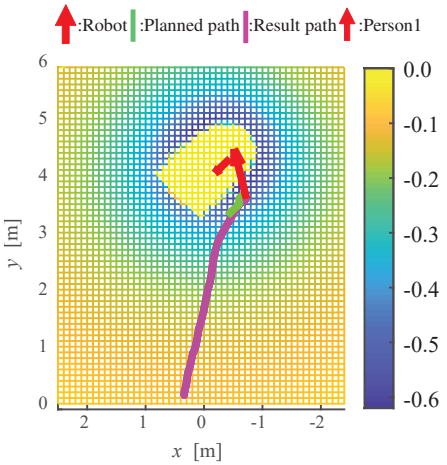


(b) Result path

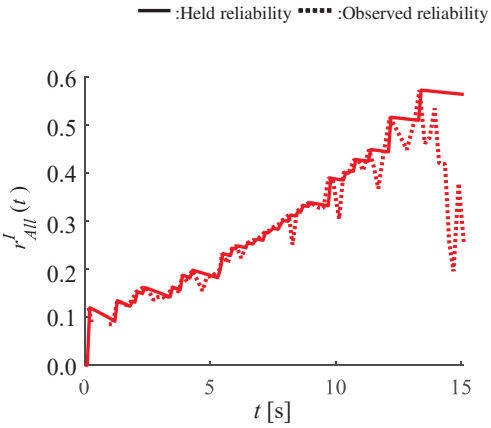


(c) Recognition reliability over time

Figure 4.17: Results from Scenario 1.1

(a) Actual movement

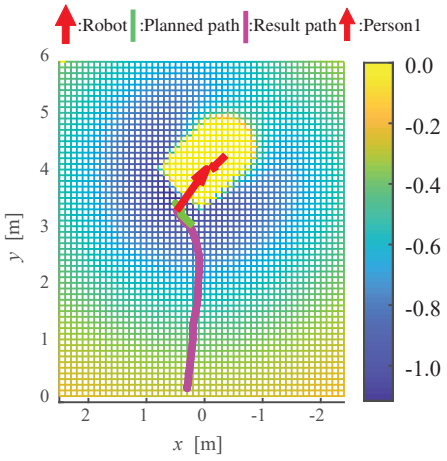


(b) Result path

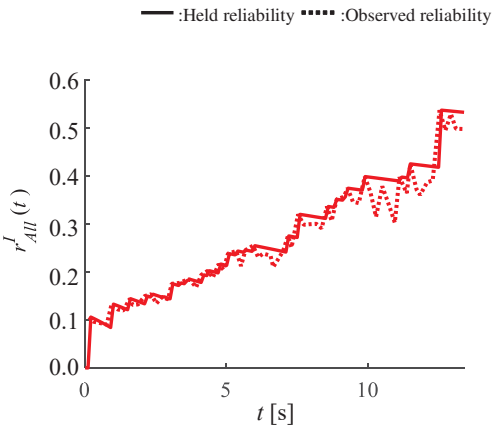


(c) Recognition reliability over time

Figure 4.18: Results from Scenario 1.2

### シナリオ 2: 複数の人への接近における検証

複数の人へ接近した場合における実験結果は，Figs. 4.19-4.22 に示す通りである．複数人を対象としたインタラクションの場合，それぞれの人について算出されたマルチモーダルポテンシャル場を統合して一つのマルチモーダルポテンシャル場を算出する，

シナリオ 2.1，3.1 の注文取りタスクの場合では，それぞれ人のポテンシャル場は，最終的に人の音声ポテンシャルが重視される．算出されたマルチモーダルポテンシャル場において，ポテンシャル値が低くなる場所は，全ての人から最も近い位置である．そのため，Figs. 4.19, 4.21 のように，全ての人から最も近い位置を目的地として経路が計画され，ロボットは計画された経路に沿って移動した．認識信頼度に関しては，Figs. 4.19c, 4.21c に示すように，1 度認識信頼度が向上したのちに人の音声ポテンシャルが重視され，ロボットが人へ接近しすぎたため，最終的には認識信頼度は低下した．

シナリオ 2.2，3.2 の飲み物配膳タスクの場合には，それぞれの人のマルチモーダルポテンシャル場では人の画像ポテンシャルが重視された．その結果，マルチモーダルポテンシャル場においてポテンシャル値が最も低い位置がすべての人の正面付近となったため，Figs. 4.20, 4.22 のように全員の前へ移動するように経路が計画された，また，マルチモーダルポテンシャル場では人の画像ポテンシャルが重視され続けたことで，Figs. 4.20c, 4.22c のように認識信頼度は継続的に向上した．さらに，RGB-D カメラにより 3 人を同時に観測すること困難であったが，観測値の保持することが有効に機能したことが確認できた．

環境 2，3 で得られた実験結果から，ロボットが複数人に接近する場合でも，タスクの内容や人の配置を考慮しながら経路を計画し，目的地まで移動することが確認できた．

また，Figs. 4.19d, 4.19e, 4.21d, 4.21e に示すように，対象の人の認識信頼度に応じて算出されたポテンシャル場と経路された計画が変化した．さらに，Figs. 4.19c, 4.21c を確認すると，平均認識信頼度が向上した際に，タスク内容に基づき人の音声ポテンシャルを重視するにポテンシャル場が変化したことがわかる．これにより，ロボットが人の配置を正しく観測したのちに，ロボットがタスク内容を考慮しつつ目的地を決定できることが確認できた．

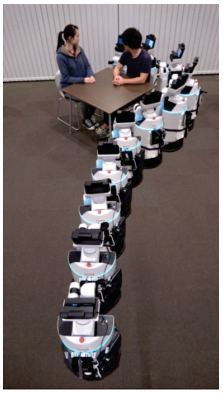

(a) Actual movement

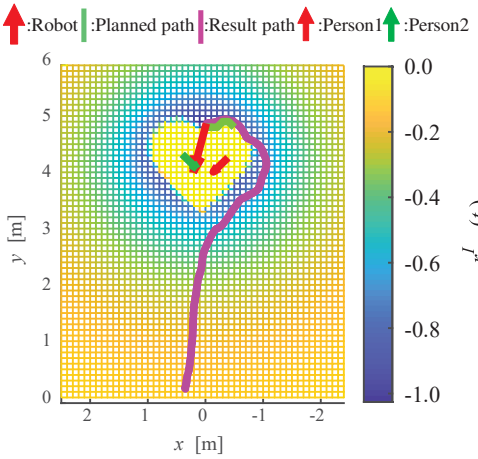


(b) Result path

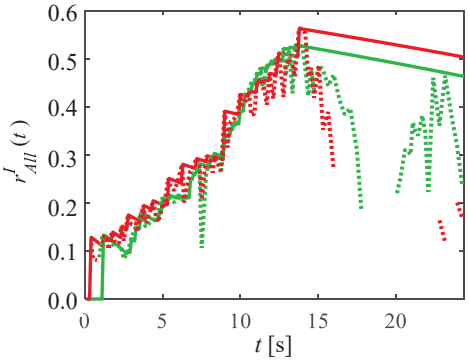


(c) Recognition reliability over time

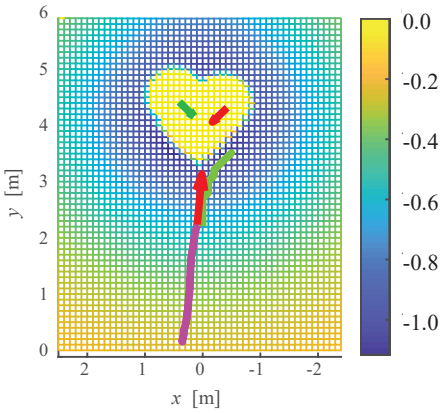


(d) Potential field at 9.0 s

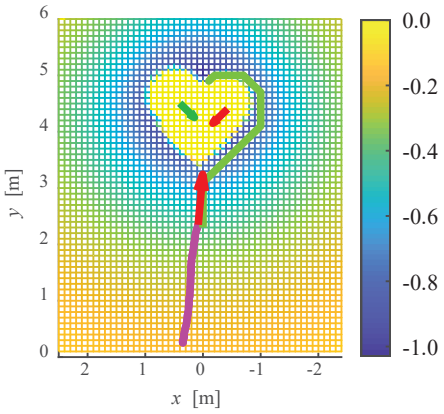


(e) Potential field at 9.1 s

Figure 4.19: Results from Scenario 2.1

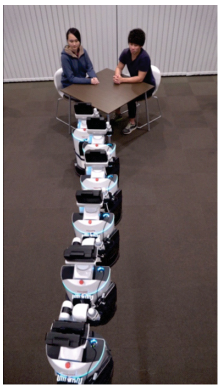

(a) Actual movement

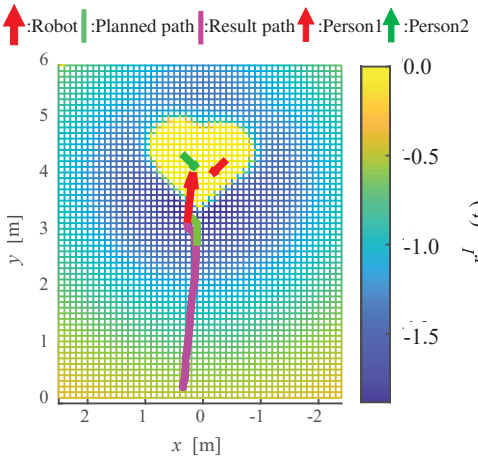


(b) Result path

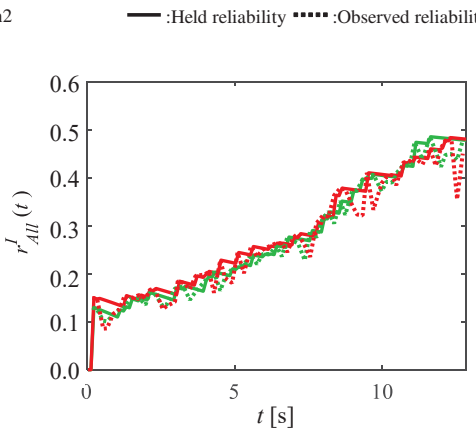


(c) Recognition reliability over time

Figure 4.20: Results from Scenario 2.2

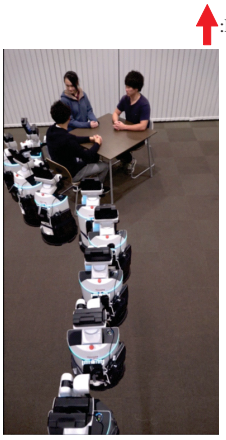

(a) Actual movement

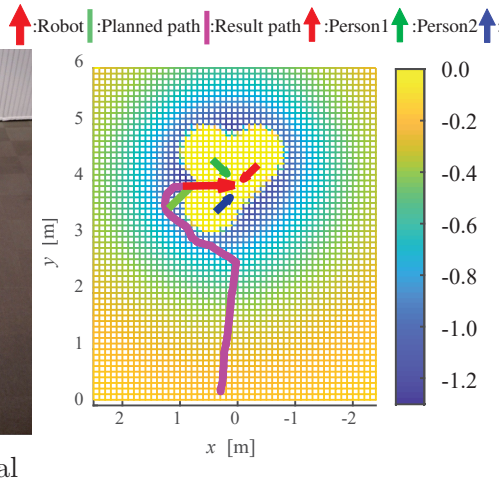


(b) Result path

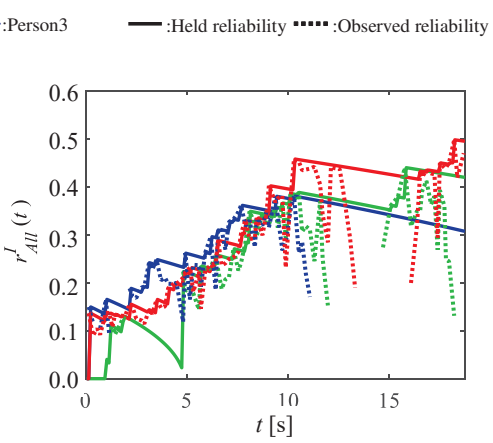


(c) Recognition reliability over time

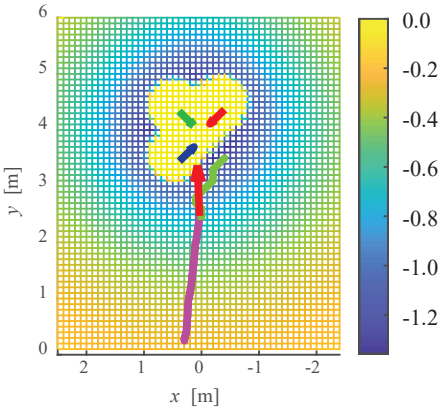


(d) Potential field at 9.5 s

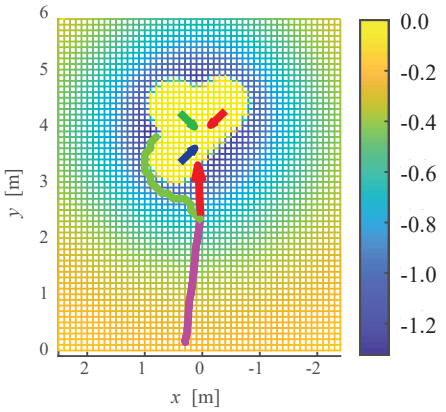


(e) Potential field at 9.6 s

Figure 4.21: Results from Scenario 3.1

(a) Actual movement

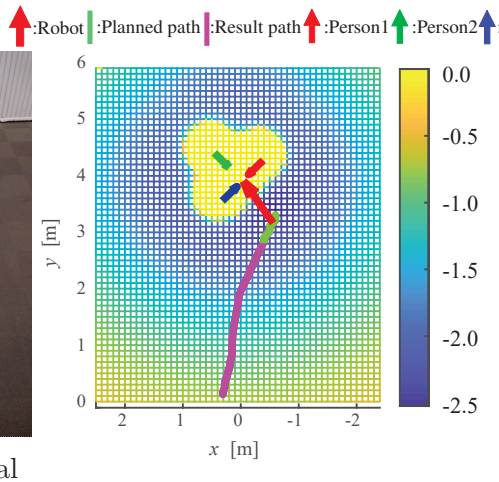


(b) Result path

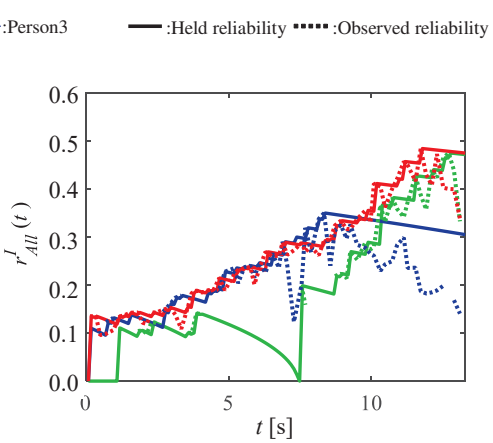


(c) Recognition reliability over time

Figure 4.22: Results from Scenario 3.2

### シナリオ 3: 人の配置が変化する中での接近における検証

人の配置が変化する場合の実験結果を Figs. 4.23, 4.24 に示す．シナリオ 4.1 のタスク内容は，注文取りタスクであるため，最終的にロボットはシナリオ 3.1 と同じ位置まで移動した．シナリオ 4.1 では，ロボットの移動中に，新たな人が座席に到着した．その際のマルチモーダルポテンシャル場の変化を Figs. 4.23d, 4.23e に示す．人が 2 人座っている間は，2 人に一番近いところに経路が計画されている．さらに，新しい人が席に着いた後，ポテンシャル場には新しい人が反映され，3 人を含めたポテンシャル場に基づき経路が計画された，Fig. 4.23c に示すように，オクルージョンなどで対象者の連続観測が困難となる場合において，観測値の保持が有効に作用することが確認できた，

シナリオ 4.2 のタスク内容は，飲み物提供タスクであるため，シナリオ 2.2 と同様に，最終的にロボットは 2 人の正面の位置に移動した．シナリオ 4.2 でロボットが移動している間に，1 人の人が離席した．その時のマルチモーダルポテンシャル場の変化を Figs. 4.24d, 4.24e に示す．人が離席した後，長時間観測されなかったため考慮されず，残りの 2 人を考慮したポテンシャル場が生成された．Fig. 4.24c に示すように，認識信頼度を適切に減衰させることで，保持された古い観測値が適切に棄却されることが確認できた．

以上の実験結果により，人の配置の変化に応じて，計画される経路が適切に変更されることが確認できた．そして，ロボットはセンサデータを取得し，提案手法に基づき動的に経路を計画するため，動作中の人の配置の変化にも対応可能であることが確認できた．

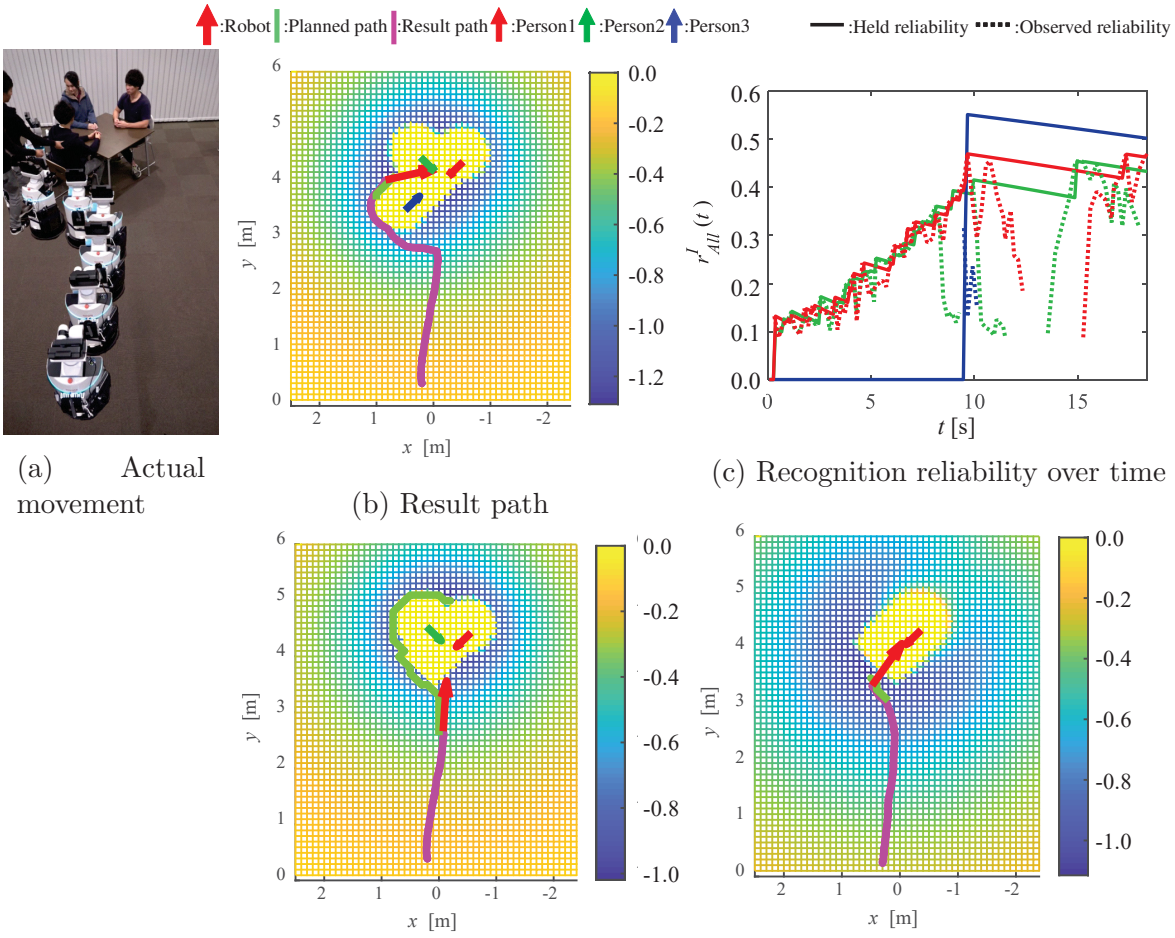


(a) Actual movement

(b) Result path

(c) Recognition reliability over time

(d) Potential field at 9.6 s

(e) Potential field at 9.7 s

Figure 4.23: Results from Scenario 4.1

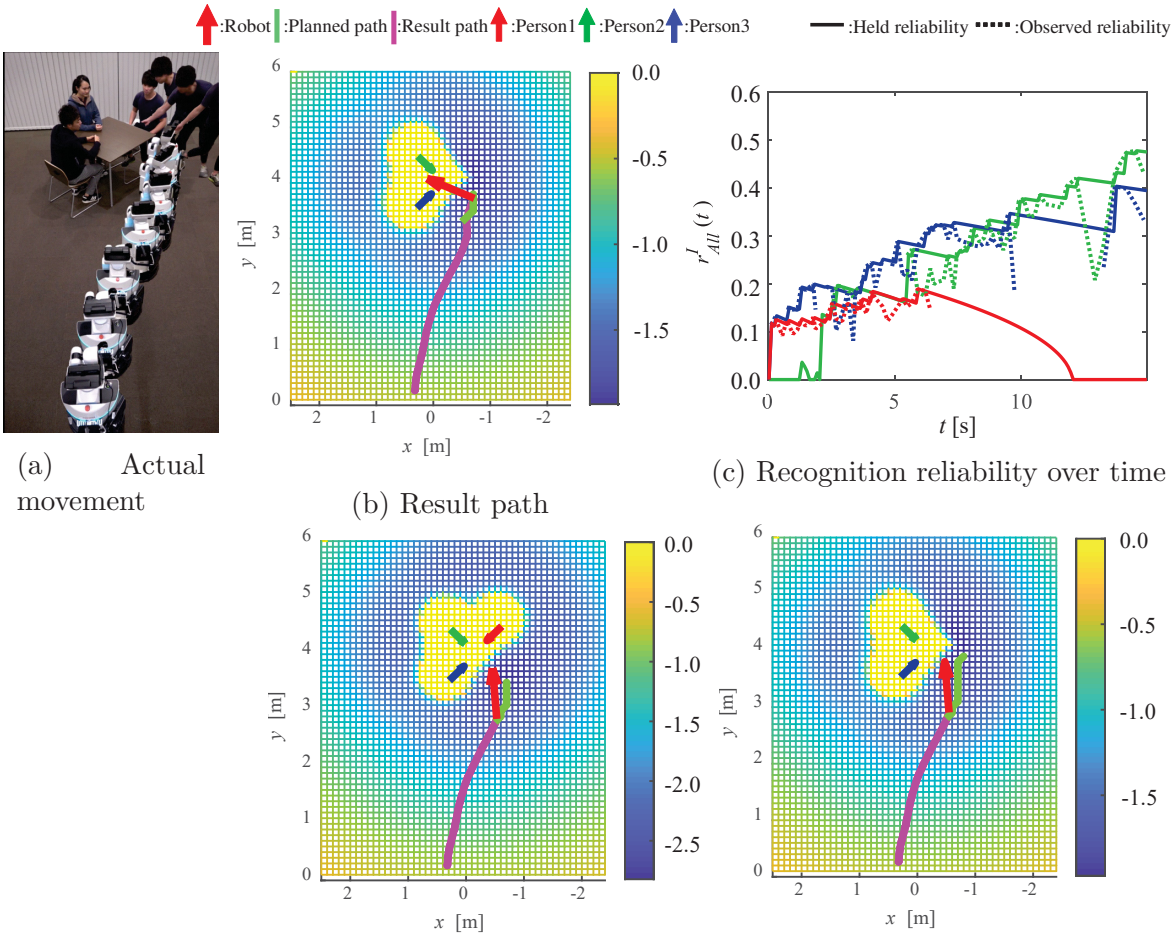


(a) Actual movement

(b) Result path

(c) Recognition reliability over time

(d) Potential field at 11.6 s

(e) Potential field at 11.7 s

Figure 4.24: Results from Scenario 4.2

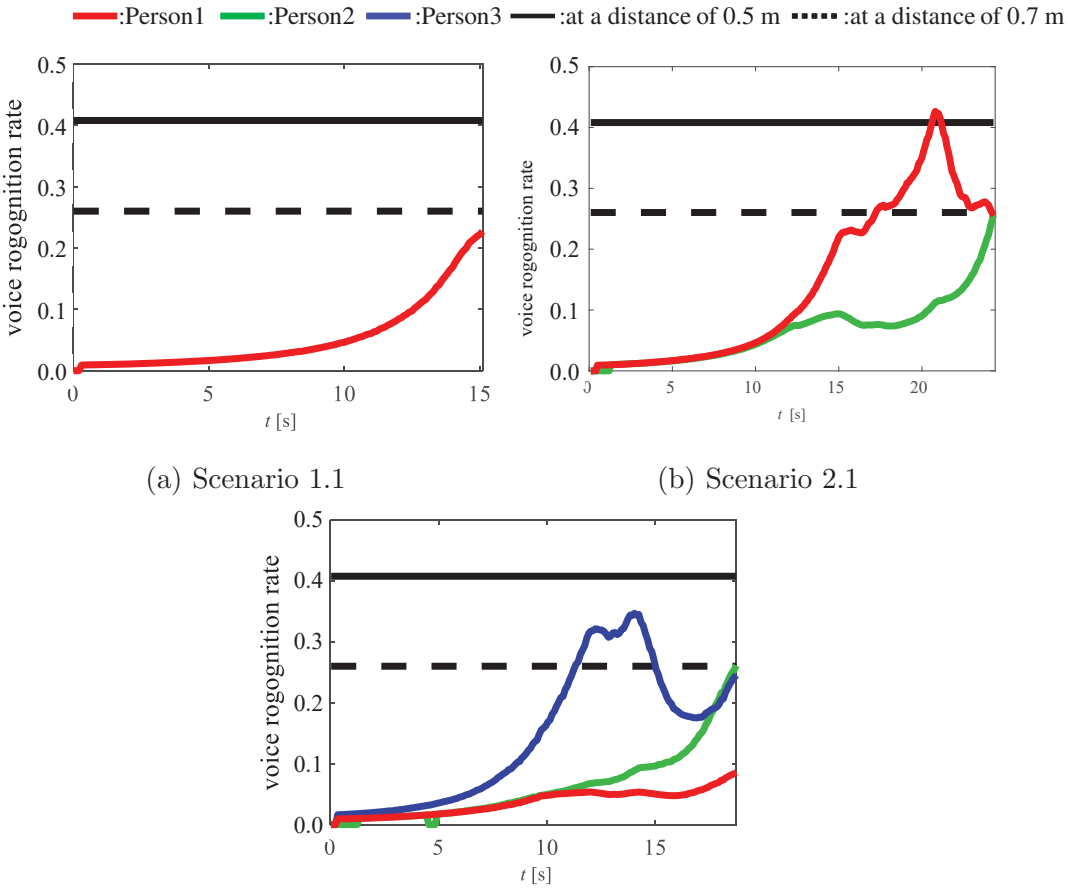


(a) Scenario 1.1

(b) Scenario 2.1

(c) Scenario 3.1

Figure 4.25: Time history of expected voice recognition rate

### シナリオ 4: 目的地におけるセンシング信頼度の検証

目的地において，インタラクションタスクに有用なセンサの期待されるセンシング信頼度を評価した．また，接近時に期待される音声認識率は，Fig. 4.25 に示すように，人の音声センシング特性とロボットと人の距離からに基づき推定した．音声認識率は距離の 2 乗に反比例するため，少しの距離でも人に接近することが重要である．黒の実線は 0.5m，黒の点線は 0.7m の距離での音声認識率を示している．ロボットは人に対して最大限接近した場合，0.5m まで接近可能である．今回の実験では，人に対して設けた障害物ポテンシャルを半径 0.7m の丸柱と想定して計算した．そのため，ロボットは人から 0.7m の距離まで移動したが，経路追従精度の影響を受けて 0.7m 以内に近づく場合も生じた．この結果から，ロボットは障害物形状ポテンシャルを考慮しつつ，可能な限り人に接近したことが確認できた．

シナリオ 3.2 の目的地で RGB-D カメラを用いて撮影された人の画像を Fig. 4.26 に示す．音声の重要度が低いタスクの場合に，人間の画像ポテンシャルを重視したマルチモーダルポテンシャル場に基づいて，ロボットは目的地へ移動した．そのため，ロボットは人の正面付近まで移動し，RGB-D カメラの回転させることで人物の正面から有用な写真を撮影できた．撮影先で 10 回平均の認識信頼度を評価し，その結果を Table 4.4 に示めす．認識信頼度は，RGB-D カメラで人物を撮影した際に評価する．認識信頼度のばらつきは大きいが，4.4.2 項で述べた認識信頼度の測定実験に基づき，飲み物提供タスクにおける認識信頼度の平均値が十分に高いことが確認された．

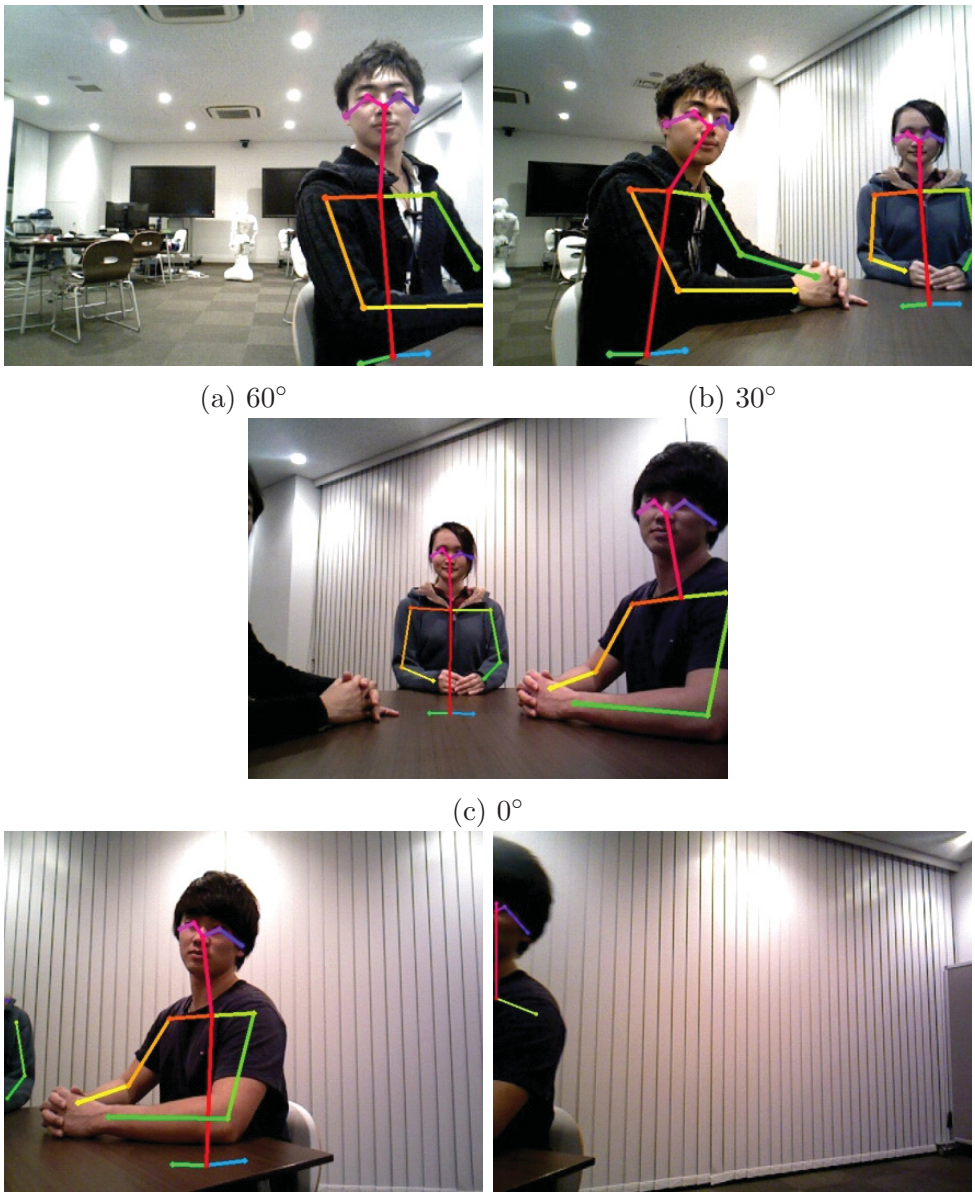

(a) 60° (b) 30°

(c) 0°

(d) −30° (e) −60°

Figure 4.26: Pictures captured at the destination in Scenario 3.2

Table 4.4: Result of recognition reliability

| Scenarios | Person1 | Person2 | Person3 | Average |
|---|---|---|---|---|
| 1.2 | 0.45 | - | - | 0.45 |
| 2.2 | 0.43 | 0.45 | - | 0.44 |
| 3.2 | 0.43 | 0.48 | 0.50 | 0.47 |

### 4.8.2 実験 2: マルチモーダルポテンシャル場に基づくアクショングラフの検証

#### 実験設定

次の行動の実行しやすさを考慮した行動列の計画を促進するため，マルチモーダルポテンシャル場に基づき世界状態依存アクショングラフを構築する手法について述べた．本実験の目的は，アクションモデルに基づきアクショングラフを構築するうえで必要となる行動の実行場所の決定方法として，マルチモーダルポテンシャル場に基づき算出される統合ポテンシャル場の極小値を行動の実行場所とする有効性を検証することである．特に，以下の二点について検証する．一点目は，アクションモデルと周辺物体の配置に基づき，次の行動の実行しやすさをより詳細に考慮した行動の実行場所の決定が可能であること．二点目は，アクショングラフに行動の実行場所を複数個与えることで，実空間における行動列全体の評価と各行動の実行しやすさの双方を考慮した行動の実行場所が決定可能であることである．

本実験では，RGB-D カメラ，マイクを有したモバイルマニピュレータの HSR [57] を想定したシミュレーションを実施した．シミュレーションでは，Fig. 4.27 に示す想定環境を対象に複数の手法で世界状態依存アクショングラフを構築し，目標状態を達成するための行動列を計画した．初期状態 *init* は，ロボットは $p_0^r$ の位置に Bottle を把持した状態で存在しており，もう一つの Bottle は Table 3 の上に存在している状態とした．目標状態 *goal* は，Person 4，Person 5 が Bottle を把持している状態とした．アクショングラフを構築時に考慮する行動は *pickup*，*handover*，*push* とした．アクショングラフを構築する上での，各行動の実行場所を決定する処理 **GetFeasiblePositionsForActions** に複数の手法を適用した．基本的な行動の実行場所の決定方法として，3.3.5 項に記載した，物体を中心とした円周上 4 点を候補としたうえで，ロボットのフットプリントと環境中の物体の配置を考慮しロボットが到達可能な点を採用する方法を適用した．そして，*handover* 行動の実行場所の候補の決定方法に対して Table 4.5 に示す三つの手法を適用し，アブレーションスタディを実施した．比較手法 1 では，四つの行動実行場所を与える他の行動と同様の 3.3.5 項に記載した方法を適用した．比較手法 2 と提案手法では，アクションモデルを考慮したうえで行動実行場所を決定する．*handover* 行動は人の姿勢が観測できることが重要な行動であるため，音声重要度 $w^S$ が 0 のマルチモーダルポテンシャル場と障害物ポテンシャルを統合したポテンシャル場に基づく方法とした．比較手法 2 は，行動の実行場所を統合ポテンシャル場の最小点とし，計画前から行動に対して実行場所を 1 対 1 に対応させる方法とした．提案手法は，4.7 節で述べた，統合ポテンシャル場における極小点のうち閾値よりも評価の良い点とし，行動に対して複数の実行場所を対応付ける方法とした．閾値は，行動の実行に要求される観測精度に依存し，本実験では試行錯誤的に-0.8 とした．

#### 実験結果

想定環境を対象に，比較手法と提案手法に基づき世界状態依存アクショングラフを構築し，目標状態を達成するための行動列を計画した結果を示す．

まず，手法毎の行動の実行場所の候補の差を示すため，世界状態依存アクショングラフの事前行動可能性グラフ $G_0^a$ を構築するうえで決定した Person 4 と Person 5 に対する $Handover$ 行動の実行場所の候補と，それに基づいて構築した $G_0^a$ を Figs. 4.28-4.30 に示す．各 $Handover$ 行動の実行場所の上部に記載されている赤字の数値はマルチモーダルポテンシャル場の評価値である．比較手法 1 では Person 4 や Person 5 への $Handover$ 行動の実行場所はそれぞれ Figs. 4.28a, 4.28b に示すように人の周りの 4 点となる．さらにその他の行動の実行場所を取得し，ロボットが到達可能な点を採用した上で Fig. 4.28c に示すように行動可能性グラフが構築される．比較手法 2 では，Person 4 や Person 5 への $Handover$ 行動の実行場所はそれぞれ Figs. 4.29a, 4.29b に示すように周辺物体の配置と

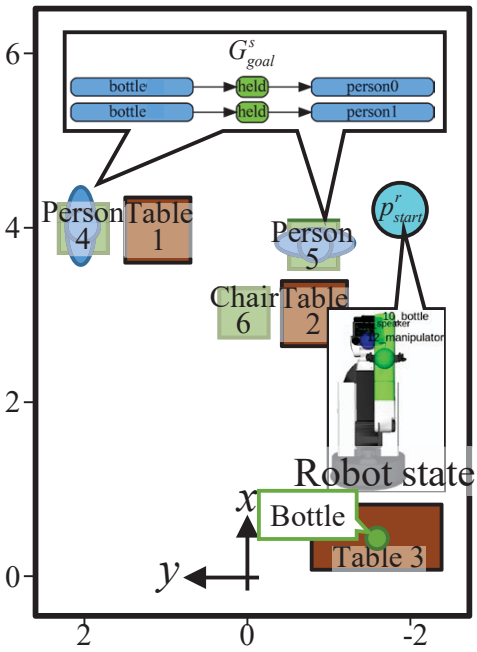


Figure 4.27: Assumed environment in Experiment2

アクションモデルに基づき算出されたポテンシャル場の最小点が実行場所として決定される．さらにその他の行動の実行場所の候補を取得し，ロボットが到達可能な点を採用した上で Fig. 4.29c に示すように行動可能性グラフが構築される．提案手法では，Person 4 や Person 5 への *Handover* 行動の実行場所はそれぞれ Figs. 4.30a, 4.30b に示すように，提案手法ではポテンシャル場の最小点だけでなく極小点のうち-0.8 を下回る点が実行場所として決定される．そして，Fig. 4.30c に示す行動可能性グラフが構築される．

次に，それぞれの手法に基づき構築したアクショングラフに基づき，目標状態を達成するための行動列を計画した結果を Fig. 4.31 と Table 4.6 に示す．比較手法 1 に基づき計画された行動列の内容は，Fig. 4.31a に示すように，初期状態からロボットが把持している Bottle を Person 5 に *Handover* をした後，Table 3 から Bottle を *Pickup* し，その Bottle を Person 4 に *Handover* してタスクを達成するものとなった．しかし，比較手法 1 では，*Handover* の実行を考慮した人への接近のアクションモデルが考慮されていないため，人の真横を行動の実行場所として決定しており，期待される人の認識信頼度はそれぞれ 0.30, 0.30 となった．また，行動列のコストである移動距離は 7.25 である．比較手法 2 に基づき計画された行動列の内容は，Fig. 4.31b に示すように，初期状態からロボットが把持している Bottle を Person 4 に *Handover* をした後，Table 3 から Bottle を *Pickup* し，その Bottle を Person 5 に *Handover* してタスクを達成するものとなった．比較手法 2 では，*Handover* の実行を考慮した人への接近のアクションモデルが考慮されているため，最も人の姿勢を観測しやすい人の正面の位置が行動の実行場所として決定されており，期待される人の認識信頼度はそれぞれ 0.45, 0.45 となった．また，行動列のコストは 8.48 である．提案手法に基づき計画された行動列の内容は，Fig. 4.31c に示すように，比較手法 1 と同じものになった．提案手法では，比較手法 2 と同様に *Handover* の実行を考慮した人への接近のアクションモデルを考慮した上で，統合ポテンシャルの極小点に基づき，複数の点が行動の実行場所として決定されている．その結果，期待される人の認識信頼度は Person 4 が 0.39, Person 5 が 0.40 となった．また，行動列のコストは 7.34 である．

比較手法 1 と提案手法の結果を比較することで，行動列のコストは同等であるが，期待される人の認識信頼度は提案手法のほうが高くなっているため，提案手法ではアクショ

Table 4.5: Experimental conditions of method in Experiment 2

| Considered items \ Method | Com. 1 | Com. 2 | Pro. |
|---|---|---|---|
| Action model | ○ | | ○ |
| Multiple candidates of action position | | ○ | ○ |

Table 4.6: Expected recognition reliability at planned action positions and cost of plans

| Method | Recognition reliability of Person4 | Recognition reliability of People5 | Cost |
|---|---|---|---|
| Com.1 | 0.30 | 0.30 | 7.25 |
| Com.2 | 0.45 | 0.45 | 8.48 |
| Pro | 0.39 | 0.40 | 7.34 |

ンモデルを考慮することで各行動の実行しやすさ向上させることが示された．また，比較手法 2 と提案手法の結果を比較することで，期待される人の認識信頼度は比較手法 2 のものが高いが，行動順や行動の実行場所が異なっており，行動列のコストは提案手法のものが低いことがわかる．そのため，提案手法では，設定した $Handover$ 行動に要求される統合ポテンシャルの評価の閾値を満たしたうえで，より行動列のコストが低くなる行動の実行場所が決定可能であることが示された．以上の結果より，提案手法では，要求される認識信頼度を満たした行動の実行場所の候補を決定したうえで，行動列全体の移動距離がより短くなるように行動列が決定可能であることを確認し，要求される認識信頼度と行動列全体の実空間における評価の双方を同時に考慮した行動列の決定が可能であることを示した．

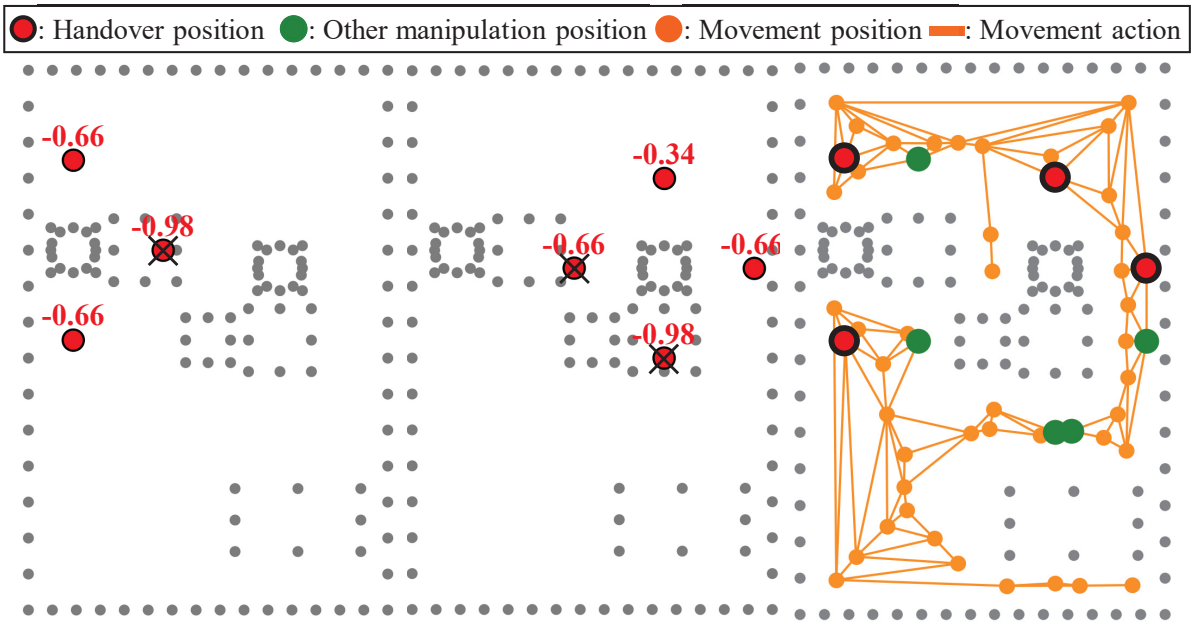


(a) Added action positions of *handover* to Person 4

(b) Added action positions of *handover* to Person 5

(c) Constructed prior action possibility graph $G_0^a$

Figure 4.28: Prior action possibility graph $G_0^a$ based on Comparison method 1

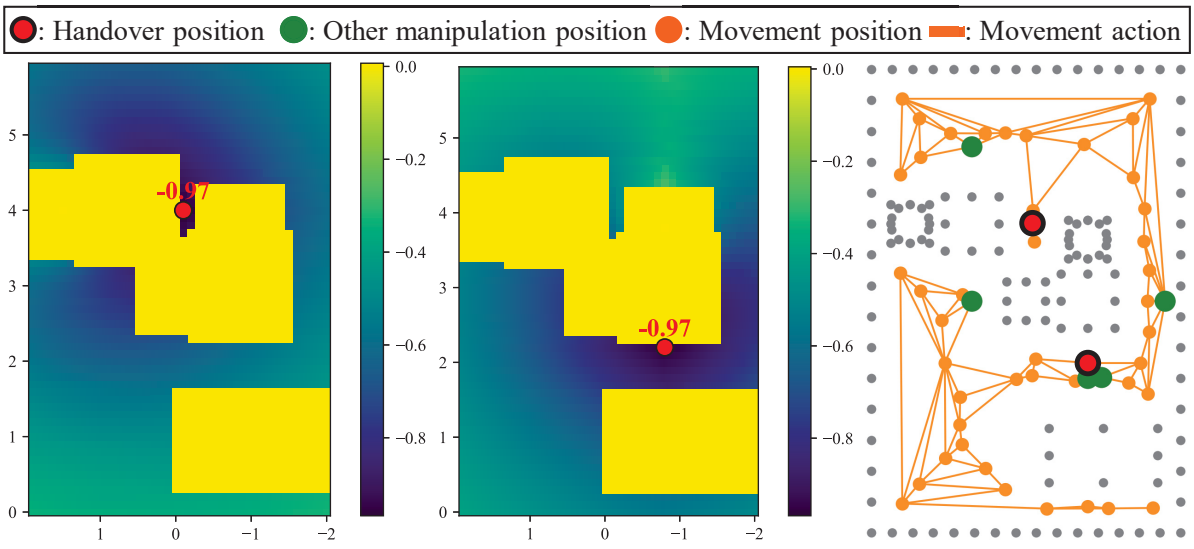


(a) Added action positions of *handover* to Person 4

(b) Added action positions of *handover* to Person 5

(c) Constructed prior action possibility graph $G_0^a$

Figure 4.29: Prior action possibility graph $G_0^a$ based on Comparison method 2

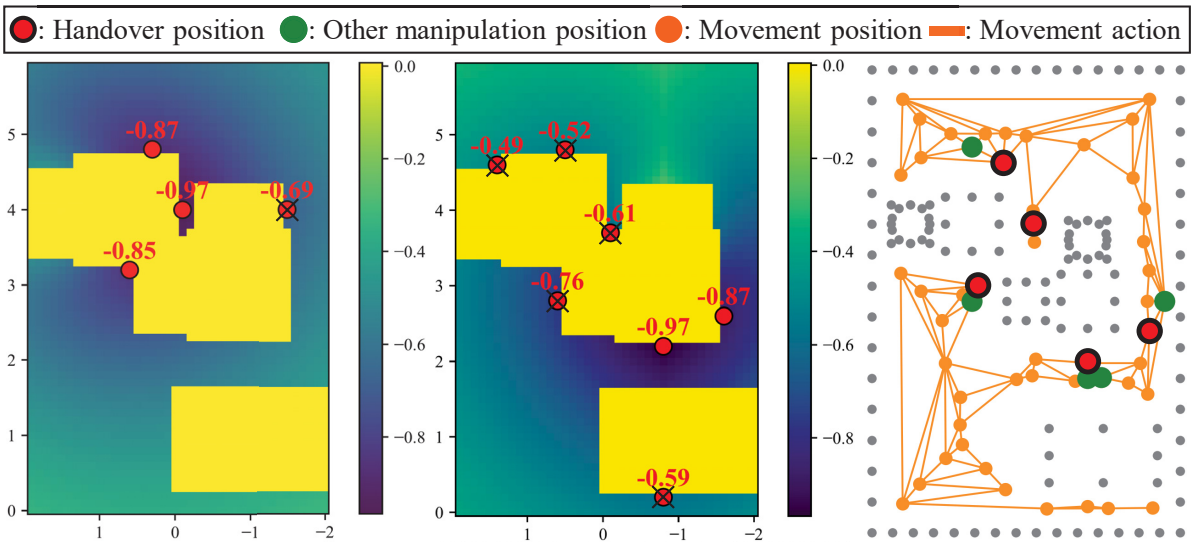


(a) Added action positions of *handover* to Person 4

(b) Added action positions of *handover* to Person 5

(c) Constructed prior action possibility graph $G_0^a$

Figure 4.30: Prior action possibility graph $G_0^a$ based on Proposed method

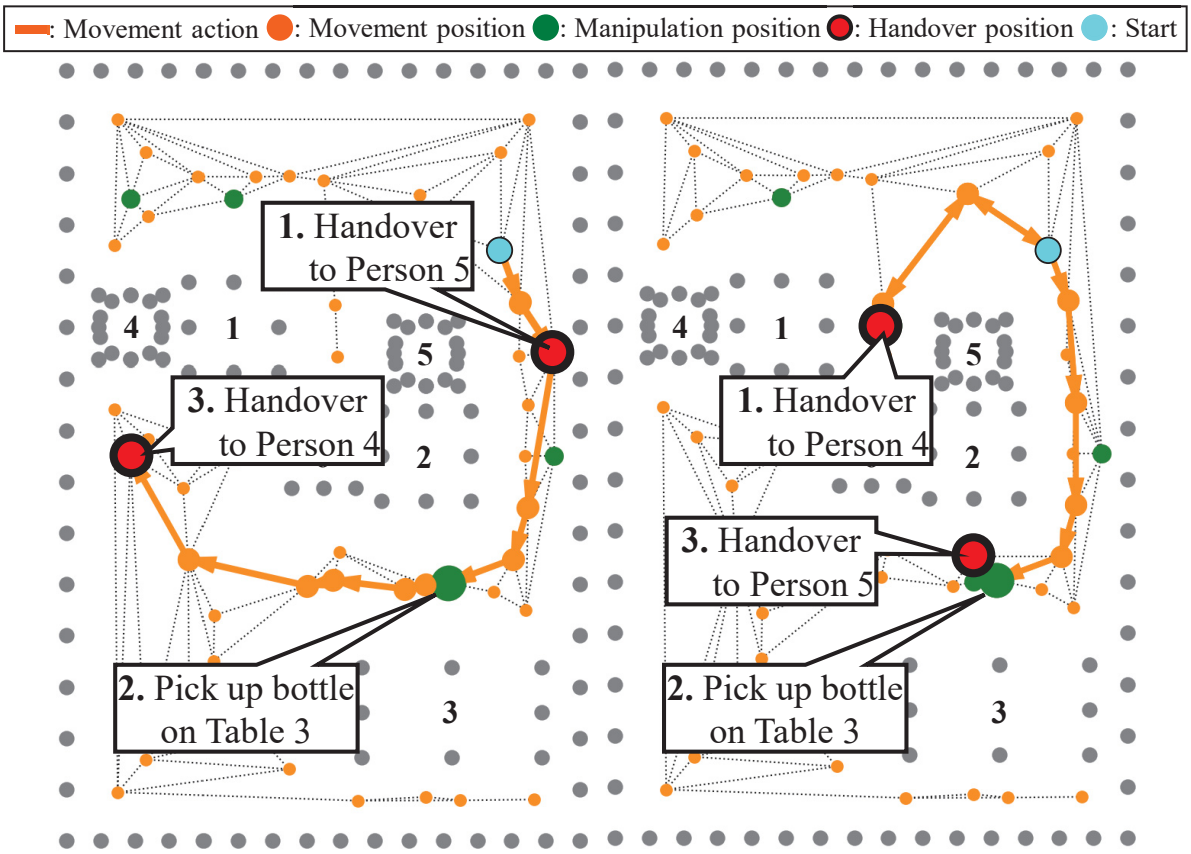


(a) Comparison 1 (b) Comparison 2

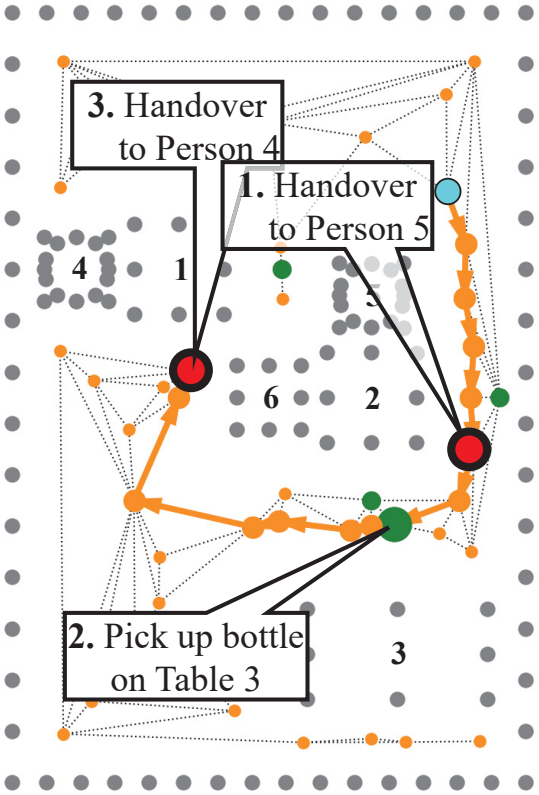


(c) Proposed

Figure 4.31: Planning result based on action graph

## 4.9 結言

本章では，ロボットに搭載されているセンサを活かしHRI行動を促進するための人への接近行動のアクションモデリング手法を提案した．具体的には，センサ特性や人の情報など，次元の異なる情報を実空間におけるポテンシャル場を用いて同じ情報空間へ統合するための方法について提案した．HRI行動の内容やセンサ情報に基づき，画像センシング，音声センシング，障害物回避に基づく重み付けと合成を行い，人への接近行動のアクションモデルとしてのマルチモーダルポテンシャル場の算出方法を提案した．経路計画においては，リアルタイムのセンサデータに基づいて，マルチモーダルポテンシャル場をリアルタイムに生成するとともに，人の配置に基づくマルチモーダルなポテンシャル場を合成することで，動的な観測状況や複数人のシナリオを考慮することが可能である．さらに，接近行動のアクションモデルとしてのマルチモーダルポテンシャル場に基づくアクショングラフの構築手法として，ポテンシャル場の極小点を行動の実行場所とする設計方法を提案した．本手法を喫茶店の環境下で実験的に評価した．まず，人への接近における経路計画では，一人や複数人，人の配置が動的に変化するシナリオにおいてHRI行動の実行に有用な人の情報を取得可能な位置へ移動可能であることを確認した，さらに，提案の接近行動のアクションモデルに基づくアクショングラフの構築手法の有効性を，複数の手法と比較検証することで確認した．

# Chapter 5

# 結論

サービスロボットによる円滑なタスク遂行を実現するため，ロボットの機能や環境を有効活用できる行動列を計画する手法を提案した．ロボットの機能や環境を有効活用するためには，計画された行動列が実空間における指標に基づき決定された行動で構成され，個々の行動は次の行動を促進するものである必要がある．そこで，実行場所に着目し，行動を幾何空間に埋め込み，連続的な幾何空間を適切に離散化することで，実空間を考慮したうえで現在・未来にロボットが実行可能な行動の範囲を理解し，その範囲でタスクを解釈することで行動列を決定した．まず，行動に関する記号的な知識や，ロボットのアクチュエータやセンサの性質，物体集合などの幾何的な情報に基づく実行可能な行動の時空間的な関係性を記述する環境表現手法を構築した．そして，その表現手法に基づき，行動列の内容や順番，実行場所を同時に最適化する計画手法を構築した．具体的には，実空間に実行可能な複数の行動を埋め込む方法として，行動の実行場所に着目し，エッジを行動の実行，ノードを行動の実行場所としたグラフ表現であるアクショングラフを提案した．

アクショングラフは，ある環境においてロボットが実行可能な複数の行動を表現する行動可能性グラフを環境変化前，環境変化後に対して構築し，それらを統合して得られる多層グラフであるため，現在・未来に実行可能な行動を表現することが可能である．まず，ロボットの移動タスクを対象に，基本的なアクショングラフとそれに基づく計画手法を提案した．そして，それぞれのサービスロボットの機能を活かして目的地へ移動可能であることを示した．次に，アクショングラフにおいてモバイルマニピュレーションタスクを扱うため，環境状態とロボット状態からなる世界状態とロボットが実行可能な行動の相互作用を表現できるようにアクショングラフを時間方向に拡張し，再帰的な多層構造を有する世界状態依存アクショングラフを提案した．そして，モバイルマニピュレーションタスクにおいて，ロボットの機能や環境を活かしてタスクを遂行できることを示した．また，サービスロボットの HRI のための接近行動に着目し，行動を実空間へ落とし込むうえで，次の HRI 行動を促進するための重要なセンサ情報とセンサ特性に基づくアクションモデリング手法を提案した．さらに，得られたアクションモデルを，経路計画手法やアクショングラフに適用する手法を提案し，次の行動の促進に有効であることを示した．

## 5.1 貢献

### 多層構造を有するアクショングラフによる行動の時空間表現

従来のタスク・モーションプランニングにおいて，実空間で実行可能な行動やその位置を特定する手法は，動作計画を活用し，その行動の実現可能性を検証する方法や，最短経路上に存在する移動可能物体を検出する方法が一般的であった．しかし，上記の手法では目標位置の方向に存在しない一見遠回りに見える位置の物体を対象とした実行可

能な行動を考慮することが困難な場合や行動可能性の変化の因果関係を正しく表現することが困難となる場合が存在し，実行可能な行動の時空間的な理解や選択可能な行動列の理解に制限がある．一方，提案のアクショングラフは，ロボットが認識している全ての物体集合とロボットのサブシステム構成に基づき構築されること，多層のグラフ表現を有することで，実空間を考慮した上でロボットが実行可能な行動の時空間的な関係性を表現することが可能である．さらに，構築したアクショングラフに基づくタスクプランニングでは，目的地に到達する上で選択可能な環境変化毎に，行動列を計画することが可能である．これにより，目標位置に直接向かわない戦略も含めて環境中で選択可能な行動列をより多く把握することが可能であり，その中から評価関数に基づき適切な行動列を選択することが可能である．本論文の検証では，移動タスクを対象としたシミュレーションや実機実験を通じて，アクショングラフにより考慮可能な行動の種類や行動列が増加することを示した．

### 世界状態と行動可能性の相互作用を表現する世界状態依存アクショングラフに基づく行動列の内容，順序，実行場所の同時最適化

複数の行動を組み合わせて達成されるモバイルマニピュレーションタスクにおいて，ロボットの機能やおかれた環境を有効活用するためには，他の行動を考慮し，実空間においてより短い行動列となるように行動列の内容や順序，実行場所が決定される必要がある．しかし，従来のタスク・モーションプランニングにおける各行動の目標状態を決定方法では，その他の行動の実行しやすさは考慮されていない．一方，提案の世界状態依存アクショングラフでは，実行可能な行動の実行場所に着目し，再帰的な多層構造により世界状態に基づく行動可能性とロボットが実行する行動の相互作用を表現した．さらに，行動可能性グラフでは，記号的情報と幾何的情報の双方を含む行動に関する知識に基づき，シーングラフを用いた行動の対応付けや各行動に対する複数の実行場所の候補の埋め込みを行うことで複数の行動の位置関係を表現した．これにより，世界状態依存アクショングラフでは，行動の時空間的な関係性を網羅的に表現可能であるため，行動列の内容や順序，実行場所を同時に最適化することが可能である．そして，実空間においてより移動距離が短い行動列を決定することで，ロボットの機能やおかれた環境の有効活用を実現した．本論文の検証では，モバイルマニピュレーションタスクを対象としたシミュレーションや実機実験を通じて，世界状態依存アクショングラフにより実空間において移動距離がより短い行動列を決定し，ロボットの機能やおかれた環境を有効活用することが可能であることを示した．

### ポテンシャル場を用いた情報統合による接近行動のアクションモデリング

従来，HRI 行動を促進するための移動行動の設計手法では，人の感性的な要素を考慮したものや，特定の HRI タスクに特化した移動設計を行う手法が提案されてきた．一方，提案の接近行動のアクションモデリングでは，HRI 行動を促進するアプローチとして，人から重要な情報を観測することに着目し，次の HRI 行動に重要となるセンサ情報が高い信頼性で観測できる位置をモデル化した．この際，HRI タスク内容やセンサ特性，人の情報など，次元の異なる情報を同じ情報空間へ統合する必要がある．そこで，本研究では，ポテンシャル場を用いて次元の異なる情報を同じ情報空間へ統合するマルチモーダルポテンシャル場を提案した．これにより，得られたアクションモデルでは，複数の種類の HRI 行動や，複数人を相手とした HRI 行動を扱うことを実現した．本論文の検証では，マルチモーダルポテンシャル場に基づく経路計画手法やアクショングラフの構築手法を提案したうえで，シミュレーションや実機実験を行い，ロボットが HRI タスクに応じてのセンサを有効活用可能な位置へ移動可能であることを検証した．

## 5.2 今後の展望

本研究が現時点で有する展望に関して，想定外を扱うための課題，実装に関する課題，応用に関する拡張性，ベンチマーク課題の提案の項目で整理し，今後の研究の方向性で代表的なものを以下に述べる．

### 5.2.1 想定外を扱うための課題

#### タスクの動的な変更や割り込みの考慮

本研究では，ロボットに指示されるタスクは静的に指定され，動的にタスクが変更されることや新たにタスクが割り込むことは起こりえないと想定した．

タスクの動的な変更や割り込みを扱えるようにアルゴリズムを拡張する上では，計画手法において，複数のゴール条件やゴール条件の優先順位を扱えるように拡張する必要がある．また，割りこまれたタスクと実行中のタスクを両立するアルゴリズムや，タスクやゴール条件の優先順位を判断するアルゴリズムの構築が必要である．

#### 行動に関する事前知識の不確かさの考慮

本研究では，人とロボットは協働関係を築いており，環境中の人はロボットに協力的であることを想定した．また，ロボットの移動行動やマニピュレーション行動は失敗しないことを想定した．

今後は，このような想定を置けず，行動の結果が複数考えられるような状況を扱えるようにアルゴリズムを拡張する必要がある．具体的には，アクショングラフを用いたタスク・モーションプランニングでは，目標状態を達成可能な行動列を複数個取得することが可能であり，他の行動列へ切り替えることを考慮した計画手法へ拡張する必要がある．その際には，行動列の実行に関する指標としてリスクや他の実行可能な行動列への移行しやすさを考慮した行動列の計画手法を確立する必要がある．

#### 未知環境や環境変化の考慮

本研究では，環境センシングシステム等を用いることで環境中の物体の位置や種類，形状などの環境状態は既知とした上で，環境状態はロボット以外によって変更されないこととした．

しかし，ロボットに搭載されたセンサから得た情報に基づいてアクショングラフを構築し，人による環境変更などに関しても考慮出来ることが望ましい．今後は，ロボットに搭載されたセンサから得た物体情報に基づいてアクショングラフを更新しつつ，行動列を計画できるように拡張する必要がある．アクショングラフの構築や行動列の計画には計算コストを要するため，センサ情報の更新の度にアクショングラフや行動列を再度計算することは現実的ではない．そのため，新たに得たセンサ情報の内容や実行中のタスクに応じた，アクショングラフや行動列の更新則を構築する必要がある．環境中の物体の配置が変化した場合には，実行中の行動列への影響によって，実行する行動列を他の候補へ変更すること，アクショングラフを部分的に更新し行動列を再計画すること，アクショングラフを再構築するなど複数の対処方法の候補から適切な対処を選択するアルゴリズムの開発が必要である．

また，人などの動的なエージェントによる自由な行動を考慮する場合，そのエージェントの行動可能性を考慮した計画手法が必要である．その際には，ロボットだけでなく動的なエージェントに対してもアクショングラフを構築して行動予測に活かすなど，ロ

ボット以外のエージェントへもアクショングラフを適用することが本研究の拡張の方向性として考えられる．

さらに，環境状態が未知であることを想定した場合には，環境状態の把握とタスク遂行を同時に実行することが必要となるため，観測行動や観測の不確かさを考慮したアクショングラフの構築やそれに基づく計画手法を構築する必要がある．

#### アクショングラフにおける未知物体の考慮

本研究では，事前知識に含まれない物体は考慮されていない．しかし，人の生活空間に存在する物体を事前知識で網羅することは困難であるうえ，事前知識に含まれない物体も扱うことが求められる．

今後は，未知物体に対しても行動を対応付けられるようにアルゴリズムを拡張する必要がある．具体的には，現在の行動に関する事前知識は具体的な物体情報を用いて記述されているが，物体情報をアフォーダンスの概念に基づき抽象化したうえで記述することが可能である．さらに，ロボットが未知物体に遭遇した際，画像情報や実際に行動を試みた結果などに基づきアフォーダンスを分類し，知識やアクショングラフを更新することが考えられる．

### 5.2.2 実装に関する課題

#### 計算コストの削減

本研究では，一般家庭の一つのフロア程度の大きさの環境を想定し，提案手法の検証を行った．今後は広いフロアである病院等や物体の個数が増加するカフェ環境等への提案手法を適用し，汎化性能を検証する必要がある．その際，考慮すべき行動可能性グラフの数は，環境中における考慮すべき物体の数に依存して増大することが予想される．

アクショングラフ構築に関わる計算コストを低減する方針案として，構築するアクショングラフを複数に分割する方法とタスク指向でアクショングラフを構築することがあげられる．

構築するアクショングラフを複数に分割する方法では，一つの大規模なアクショングラフを構築する場合には組み合わせが膨大となる場合も，エリアを複数に分割し小規模なアクショングラフを構築し，それらを接続することで，構築する行動可能性グラフを削減することが見込まれる．しかし，適切にエリアを分割する方法や複数のアクショングラフを接続する方法に関して，さらなる検討が必要である．

タスク指向のアクショングラフ構築に関しては，アクショングラフを構築するより前にタスクが明らかになっている場合，タスクに関連する物体や環境中の物体配置に基づき幾何的に重要となる物体に限定してアクショングラフを構築することで，構築するべき行動可能性グラフを削減することが可能である．考慮する物体を限定する方法として，タスク・モーションプランニングの研究分野では，より性能の良いヒューリスティック関数を推定する研究が数多く行われている [32, 102–107]．また，最新の動向の一つとして，言語モデルをタスク・モーションプランニングに用いる手法が提案されている [35]．そのようなヒューリスティック関数をアクショングラフの構築に適用する方法を検討することや，アクショングラフの構築における適切なヒューリスティック関数を推定する必要がある．

マルチモーダルポテンシャル場における歩行者とのインタラクションの考慮

本研究では，席に着席している人に対して接近することを想定している．しかし，状況によっては移動中の人に対して話しかけるなどのインタラクションが考えられる．

今後は，観測誤差などの不確かさの影響を受けるシナリオなどより複雑なタスクにおける検証が必要であり，その際には成功率等に基づく提案手法の統計的な分析が必要である．

マルチモーダルポテンシャル場における人の詳細な状態の考慮

本研究では，人の感情や声の大きさは一定であることを想定している．しかし，人の情報の取得しやすさはセンサの特性だけでなく観測対象の状態にも依存して変化する．

今後の研究の方向性として，移動過程で人の感情や声量など人の詳細な状態で個人差が生じる要素についても扱えるようにアルゴリズムを拡張することが考えられる．

### 5.2.3 応用に関する拡張性

異なるエージェントに関するアクショングラフの構築

本研究では，計画対象のロボットに関するアクショングラフを構築したが，異なるエージェントに対しても構築可能である．計画対象のロボットだけでなく，他の人やロボットに対してアクショングラフを構築することで，他のエージェントの状況を行動可能性の観点から把握することが考えられる．

今後の方向性として，アクショングラフを介して行動可能性におけるエージェント間の共通部分や差を把握することができるため，他のエージェントの機能を引き出す計画や，他のエージェントに対して利他的なふるまいをする計画など，マルチエージェントを対象とした計画問題への応用が考えられる．エージェントとして人を対象にする場合，患者の機能を引き出す支援が要求されるリハビリテーションへの応用などが考えられる．

行動履歴に基づくアクショングラフの構築

本研究では，ロボットが有する行動の事前知識に基づき，アクショングラフを構築することを想定している．人とロボットの共進化などを見据えると，他のエージェントの行動を観測する中で，新たな知識を獲得し，自身のふるまいへ反映できることが望ましい．

今後の研究の方向性として，実世界におけるエージェントの行動履歴をアクショングラフで解釈することで，エージェントのサブシステムの性質や行動の知識を特定し，新たな知識として獲得することが考えられる．

アクショングラフに基づく実空間を考慮した対話の実現

本研究では，人からのタスクは曖昧さを含まない前提で，与えられたタスクをロボットの行動可能性の範囲内で解釈し，タスクを達成するための行動列を決定する計画手法を構築した．環境中の物体に干渉することができるサービスロボットと人の会話を想定すると，記号空間における情報だけでなく，実空間における情報を同時に考慮したうえで曖昧さを含む人の発言を解釈する必要がある．

実空間における情報から構築したアクショングラフに基づきロボットが実現可能な世界状態を把握することができるため，今後の研究の方向性として，既存の自然言語処理アルゴリズムとアクショングラフを組み合わせることで，曖昧さを含む人の発言をロボットの行動可能性に基づき解釈し，より円滑な対話を実現することが考えられる．

アクショングラフに基づく空間設計

本研究では，環境中の物体配置やエージェントの状態に基づき，実行可能な行動を実空間に埋め込んだうえで，その変化を把握することで，ロボットが実行可能な行動の時空間的な関係性をグラフ表現で記述可能である．そのため，AR 表現技術などを用いることで対象のエージェントの行動可能性を実空間へ投影することが可能であり，非専門家による行動可能性の理解を促進することが可能である．また，エージェントの行動可能性をグラフで表現可能であるため，グラフ理論に基づく定量的な解析が可能である．

以上のアクショングラフの特色に着目し，今後の研究の方向性として，エージェントの行動可能性に基づく人の生活空間や人とロボットの協働空間の設計に応用することが考えられる．AR 表現技術を用いた行動可能性の表示により，エージェントの行動しやすさと感性的要素を同時に考慮することを実現し，環境とインタラクティブな空間設計を促進することが考えられる．また，サービスロボットと人が協働する空間を，行動可能性という新たな指標と収容人数などのサービス面の要求を同時に考慮したうえで，数値的に最適化する新たな空間設計法を構築することが考えられる，

### 5.2.4 ベンチマーク課題の提案

本研究では，実空間における指標に基づき行動列を決定することで，ロボットの機能や環境を有効活用するための手法を提案した．そのため，手法の検証において，家具や人などの環境中の物体の配置が重要である．しかし，提案されているベンチマーク課題では，単調な家具配置の環境を対象としているものやテーブル上の複雑な物体配置に着目したタスクを対象としている [108]．また，World Robot Summit におけるパートナーロボットチャレンジ [109] や Robocup の@Home リーグ [110] などの人の生活空間を対象とした国際的な競技会が存在するが，対象としているタスクでは，人の指示の理解や環境中の物体の認識，物体の把持やドアを開けるなど個々の動作に焦点が当たっており，タスク・モーションプランニングが扱うような複数の行動の組み合わせ方については現段階では焦点が当たっていない．そこで，本研究では各実験において，想定する環境を例示し，その環境において従来手法と性能を比較することやアブレーションスタディによる提案要素と性能の関係性を明らかにすることで，提案手法の有効性を検証した．今後の課題として，本研究が対象としている問題意識を表現する想定環境や一般課題を考案し，ベンチマーク課題として提案する必要がある．その際には，一般の人にも適用可能なベンチマーク課題とし，人が実行する行動列とロボットが実行する行動列を比較できるようにするなど，より一般的な評価が可能な枠組みを構築することを検討している．

# 参考文献


[1] 内閣府, 令和 *3* 年版高齢社会白書. 2022.

[2] 総務省, 情報通信白書平成 *28* 年版. 2016.

[3] 一般社団法人日本機械工場連合会, *2021* 年度　ロボット産業・技術振興に関する調査研究報告書. 2022.

[4] PUDU, "Bellabot product page." `https://www.pudurobotics.com/jp/product/detail/bellabot`, (as of Dec. 2022).

[5] navel robotics, "navel product page." `https://navelrobotics.com/en/home-en-2/`, (as of Dec. 2022).

[6] P. ROBOTICS, "TIAGo product page." `https://pal-robotics.com/robots/tiago/`, (as of Dec. 2022).

[7] L. Kavraki, P. Svestka, J.-C. Latombe, and M. Overmars, "Probabilistic roadmaps for path planning in high-dimensional configuration spaces," *IEEE Transactions on Robotics and Automation*, vol. 12, no. 4, pp. 566–580, 1996.

[8] S. M. LaValle, "Rapidly-exploring random trees : a new tool for path planning," *The annual research report*, 1998.

[9] J. Kuffner and S. LaValle, "Rrt-connect: An efficient approach to single-query path planning," in *Proceedings 2000 ICRA. Millennium Conference. IEEE International Conference on Robotics and Automation. Symposia Proceedings (Cat. No.00CH37065)*, vol. 2, pp. 995–1001 vol.2, 2000.

[10] M. Zucker, N. Ratliff, A. D. Dragan, M. Pivtoraiko, M. Klingensmith, C. M. Dellin, J. A. Bagnell, and S. S. Srinivasa, "Chomp: Covariant hamiltonian optimization for motion planning," *The International Journal of Robotics Research*, vol. 32, no. 9-10, pp. 1164–1193, 2013.

[11] M. Kalakrishnan, S. Chitta, E. Theodorou, P. Pastor, and S. Schaal, "Stomp: Stochastic trajectory optimization for motion planning," in *2011 IEEE International Conference on Robotics and Automation*, pp. 4569–4574, 2011.

[12] D. J. Webb and J. van den Berg, "Kinodynamic rrt*: Asymptotically optimal motion planning for robots with linear dynamics," in *2013 IEEE International Conference on Robotics and Automation*, pp. 5054–5061, 2013.

[13] D. McDermott, M. Ghallab, A. Howe, C. Knoblock, A. Ram, M. Veloso, D. Weld, and D. Wilkins, "Pddl-the planning domain definition language," 1998.

[14] M. Fox and D. Long, "PDDL 2.1: An extension to pddl for expressing temporal planning domains," *Journal of artificial intelligence research*, vol. 20, pp. 61–124, 2003.

[15] S. Edelkamp and J. Hoffmann, "PDDL 2.2: The language for the classical part of the 4th international planning competition," AlbertLudwigs-Universitat Freiburg, Institut für Informatik, 2004.

[16] R. E. Fikes and N. J. Nilsson, "Strips: A new approach to the application of theorem proving to problem solving," *Artificial Intelligence*, vol. 2, no. 3, pp. 189–208, 1971.

[17] J. Hoffmann and B. Nebel, "The ff planning system: Fast plan generation through heuristic search," *Journal of Artificial Intelligence Research*, vol. 14, p. 253–302, may 2001.

[18] M. Helmert, "The fast downward planning system," *Journal of Artificial Intelligence Research*, vol. 26, p. 191–246, jul 2006.

[19] H. Kautz and B. Selman, "Unifying sat-based and graph-based planning," in *Proceedings of the 16th International Joint Conference on Artifical Intelligence*, p. 318–325, 1999.

[20] J. Rintanen, "Planning as satisfiability: Heuristics," *Artificial Intelligence*, vol. 193, pp. 45–86, 2012.

[21] F. Lagriffoul, D. Dimitrov, J. Bidot, A. Saffiotti, and L. Karlsson, "Efficiently combining task and motion planning using geometric constraints," *The International Journal of Robotics Research*, 2014.

[22] S. Srivastava, E. Fang, L. Riano, R. Chitnis, S. Russell, and P. Abbeel, "Combined task and motion planning through an extensible planner-independent interface layer," in *Proceedings of the 2014 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 639–646, May 2014.

[23] N. T. Dantam, S. Chaudhuri, and L. E. Kavraki, "The Task-Motion Kit: An Open Source, General-Purpose Task and Motion-Planning Framework," *IEEE Robotics and Automation Magazine*, vol. 25, no. 3, pp. 61–70, 2018.

[24] C. R. Garrett, T. Lozano-Pérez, and L. P. Kaelbling, "Ffrob: Leveraging symbolic planning for efficient task and motion planning," *The International Journal of Robotics Research*, vol. 37, no. 1, pp. 104–136, 2018.

[25] N. Castaman, E. Pagello, E. Menegatti, and A. Pretto, "Receding horizon task and motion planning in changing environments," *Robotics and Autonomous Systems*, vol. 145, p. 103863, 2021.

[26] M. Mansouri, F. Pecora, and P. Schüller, "Combining task and motion planning: Challenges and guidelines," *Frontiers in Robotics and AI*, vol. 8, 2021.

[27] D. Nau, T. C. Au, O. Ilghami, U. Kuter, J. W. Murdock, D. Wu, and F. Yaman, "Shop2: An htn planning system," *Journal of Artificial Intelligence Research*, vol. 20, pp. 379–404, 12 2003.

[28] J. Wolfe, B. Marthi, and S. Russell, "Combined task and motion planning for mobile manipulation," in *Proceedings of the Twentieth International Conference on International Conference on Automated Planning and Scheduling*, ICAPS'10, p. 254–257, AAAI Press, 2010.

[29] C. R. Garrett, R. Chitnis, R. Holladay, B. Kim, T. Silver, L. P. Kaelbling, and T. Lozano Pérez, "Integrated task and motion planning," *Annual Review of Control, Robotics, and Autonomous Systems*, vol. 4, no. 1, pp. 265–293, 2021.

[30] C. R. Garrett, T. Lozano-Perez, and L. P. Kaelbling, "Pddlstream: Integrating symbolic planners and blackbox samplers via optimistic adaptive planning," in *International Conference on Automated Planning and Scheduling*, 2018.

[31] M. Toussaint, "Logic-geometric programming: An optimization-based approach to combined task and motion planning," in *Proceedings of the 24th International Conference on Artificial Intelligence*, IJCAI'15, p. 1930–1936, AAAI Press, 2015.

[32] R. Chitnis, D. Hadfield Menell, A. Gupta, S. Srivastava, E. Groshev, C. Lin, and P. Abbeel, "Guided search for task and motion plans using learned heuristics," in *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 447–454, 2016.

[33] B. Kim, L. Shimanuki, L. P. Kaelbling, and T. L. Perez, "Representation, learning, and planning algorithms for geometric task and motion planning," *The International Journal of Robotics Research*, vol. 41, pp. 210 – 231, 2021.

[34] A. Curtis, T. Silver, J. B. Tenenbaum, T. L. Perez, and L. P. Kaelbling, "Discovering state and action abstractions for generalized task and motion planning," in *AAAI Conference on Artificial Intelligence*, 2021.

[35] B. Ichter, A. Brohan, Y. Chebotar, C. Finn, K. Hausman, A. Herzog, D. Ho, J. Ibarz, A. Irpan, E. Jang, R. Julian, D. Kalashnikov, S. Levine, Y. Lu, C. Parada, K. Rao, P. Sermanet, A. T. Toshev, V. Vanhoucke, F. Xia, T. Xiao, P. Xu, M. Yan, N. Brown, M. Ahn, O. Cortes, N. Sievers, C. Tan, S. Xu, D. Reyes, J. Rettinghouse, J. Quiambao, P. Pastor, L. Luu, K. H. Lee, Y. Kuang, S. Jesmonth, K. Jeffrey, R. J. Ruano, J. Hsu, K. Gopalakrishnan, B. David, A. Zeng, and C. K. Fu, "Do as i can, not as i say: Grounding language in robotic affordances," in *6th Annual Conference on Robot Learning*, 2022.

[36] S. Y. Lo, S. Zhang, and P. Stone, "The petlon algorithm to plan efficiently for task-level-optimal navigation," *Journal of Artificial Intelligence Research*, vol. 69.

[37] Y. Jiang, F. Yang, S. Zhang, and P. Stone, "Task-motion planning with reinforcement learning for adaptable mobile service robots," in *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 7529–7534, 2019.

[38] C. R. Garrett, C. Paxton, T. Lozano Pérez, L. P. Kaelbling, and D. Fox, "Online replanning in belief space for partially observable task and motion problems," in *2020 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 5678–5684, 2020.

[39] N. T. Dantam, Z. K. Kingston, S. Chaudhuri, and L. E. Kavraki, "An incremental constraint-based framework for task and motion planning," *The International Journal of Robotics Research*, vol. 37, no. 10, pp. 1134–1151, 2018.

[40] W. Hai Ning, M. Levihn, and M. Stilman, "Navigation among movable obstacles in unknown environments," in *Proceedings of the 2010 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 1433–1438, October 2010.

[41] M. Wang, R. Luo, A. Ö. Önol, and T. Padir, "Affordance-based mobile robot navigation among movable obstacles," in *Proceedings of the 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 2734–2740, October 2020.

[42] H. P. Moravec and A. Elfes, "High resolution maps from wide angle sonar," in *Proceedings of the 1985 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 116–121, March 1985.

[43] N. Sünderhauf, T. T. Pham, Y. Latif, M. Milford, and I. Reid, "Meaningful maps with object-oriented semantic mapping," in *Proceedings of the 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 5079–5085, September 2017.

[44] I. Kostavelis and A. Gasteratos, "Semantic mapping for mobile robotics tasks: A survey," *Robotics and Autonomous Systems*, vol. 66, pp. 86–103, 2015.

[45] U. H. Kim, J. M. Park, T. J. Song, and J. H. Kim, "3-D Scene Graph: A Sparse and Semantic Representation of Physical Environments for Intelligent Agents," *IEEE Transactions on Cybernetics*, vol. 50, no. 12, pp. 4921–4933, 2020.

[46] N. Rhinehart and K. M. Kitani, "Learning action maps of large environments via first-person vision," in *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 580–588, June 2016.

[47] R. Hachiuma, Y. Ozasa, and A. Yorozu, "Socially adaptive manner for motion planning from human server in cafe," in *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems Workshop (IROSW)*, pp. 1–2, October 2018.

[48] F. J. Chu, R. Xu, L. Seguin, and P. A. Vela, "Toward affordance detection and ranking on novel objects for real-world robotic manipulation," *IEEE Robotics and Automation Letters*, vol. 4, no. 4, pp. 4070–4077, 2019.

[49] T. Lüddecke, T. Kulvicius, and F. Wörgötter, "Context-based affordance segmentation from 2d images for robot actions," *Robotics and Autonomous Systems*, vol. 119, pp. 92 – 107, 2019.

[50] S. Bazeille and D. Filliat, "Incremental topo-metric slam using vision and robot odometry," in *Proceedings of the 2011 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 4067–4073, May 2011.

[51] J. L. Blanco, J. A. Fernandez Madrigal, and J. Gonzalez, "A new approach for large-scale localization and mapping: Hybrid metric-topological slam," in *Proceedings of the 2007 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 2061–2067, April 2007.

[52] P. T. Wu, C. A. Yu, S. H. Chan, M. L. Chiang, and L. C. Fu, "Multi-Layer Environmental Affordance Map for Robust Indoor Localization, Event Detection and Social Friendly Navigation," *Proceedings of the 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 2945–2950, November 2019.

[53] C. R. Dreher, M. Waechter, and T. Asfour, "Learning Object-Action Relations from Bimanual Human Demonstration Using Graph Networks," *IEEE Robotics and Automation Letters*, vol. 5, pp. 187–194, 2020.

[54] M. J. Aein, E. E. Aksoy, and F. Wörgötter, "Library of actions: Implementing a generic robot execution framework by using manipulation action semantics," *The International Journal of Robotics Research*, vol. 38, no. 8, pp. 910–934, 2019.

[55] MobileRobots, "P-3DX product page." `https://www.generationrobots.com/media/Pioneer3DX-P3DX-RevA.pdf`, (as of Aug. 2021).

[56] softbank, "pepper product page." `https://www.softbank.jp/robot/pepper/`, (as of Aug. 2021).

[57] T. Yamamoto, K. Terada, A. Ochiai, F. Saito, Y. Asahara, and K. Murase, "Development of Human Support Robot as the research platform of a domestic mobile manipulator," *ROBOMECH Journal*, vol. 6, no. 4, 2019.

[58] Microsoft, "Azure Kinect DK product page." https://azure.microsoft.com/ja-jp/services/kinect-dk/, (as of Aug. 2021).

[59] K. He, G. Gkioxari, P. Dollar, and R. Girshick, "Mask R-CNN," in *Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV)*, pp. 2980–2988, October 2017.

[60] R. Tsuzaki and K. Yoshida, "Motion Control Based on Fuzzy Potential Method for Autonomous Mobile Robot with Omnidirectional Vision," *Journal of the Robotics Society of Japanthe Robotics Society of Japan*, vol. 21, no. 6, pp. 676–682, 2003.

[61] T. Suzuki and M. Takahashi, "Obstacle Avoidance for Autonomous Mobile Robots Based on Position Prediction," in *Proceedings of 6th International Conference on Informatics in Control, Automation and Robotics (ICINCO)*, pp. 299–304, July 2009.

[62] T. T. Do, A. Nguyen, and I. Reid, "Affordancenet: An end-to-end deep learning approach for object affordance detection," in *2018 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 5882–5889, 2018.

[63] T. Lüddecke and F. Wörgötterr, "Fine-grained action plausibility rating," *Robotics and Autonomous Systems*, vol. 129, p. 103511, 2020.

[64] H. S. Koppula and A. Saxena, "Anticipating human activities using object affordances for reactive robotic response," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 1, pp. 14–29, 2016.

[65] J. Liang, L. Jiang, J. C. Niebles, A. G. Hauptmann, and L. Fei-Fei, "Peeking into the future: Predicting future person activities and locations in videos," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 5725–5734, 2019.

[66] F. Ziaeetabar, E. E. Aksoy, F. Wörgötter, and M. Tamosiunaite, "Semantic analysis of manipulation actions using spatial relations," in *2017 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 4612–4619, 2017.

[67] Y. Kawasaki, S. Mochizuki, and M. Takahashi, "Astron: Action-based spatio-temporal robot navigation," *IEEE Access*, vol. 9, pp. 141709–141724, 2021.

[68] C. Yu, Z. Liu, X. J. Liu, F. Xie, Y. Yang, Q. Wei, and Q. Fei, "Ds-slam: A semantic visual slam towards dynamic environments," in *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 1168–1174, 2018.

[69] Z. Hu, J. Zhao, Y. Luo, and J. Ou, "Semantic slam based on improved deeplabv3$^+$ in dynamic scenarios," *IEEE Access*, vol. 10, pp. 21160–21168, 2022.

[70] A. Thyagharajan, B. Ummenhofer, P. Laddha, O. J. Omer, and S. Subramoney, "Segment-fusion: Hierarchical context fusion for robust 3d semantic segmentation," in *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1226–1235, 2022.

[71] I. Armeni, Z. Y. He, A. Zamir, J. Gwak, J. Malik, M. Fischer, and S. Savarese, "3d scene graph: A structure for unified semantics, 3d space, and camera," in *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, pp. 5663–5672, 2019.

[72] L. Cordella, P. Foggia, C. Sansone, and M. Vento, "A (sub)graph isomorphism algorithm for matching large graphs," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 26, no. 10, pp. 1367–1372, 2004.

[73] A. Pandey, "Mobile Robot Navigation and Obstacle Avoidance Techniques: A Review," *International Robotics & Automation Journal*, 2017.

[74] S. G. Tzafestas, "Mobile Robot Control and Navigation: A Global Overview," *Journal of Intelligent & Robotic Systems*, 2018.

[75] A. R. Soltani, H. Tawfik, J. Y. Goulermas, and T. Fernando, "Path planning in construction sites: Performance evaluation of the dijkstra, a*, and GA search algorithms," *Advanced Engineering Informatics*, 2002.

[76] T. Kruse, A. K. Pandey, R. Alami, and A. Kirsch, "Human-aware robot navigation: A survey," *Robot. Auton. Syst.*, 2013.

[77] K. Charalampous, I. Kostavelis, and A. Gasteratos, "Recent trends in social aware robot navigation: A survey," *Robot. Auton. Syst.*, 2017.

[78] M. Sisbot, E.A.and L.F. and T. Alami, R.and Simeon, "A Human Aware Mobile Robot Motion Planner," *IEEE Transactions on Robotics*, 2007.

[79] J. Rios-Martinez, A. Spalanzani, and C. Laugier, "Understanding human interaction for probabilistic autonomous navigation using risk-RRT approach," *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2011.

[80] J. Rios-Martinez and A. Escobedo, "Intention Driven Human Aware Navigation for Assisted Mobility," *Workshop on Assistance and Service Robotics in a Human Environment at International Conference on Intelligent Robots and Systems*, 2012.

[81] T. Hirakawa, T. Yamashita, and H. Fujiyoshi, "Scene Context-aware Rapidly-exploring Random Trees for Global Path Planning," *IEEE International Conference on Pervasive Computing and Communications Workshops*, 2019.

[82] D. V. Lu, D. Hershberger, and W. D. Smart, "Layered costmaps for context-sensitive navigation," *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2014.

[83] M. Kollmitz, K. Hsiao, J. Gaa, and W. Burgard, "Time dependent planning on a layered social cost map for human-aware robot navigation," *European Conference on Mobile Robots*, 2015.

[84] J. V. Gómez, N. Mavridis, and S. Garrido, "Fast marching solution for the social path planning problem," *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2014.

[85] K. Dautenhahn, M. Walters, S. Woods, K. L. Koay, C. L. Nehaniv, E. A. Sisbot, R. Alami, and T. Siméon, "How may I serve you? A robot companion approaching a seated person in a helping context," *ACM/IEEE International Conference on Human Robot Interaction*, pp. 172–179, 2006.

[86] K. L. Koay, E. A. Sisbot, D. S. Syrdal, M. L. Walters, K. Dautenhahn, and R. Alami, "Exploratory study of a robot approaching a person in the context of handing over an object," *AAAI spring symposium: multidisciplinary collaboration for socially assistive robotics*, pp. 18–24, 2007.

[87] S. Satake, T. Kanda, D. F. Glas, M. Imai, H. Ishiguro, and N. Hagita, "How to approach humans?-Strategies for social robots to initiate interaction," *ACM/IEEE International Conference on Human Robot Interaction*, 2008.

[88] Y. Kato, T. Kanda, and H. Ishiguro, "May i help you?: Design of Human-like Polite Approaching Behavior," *ACM/IEEE International Conference on Human Robot Interaction*, 2015.

[89] K. Mizumaru, S. Satake, T. Kanda, and T. Ono, "Stop Doing it! Approaching Strategy for a Robot to Admonish Pedestrians," *ACM/IEEE International Conference on Human Robot Interaction*, 2019.

[90] Z. Cao, T. Simon, S.-E. Wei, and Y. Sheikh, "Realtime multi-person 2d pose estimation using part affinity fields," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1302–1310, 2017.

[91] CMU-Perceptual-Computing-Lab, "OpenPose." `https://github.com/CMU-Perceptual-Computing-Lab/openpose`. (as of Dec. 2022).

[92] K. Khoshelham and S. Elberink, "Accuracy and resolution of kinect depth data for indoor mapping applications," *SENSORS*, 2012.

[93] J. Lewis, *Microphone specifications explained*. Application Note 1112, Analog Devices, 2011.

[94] N. Vahrenkamp, T. Asfour, G. Metta, G. Sandini, and R. Dillmann, "Manipulability analysis," in *2012 12th IEEE-RAS International Conference on Humanoid Robots (Humanoids 2012)*, pp. 568–573, 2012.

[95] A. Magassouba, K. Sugiura, A. Nakayama, T. Hirakawa, T. Yamashita, H. Fujiyoshi, and H. Kawai, "Predicting and attending to damaging collisions for placing everyday objects in photo-realistic simulations," *Advanced Robotics*, vol. 35, no. 12, pp. 787–799, 2021.

[96] Y. Kawasaki and M. Takahashi, "Bottom-up action modeling via spatial factorization for serving food," *Advanced Robotics*, vol. 35, no. 12, pp. 756–770, 2021.

[97] A. Meurer, C. P. Smith, M. Paprocki, O. Čertík, S. B. Kirpichev, M. Rocklin, A. Kumar, S. Ivanov, J. K. Moore, S. Singh, T. Rathnayake, S. Vig, B. E. Granger, R. P. Muller, F. Bonazzi, H. Gupta, S. Vats, F. Johansson, F. Pedregosa, M. J. Curry, A. R. Terrel, v. Roučka, A. Saboo, I. Fernando, S. Kulal, R. Cimrman, and A. Scopatz, "Sympy: symbolic computing in python," *PeerJ Computer Science*, vol. 3, p. e103, Jan. 2017.

[98] M. Kosuge, Y. Ishihara, and M. Takahashi, "Body pressure prediction for pressure ulcer prevention in a bed head elevation operation," *Advanced Robotics*, vol. 35, no. 3-4, pp. 181–193, 2021.

[99] A. Secord, "Weighted voronoi stippling," in *Proceedings of the 2nd International Symposium on Non-Photorealistic Animation and Rendering*, NPAR '02, (New York, NY, USA), p. 37–43, Association for Computing Machinery, 2002.

[100] ROS.org, "gmapping." `http://wiki.ros.org/gmapping`. (as of Dec. 2022).

[101] ROS.org, "amcl." `http://wiki.ros.org/amcl`. (as of Dec. 2022).

[102] S. Yoon, A. Fern, and R. Givan, "Learning heuristic functions from relaxed plans," in *Proceedings of the Sixteenth International Conference on International Conference on Automated Planning and Scheduling*, ICAPS'06, p. 162–170, AAAI Press, 2006.

[103] Y. Xu, A. Fern, and S. W. Yoon, "Discriminative learning of beam-search heuristics for planning," in *IJCAI 2007, Proceedings of the 20th International Joint Conference on Artificial Intelligence, Hyderabad, India, January 6-12, 2007* (M. M. Veloso, ed.), pp. 2041–2046, 2007.

[104] C. R. Garrett, T. Lozano-Perez, and L. P. Kaelbling, "Ffrob: An efficient heuristic for task and motion planning," in *Workshop on the Algorithmic Foundations of Robotics*, 2015.

[105] B. Kim, Z. Wang, L. P. Kaelbling, and T. L. Pérez, "Learning to guide task and motion planning using score-space representation," *The International Journal of Robotics Research*, vol. 38, no. 7, pp. 793–812, 2019.

[106] A. M. Wells, N. T. Dantam, A. Shrivastava, and L. E. Kavraki, "Learning feasibility for task and motion planning in tabletop environments," *IEEE Robotics and Automation Letters*, vol. 4, no. 2, pp. 1255–1262, 2019.

[107] Y. Zhu, J. Tremblay, S. Birchfield, and Y. Zhu, "Hierarchical planning for long-horizon manipulation with geometric and symbolic scene graphs," in *2021 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 6541–6548, 2021.

[108] F. Lagriffoul, N. T. Dantam, C. Garrett, A. Akbari, S. Srivastava, and L. E. Kavraki, "Platform-independent benchmarks for task and motion planning," *IEEE Robotics and Automation Letters*, vol. 3, no. 4, pp. 3765–3772, 2018.

[109] L. Contreras, T. Yamamoto, Y. Matsusaka, and H. Okada, "Towards general purpose service robots: World robot summit — partner robot challenge," *Advanced Robotics*, vol. 36, no. 17-18, pp. 812–824, 2022.

[110] 杉浦孔明, "ロボカップ@ ホーム: 人と共存するロボットのベンチマークテスト," **人工知能**, vol. 31, no. 2, pp. 230–236, 2016.

# 謝辞

本研究は，著者が慶應義塾大学大学院理工学研究科後期博士課程在学中に，慶應義塾大学理工学部システムデザイン工学科髙橋正樹教授のご指導の下で行ったものです．

髙橋先生には，本研究を遂行するにあたり，多大なるご指導とご鞭撻を賜りました．ご多忙にも関わらず常日頃から親身に議論をさせていただくとともに，多角的な視点からのご指導いただくことで，ここまで研究を推進することができました．研究・学会活動・社会実装活動など数多くの成長の機会と貴重な経験を与えてくださり，筆者が髙橋研究室に在籍した 6 年間は，大変濃密で掛け替えのないものとなりました．この場を借りて改めて心より厚く御礼申し上げます．

本論文の執筆にあたり，慶應義塾大学理工学部，中澤和夫准教授，今井倫太教授，石上玄也准教授に数多くのご指摘，ご意見を頂きました．先生方との議論を通じて，改めて提案の本質を考え，本研究の主張や特徴を明確化することができ，本論文の説得力を向上させることができました．また，それぞれの先生の視点から本研究を見つめていただくことで，新たな側面に気づくことができました．主査の髙橋先生，副査の中澤先生，今井先生，石上先生にはご多忙にもかかわらず，本研究の提案について議論する機会を頂きましたことは，研究者として大変光栄であり，非常に刺激的な経験となりました．改めて感謝申し上げます．

筑波大学助教の萬礼応博士には，筆者が学部 4 年時から，研究活動の基本や魅力をご教示していただくとともに，御多忙にも関わらず親身に相談に乗ってくださいました．また，ロボットの研究・開発に共に取り組んでくださった貴重な経験が，筆者が博士後期課程進学を志すきっかけとなりました．改めて深く感謝の意を表します．

髙橋研究室のメンバー，とりわけ，研究室に在籍している間，切磋琢磨し，互いの研究について多くの議論をさせていただいた，江口僚氏，石原悠氏，小菅正道氏に感謝申し上げます．それぞれのメンバーの研究に対する哲学や精力的な活動には，感銘を受けるとともに励まされてきました．精力的なメンバーに囲まれて過ごした博士課程の期間は大変充実したものとなりました．改めて深く感謝の意を表します．

本研究の一部は，国立研究開発法人，科学技術振興機構 (JST)，戦略的創造研究推進事業 (CREST)，JPMJCR14E3，JPMJCR19A1 の支援を受けたものであり，ここに謝意を表します．

最後に，常に著者を陰で支え，応援してくれた家族と友人に深く感謝し，本論文の謝辞と致します．

2023 年 3 月

川崎陽祐

# 著者論文目録

## １．定期刊行誌掲載論文（主論文に関連する原著論文）

[1]. Yosuke Kawasaki, Shunsuke Mochizuki, Masaki Takahashi, “ASTRON: Action-Based Spatio-Temporal Robot Navigation”, IEEE Access, Vol.9, pp.141709-141724, 2021.

[2]. Yosuke Kawasaki, Ayanori Yorozu, Masaki Takahashi, Enrico Pagello, “A multimodal path planning approach to human robot interaction based on integrating action modeling”, Journal of Intelligent & Robotic Systems, Vol.100, No.3, pp.955–972, 2020.

## ２．定期刊行誌掲載論文（その他の論文）

[1]. Yosuke Kawasaki, Masaki Takahashi, Bottom-up action modeling via spatial factorization for serving food, Advanced Robotics, Vol. 35, Issue 12, pp.756–770, 2021.

## ３．国際会議論文（査読付きの **full-length papers**）

[1]. *Shunsuke Mochizuki, Yosuke Kawasaki, Masaki Takahashi, “ProTAMP: Probabilistic Task and Motion Planning Considering Human Action for Harmonious Collaboration”, The 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2022), Kyoto, October 2022 (Oral presentation).

[2]. *Yosuke Kawasaki, Masaki Takahashi, “Spatio-Temporal Action Order Representation for Mobile Manipulation Planning”, 31st IEEE International Conference on Robot & Human Interactive Communication (IEEE RO-MAN 2022) , Napoli, September 2022 (Oral presentation).

[3]. *Yosuke Kawasaki, Masaki Takahashi, “World state-Dependent Action Graph: a representation of action possibility and its variations in real space based on world state”, 19th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2022) , Lisbon, July 2022 (Oral presentation).

[4]. *Miyuki Nakamura, Yosuke Kawasaki, Masaki Takahashi, “Physics-Based Motion Planning of a Fruit Harvesting Manipulator for Pushing Obstacles in a Cluttered Environment”, 17th International Conference on Intelligent Autonomous Systems (IAS-17), Zagreb, June 2022 (Oral presentation).

[5]. *Fumiya Onishi, Yosuke Kawasaki, Masaki Takahashi, “Goal Inference via Corrective Path Demonstration for Human-robot Collaboration”, 17th International

Conference on Intelligent Autonomous Systems (IAS-17), Zagreb, June 2022 (Oral presentation).

[6]. *Yosuke Kawasaki, Ayanori Yorozu, and Masaki Takahashi, “Autonomous Navigation using Multimodal Potential Field to Initiate Interaction with Multiple People”, The 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS2018), pp 7654-7659, Madrid, October 2018 (Oral presentation).

[7]. *Yosuke Kawasaki, Ayanori Yorozu, Masaki Takahashi, “Multimodal path planning using potential field for human-robot interaction”, 15th International Conference on Intelligent Autonomous Systems (IAS-15), pp 597-609, Baden-Baden, June 2018 (Oral presentation).

## ４．その他の国際会議発表

なし

## ５．国内学会発表

[1]. *大西史弥, 川崎陽祐, 髙橋正樹, ユーザの修正経路教示に基づく協働搬送ロボットの目的地推論, ロボティクス・メカトロニクス 講演会 2022 (ROBOMECH 2022), 札幌, 2022 年 6 月 2 日発表済.

[2]. *川崎陽祐, 髙橋正樹, シーングラフを用いた知識表現に基づく世界状態を考慮したアクショングラフ, ロボティクス・メカトロニクス 講演会 2022 (ROBOMECH 2022), 札幌, 2022 年 6 月 2 日発表済.

[3]. *土屋碧渡、川崎陽祐、渡邊悠太、佐藤夏樹、福地庸介、松森匠哉、前川知行、髙橋正樹、今井倫太、買い物支援ロボットに向けた実世界における信念と欲求の逐次推定モデルの検討、第 84 回情報処理学会全国大会、松山市、2022 年 3 月 3 日発表済.

[4]. *土屋碧渡、川崎陽祐、渡邊悠太、佐藤夏樹、福地庸介、松森匠哉、前川知行、髙橋正樹、今井倫太、アクショングラフを用いて位置情報をもとにした信念と欲求の推定システム、クラウドネットワークロボット研究会（CNR)、オンライン開催、2021 年 9 月 21 日発表済.

[5]. *仲村美幸、川崎陽祐、髙橋正樹、果実収穫用マニピュレータの能動的接触動作のための物理ベース運動計画、第 39 回日本ロボット学会学術講演会、オンライン開催、2021 年 9 月 10 日発表済.

[6]. *佐藤夏樹、川崎陽祐、髙橋正樹、ロボットの行動可能性に基づいた自然言語指示の目標状態推定、第 39 回日本ロボット学会学術講演会、オンライン開催、2021 年 9 月 10 日発表済.

[7]. *川崎陽祐、望月駿介、髙橋正樹、多層アクショングラフを用いた行動計画、第 38 回日本ロボット学会学術講演会、オンライン開催、2020 年 10 月 10 日発表済.

[8]. *川崎陽祐、萬礼応、髙橋正樹、Hybrid A* アルゴリズムによる円滑な複数タスク実行のための経路計画、第 37 回日本ロボット学会学術講演会、新宿区、2019 年 9 月 6 日発表済.

[9]. *萬礼応、川崎陽祐、髙橋正樹、森田武史、山口高平、複数台ロボットによる喫茶店業務実践と評価、第 37 回日本ロボット学会学術講演会、新宿区、2019 年 9 月 5 日発表済.

[10]. *川崎陽祐、萬礼応、髙橋正樹、ロボットによる運搬のためのワゴンの位置・姿勢推定、第 36 回日本ロボット学会学術講演会、春日井市、2018 年 9 月 7 日発表済.

[11]. *八尋博士、川崎陽祐、ロボット活動を通じた自由なモノづくりの実践例 〜IoT としてのクリスマス・イルミネーション〜、第 11 回科学技術におけるロボット教育シンポジウム、千代田区、2018 年 7 月 21 日発表済.

[12]. *川崎陽祐、萬礼応、髙橋正樹、ヒューマンロボットインタラクションのためのポテンシャル場を用いたマルチモーダル経路計画、ロボティクス・メカトロニクス 講演会 2018 (ROBOMECH 2018)、北九州、2018 年 6 月 5 日発表済.

## 6．その他

＜賞罰＞

[1]. HSR コミュニティ研究奨励賞, 日本ロボット学会インテリジェントホームロボティクス研究専門委員会, 2022 年 3 月 24 日