

# 三次元空間における相対位置概念の学習

## Learning in Relative Spatial Concept of Three-dimensional Space

谷志翔\*1  
Zhixiang Gu

田口亮\*1  
Ryo Taguchi

服部公央亮\*2  
Koosuke Hattori

保黒政大\*2  
Masahiro Hoguro

梅崎太造\*1  
Taizo Umezaki

\*1 名古屋工業大学  
Nagoya Institute of Technology

\*2 中部大学  
Chubu University

Spatial concept is widely used in daily life. Of the cognition process in human and human interaction, an instructor can directly locate the target and the reference object, and express the certain spatial relationship between objects to instructed person by using joint attention. However, it is not easy for a service robot to recognize the action for joint attention from user in human-robot communication. Instead, the robot need to comprehend the instruction of the user from the co-occurrence information of an utterance and the context including multiple spatial relationships between target and other objects. The desired concept forming by the utterance of user and the corresponding spatial relationship, called relative spatial concept. This paper proposes a learning method with single reference based model (SRM) for relative spatial concept in three-dimensional space through human-robot interaction, which can learn concepts by estimating the most likely reference object of human. And the other, we proposed another model, named multiple referable objects based model (MRM) which by inference of each referable object to improve the accuracy of estimation.

### 1. はじめに

位置概念は物体間の位置関係の表現として、我々の日常生活で広く使用されている。例えば、ものを探す場面では、話し手と聞き手が対象の物体と周辺にある物体の位置関係を理解し、空間用語で明示しなければならない。サービスロボットにとって、位置概念を理解する能力は人との協調を実現するために非常に重要である。「前、後、左、右、上、下」といった空間用語と対応された位置関係は位置概念の認知過程を構成する。位置概念を表現する用語は対象と少なくとも1つの参照物に依存する [Landau 93][Miller 76]。即ち、位置概念を理解するためには参照物を指定する必要がある。人と人のインタラクションでは、指差しや視線、文脈などの情報を用いて参照物を推定する。しかし、ロボットがそれを理解することは困難である。人の顔の向きから対象の物体を推定する手法も開発されているが、人と向かい合っている場面だけに適用可能な技術である [Doniec 06]。人とのインタラクションを通して、指定された参照物を直接的に理解することは難しい。従って、位置概念を学習する場合には、各場面に存在する複数の物体の相対位置関係から自動的に参照物を推定しながら、学習を進める手法が必要である。本稿では、これを相対的な位置概念の学習と呼ぶ。

近年、単語の表す意味概念をロボットの感覚・運動系の信号と対応付けて学習させる研究が行われている。先行研究の多くは、単語と共起するセンサ情報を概念として直接的に学習している。しかし、相対的な位置概念の学習には指示対象と参照物との比較により表されるため、対象から直接的に得られる特徴のみでは学習できない。羽岡らが提案した手法では、参照点(参照物の重心位置)に依存する動作を、2次元空間上の相対的な軌道として学習した [羽岡 00]。しかし、また、同一場面に存在する参照点候補の配置や数が学習に与える影響については議論されていない。

本稿では、人が発話した空間用語及び指示対象と参照物の相対特徴の共起情報を用いて三次元空間における相対位置




図1 現実世界の教示環境

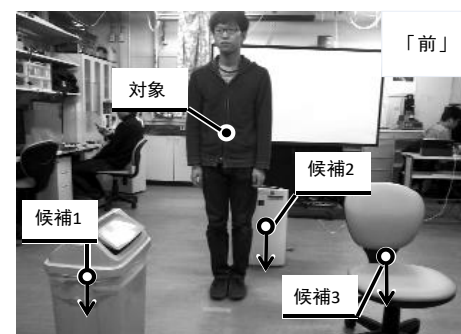


図2 ロボットの学習データ

概念を学習する手法を提案するとともに、環境中の物体の配置や数が学習に与える影響を論じる。

### 2. 提案手法

#### 2.1 タスク設定

本研究で取り扱うタスクは、ユーザがある対象をロボットに教示し、対象が持つ相対的な特徴をロボットに学習させるというものである。本実験で扱う教示は、特徴と共に方向を表す概念「前、後、左、右、上、下」のラベルを与えることで行う。ここで、教示ラベルを $w$ 、対象の三次元空間における特徴を $x^n$ とする。 $n$ は学習サンプルのインデックス( $1 \leq n \leq N$ ,  $N$ は学習サンプル数)である。また、概念の比較対象となる物体を $k$ とする。物体 $k$ を基準とした

相対的特徴量を $\mathbf{x}_k^n$ と表す.各場面における指示対象と各物体の位置と向きは既知とするが,物体のいずれかが真の参照物(ユーザーが意図している参照物)なのかは未知である. 相対特徴を実世界を例にして説明する. 図 1 に示す三次元空間内の配置で物体 1~3 が与えられ, ロボットの視点(図 2)から, 指示対象(この例では人)の重心と, 各物体の重心を抽出する. 各物体の重心を原点とした相対座標系における指示対象の位置が学習候補の相対特徴量 $\mathbf{x}_1^n \sim \mathbf{x}_3^n$ となる, ただし, 各座標系の向きは, 各物体が持っているものとする. 図 2 の場面で, 教示者は候補 2 を選択し, 「前」と教示する. この時, ロボットには選択された参照物の情報は与えられないため, 3 つの候補から, 正しい参照物を推定しながら, 「前」の位置関係を表現する確率モデルのパラメータ $\Psi_{front}$ を学習していく. このように, 本タスクでは, 複数の相対的な位置関係や向きを既知, 真の参照物を未知とした条件下で, 与えられた概念ラベルが意味する相対位置分布を学習する.

## 2.2 参照物となる物体を一つ推定するモデル (SRM: Single Reference Model)

文献[Kojima 08]から, 位置関係の表現が方向を表す角度値と距離値に依存することがわかる. そのため, 提案手法では, 対象と参照物間の特徴量を角度と距離に分け, それぞれを確率分布で表現する. 物体 $k$ から対象への方向ベクトル $\theta_k^n$ と距離 $r_k^n$ を用いると, ロボットの相対特徴量は $\mathbf{x}_k^n = (\theta_k^n, r_k^n)$ と表せる. 教示ラベル $w$ と相対特徴量の対応関係を, 平均方向ベクトル $\mu_{v_w}$ , 集中度パラメータ $\kappa_w$ の von Mises-Fisher 分布,

$$f_p(\theta|\mu_{v_w}, \kappa_w) = C_p(\kappa_w) \exp(\kappa_w \mu_{v_w}^T \theta) \quad (1)$$

$$C_p(\kappa_w) = \kappa_w^{p-1} / [(2\pi)^{p/2} I_{p-1}(\kappa_w)] \quad (2)$$

と, 平均距離 $\mu_N$ と分散 $\sigma^2$ の正規分布,

$$\mathcal{N}(r|\mu_N, \sigma^2) = \exp[-(r - \mu_N)^2 / (2\sigma^2)] / \sqrt{2\pi\sigma^2} \quad (3)$$

でモデル化する. ただし, von Mises-Fisher 分布の正規化係数 $C_p(\kappa)$ は式(2)になる.  $I_p$ は $p$ 次の第一種変形ベッセル関数である. 本研究では三次元空間を扱うため,  $p = 3$ と定義する. 今回教示する概念は方向にのみ依存するため, von Mises-Fisher 分布のパラメータには, 添字としてラベル $w$ が付与されている. 一方で, 距離は方向概念に依存せず, 参照物の選択にのみ影響を与えるとし, 正規分布のパラメータは全場面に共通とした. ユーザーが指示した方向と, 対象と参照物との距離は互いに独立であるため, 教示された相対位置関係は, 方向分布と距離分布の積として表現できる.

$$P(\mathbf{x}|\varphi_{0_w}, \kappa_w, \mu_N, \sigma^2) = f_p(\varphi|\varphi_{0_w}, \kappa_w) \mathcal{N}(r|\mu_N, \sigma^2) \quad (4)$$

更に, 学習サンプル $n$ において, 物体 $k$ が参照物である確率を $\pi_k^n$ , その集合を $\boldsymbol{\pi}$ とおく. また, サンプル $n$ における物体数を $K_n$ とすると, 各サンプルにおける参照確率は $\sum_{k=1}^{K_n} \pi_k^n = 1$ となる. 目的関数は式(5)のような対数尤度関数として表現する.

$$l(\Psi) = \sum_n \log \sum_k \pi_k^n P(\mathbf{x}_k^n|\mu_{v_w}, \kappa_w, \mu_N, \sigma^2) \quad (5)$$

目的関数のパラメータは $\Psi = (\boldsymbol{\pi}, \mu_{v_w}, \kappa_w, \mu_N, \sigma^2)$ となる. 対数尤度を最大化するパラメータをEMアルゴリズムにより求める. 参照確率の初期値は, 全ての物体を等確率に設定する. EMアルゴリズムで用いる各パラメータの更新式は式(6)~(11)となる. それぞれ, 式(6)は参照確率, 式(7), (8)は方向分布の平均ベクトルと集中度パラメータの関数, 式(9), (10)は距離分布の平均と分散の更新式である. 集中度パラメータの関数 $A(\kappa)$ は第一種変形ベッセル関数の導関数に定義できる.  $\kappa$ は $A(\kappa)$ の逆関数として数値解析的に求めることができる. 本研究では, 式(11)のよう




図3 参照物となりうる複数物体を考慮するモデル

に,  $A(\hat{\kappa})$ から $\hat{\kappa}$ の近似値を導出する[Dhillon 03].

$$\hat{\pi}_k^n = \frac{\pi_k^n P(\mathbf{x}_k^n|\mu_{v_w}, \kappa_w, \mu_N, \sigma^2)}{\sum_j \pi_j^n P(\mathbf{x}_j^n|\mu_{v_w}, \kappa_w, \mu_N, \sigma^2)} \quad (6)$$

$$\hat{\mu}_{v_w} = \frac{\sum_n \sum_k \hat{\pi}_k^n \theta_k^n}{\|\sum_n \sum_k \hat{\pi}_k^n \theta_k^n\|} \quad (7)$$

$$A(\hat{\kappa}_w) = \frac{\sum_n \sum_k \hat{\pi}_k^n \hat{\mu}_{v_w}^T \theta_k^n}{N} \quad (8)$$

$$\hat{\mu}_N = \frac{\sum_n \sum_k \hat{\pi}_k^n r_k^n}{N} \quad (9)$$

$$\hat{\sigma}^2 = \frac{\sum_n \sum_k \hat{\pi}_k^n (r_k^n - \hat{\mu}_N)^2}{N} \quad (10)$$

$$\hat{\kappa}_w \cong \frac{3A(\hat{\kappa}_w) - A(\hat{\kappa}_w)^3}{1 - A(\hat{\kappa}_w)^2} \quad (11)$$

## 2.3 参照物となりうる複数の物体を考慮するモデル (MRM: Multiple Referable objects Model)

参照物となる物体を1つ推定するモデル (SRM)では, 各場面において1つの参照物を推定しながら, 確率分布を学習する. しかし, 実環境では, 環境中に参照物の候補となる物体が多く存在する. ユーザーは, 1つの対象と, 1つの参照物を選択し, 相対位置概念を教示するが, 多くの物体が存在する場面では, 選択された参照物以外の物体も学習結果に影響を与える. von Mises-Fisher 分布は単峰であるため, 平均ベクトルに近い物体が参照物として選択されやすくなる. 例えば, ある概念の真の方向分布の平均に近い位置に物体 A が配置されており, それよりも離れた位置に真の参照物 B が配置されている場合, 物体 A の方が高い参照確率になる. そのため, 繰り返し最適化により推定される方向分布は徐々に狭くなる (集中度パラメータ $\kappa_w$ が高くなる). この問題は, その概念の方向分布の下では, 物体 A, B どちらの物体を参照物としても, その概念が使用可能であるが, SRM ではそのどちらか一方を選択しようとするために生じる.

そこで, 学習中の分布に基づいて, 各場面で参照物となりうる物体を複数推定するモデルを提案する. 提案手法のグラフィカルモデルを図3に示す. まず, 各物体が学習中の分布の下, 参照可能であるか否かを表す変数 $c_{s,k}$ を導入する. 物体 $k$ の参照状態 $c_{s,k}$ が1の場合に参照可能, 0の場合に無関係とする. サンプル $n$ に $K_n$ 個物体が存在すると, 参照状態の組合せ数は $S_n = \sum_{k=0}^{K_n} \binom{K_n}{k}$ となる.  $s$ は参照状態の組合せのいずれかを表すインデックスである. ある場面で, 参照物の候補として2つ物体が存在する場合, 参照状態の組合せは, 全て無関係(0,0), 物体1が参照可能(1,0), 物体2が参照可能(0,1), 全て参照可能(1,1)の4通りとなる. 指示対象の相対位置は, 参照可能の状態を持つ物体を原点とした場合には, 概念 $w$ に依存したパラメータ $\mu_{v_w}, \kappa_w$

の分布に従い、無関係の物体を原点とした場合にはパラメータが $\mu_{v_u}, \kappa_u$ の分布に従うものとする。 $\mu_{v_u}, \kappa_u$ の分布としては、例えば一様分布などが想定される。図3の $C$ は、分布の添字 $w$ 、または $u$ を表す。方向分布推定の目的関数は、

$$l(\Psi_V) = \sum_N \log \sum_S^n z_S^n P(\theta_{1:K_n}^n | \mu_{v_w}, \kappa_w, \mu_{v_u}, \kappa_u, c_{S,1:K_n}^n, \pi_{1:K_n}^n) \quad (12)$$

$$P(\theta_{1:K_n}^n | \mu_{v_w}, \kappa_w, \mu_{v_u}, \kappa_u, c_{S,1:K_n}^n, \pi_{1:K_n}^n) = \prod_k^{K_n} \{ c_{S,k}^n \pi_k^n f_p(\theta_k^n | \mu_{v_w}, \kappa_w) + (1 - c_{S,k}^n) f_p(\theta_k^n; \mu_{v_u}, \kappa_u) \} \quad (13)$$

となる。ただし、 $z_S^n$ は参照状態の組合せに付けられる重みで、 $\sum_S^n z_S^n = 1$ とする。また、距離分布推定の目的関数は、

$$l(\Psi_N) = \sum_n \log \sum_k^{K_n} \pi_k^n N(r_k^n | \mu_N, \sigma^2) \quad (14)$$

$$(\Psi_N^*, \Psi_V^*) = \operatorname{argmax}_{\theta, \mu} (l(\Psi_N), l(\Psi_V)) \quad (15)$$

となる。EM アルゴリズムにより各目的関数を最大化するパラメータを求める。各パラメータの更新式を式(16)~(21)に示す。

$$\hat{\pi}_k^n = \frac{\pi_k^n P(r_k^n | \mu, \sigma^2)}{\sum_j^{K_n} \pi_j^n P(r_j^n | \mu, \sigma^2)} \quad (16)$$

$$\hat{\mu} = \frac{\sum_n \sum_k^{K_n} \hat{\pi}_k^n r_k^n}{N} \quad (17)$$

$$\hat{\sigma}^2 = \frac{\sum_n \sum_k^{K_n} \hat{\pi}_k^n (r_k^n - \hat{\mu}_N)^2}{N} \quad (18)$$

$$\hat{z}_S^n = \frac{z_S^n P(\theta_{1:K_n}^n | \mu_{v_w}, \kappa_w, \mu_{v_u}, \kappa_u, c_{S,k}^n, \hat{\pi}_k^n)}{\sum_j^{S_n} z_j^n P(\theta_{1:K_n}^n | \mu_{v_w}, \kappa_w, \mu_{v_u}, \kappa_u, c_{S,k}^n, \hat{\pi}_k^n)} \quad (19)$$

$$\hat{\mu}_{v_w} = \arctan\left(\frac{\sum_n \sum_S^n z_S^n \sum_k^{K_n} c_{S,k}^n \theta_k^n}{\|\sum_n \sum_S^n z_S^n \sum_k^{K_n} c_{S,k}^n \theta_k^n\|}\right) \quad (20)$$

$$A(\hat{\kappa}_w) = \frac{\sum_n \sum_S^n z_S^n \sum_k^{K_n} c_{S,k}^n \hat{\mu}_{v_w}^T \theta_k^n}{\sum_n \sum_S^n z_S^n \sum_k^{K_n} c_{S,k}^n} \quad (21)$$

表1 概念に依存した方向分布の真のパラメータ

空間用語	X軸とのなす角 $\theta_x [^\circ]$	Z軸とのなす角 $\theta_z [^\circ]$	集中度 $\kappa$
まえ	0	90	20
うしろ	180	90	
みぎ	270	90	
ひだり	90	90	
うえ	0	0	
した	0	180	

表2 概念に依存した距離分布の真のパラメータ

(各用語)	平均 $\mu[m]$	分散 $\sigma^2[m]$
	0.5	0.15

表3 無関係な物体の生成パラメータ

X軸とのなす角 $\theta_x [^\circ]$	[0,360]
Z軸とのなす角 $\theta_z [^\circ]$	[0,180]
距離 $r[m]$	[0,5]

### 3. 実験と考察

#### 3.1 実験条件

シミュレーションにより提案手法の評価を行う。実験では物体数を3, 6, 9個のいずれかに固定する。参照可能となる物体数はランダムに決定する。参照可能物体と指示対象の相対方向と距離は、教示する概念の真の分布に従い生成する。無関係となる物体については事前に設定した確率分布に従い生成する。教示する概念と設定した分布のパラメータを表1に示す。ロボットには、その概念のラベルと、指示対象の位置、および物体の位置と向きを学習サンプルとして与える。学習サンプル毎に物体の配置を変更する。1概念につき学習サンプル数 $N$ は30とした。これにより、教示環境の複雑度が学習に与える影響を調査する。学習に用いるモデルは、(1)参照物となる物体を一つ推定するモデル(SRM)、(2)参照物となりうる複数の物体を考慮するモデル(MRM)、(3)MRMから距離分布を除いたモデルの3種類とする。

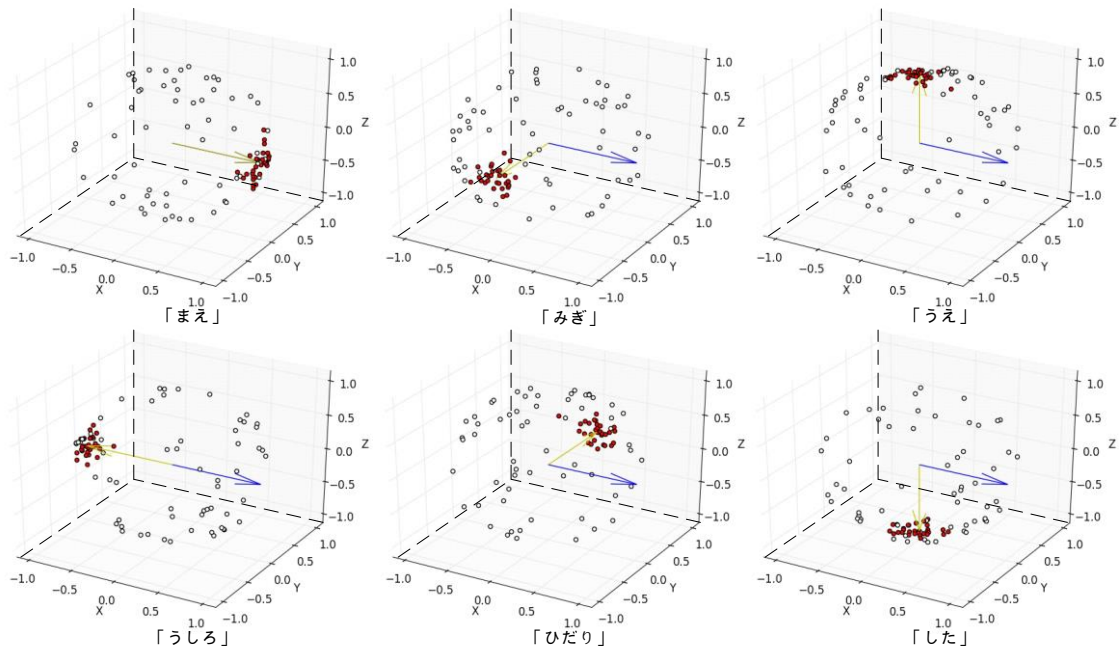


図4 三次元空間における相対位置の推定結果

### 3.2 実験結果

物体数を3個とした場合のSRMの学習結果の例を図4に示す。サンプル数が30であるため、1つの概念の学習に用いられる相対位置は90点となる。図は、それらの相対位置を、距離値を1とした三次元極座標上にプロットしている。青の矢印は物体の向き、黄色の矢印は学習された角度分布の平均ベクトルを表す。また、各場面で参照確率が最大となった物体からの相対位置を赤の点で示す。この結果から、各概念に対応する方向分布が正しく推定されたことが確認できる。

学習されるパラメータの精度を評価するため、各複雑度の教示を200回繰り返した。学習結果の一例として、「まえ」を学習して得られたパラメータの平均と標準偏差を図5~7に示す。なお、方向分布の平均ベクトルを、X軸の正の向きとのなす角 $\theta_x$ 及びZ軸の正の向きとのなす角 $\theta_z$ に変換したものを示す。教示の際に設定した「まえ」の真のパラメータは $\theta_x = 0$ ,  $\theta_z = 90$ ,  $\kappa = 20$ である。まずSRMとMRMを比較する。SRMは、平均ベクトル( $\theta_x$ ,  $\theta_z$ )の推定が、環境の複雑度に依存せず安定して行える。しかし、集中度パラメータ $\kappa$ は複雑度が増加するにつれ大きくなるのがわかる。これは、2.3節で説明したように、SRMでは真の参照物が常に1つとなるものとして学習を進めることで分布が狭くなることを表す。一方で、MRMは、環境の複雑度に依存せず真の $\kappa$ に近い値が推定されている。 $\theta_x$ の推定結果の標準偏差がSRMと比較して大きくなるのは、推定される $\kappa$ が小さく、平均値がずれやすいためであると考えられる。この結果から、参照物となりうる物体を複数推定するモデルの有効性が確認できた。

次にMRMと、距離分布を用いないMRM(図中MRM w/o distance)の結果を比較する。距離分布を用いない場合、複雑度の増加に従い、 $\kappa$ が真の値よりも小さくなる(分布が広がる)傾向が見られる。また、 $\theta_x$ の標準偏差はMRMよりも大きくなる。参照状態の組合せが増えた場合に多くの局所解が発生することにより、パラメータの推定結果のバラつきや、 $\kappa$ の減少が生じると考えられる。MRMは距離分布を用いることで、「参照物として選択されやすい物体の距離」を学習することができるため、参照状態の組合せが増えた場合でも安定して動作する。この結果から、距離分布を用いることの有効性が確認できた。

### 4. まとめ

本稿では、三次元空間における相対的な位置概念の学習手法を提案した。提案手法では、参照物から指示対象の相対的な特徴量を方向と距離にわけ、von Mises-Fisher分布と正規分布で表現する。参照物となる物体を一つ推定するモデル(SRM)は、場面における最適な参照物を推定しながら、相対位置概念の確率分布を学習する。参照可能な物体が少ない環境では、この手法が有効である。しかし、物体が多く存在する環境では、どちらの物体を参照物として選択しても、同じ位置概念で表現可能な場合がある。このような複雑度の高い環境では、SRMは方向分布の平均に近い物体を参照物として推定し、その結果を用いて方向分布を修正していくため、分布が狭くなる傾向がある。そこで、参照物となりうる物体を複数推定するモデル(MRM)を提案した。実験から、MRMを用いることで環境の複雑度を与える悪影響を抑制できることが確認された。

人と人のインタラクションで位置概念の教示を実現するには、人は体の向きや視線、指差し、視覚的な顕著性などのマルチモーダル情報や、発話の目的や対話の履歴などのコンテキスト情報を参照物推定の手がかりとして利用することで、環境内に無数に存在する物体から参照物となる候補を数個程度に絞り込むことができる。今後は、これらの情報を用いた参照物の推定過程をモデルに組み込むことで、実環境での学習を実現したい。

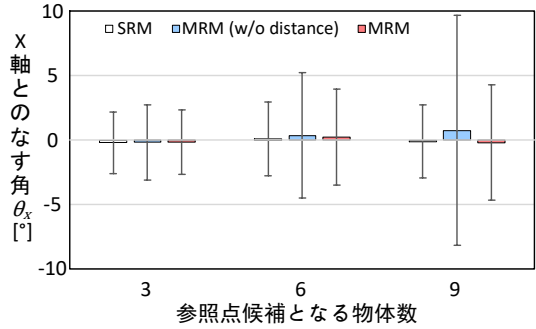


図5 学習された「まえ」のパラメータ $\theta_x$ の比較

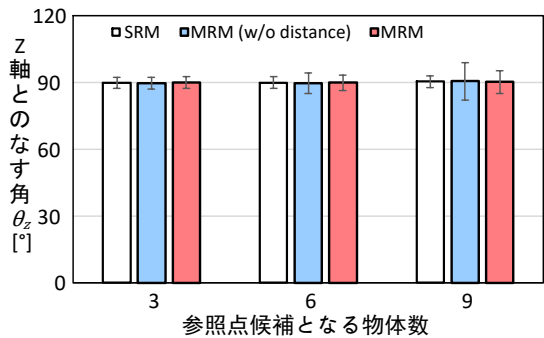


図6 学習された「まえ」のパラメータ $\theta_z$ の比較

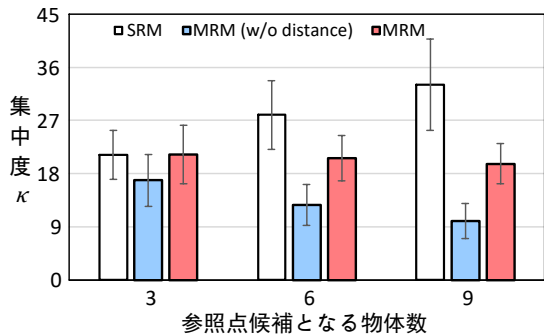


図7 学習された「まえ」のパラメータ $\kappa$ の比較

### 参考文献

- [Landau 93] B. Landau, R. Jacknedoff: "what" and "where" in spatial language and spatial cognition, Behavioral and Brain Sciences, 16, pp. 217-265, 1993.
- [Miller 76] G. A. Miller, P. N. Johnson-Laird: Language and perception, Belknap Press, Cambridge, 1976.
- [Doniec 06] M. W. Doniec, G. Sun, and B. Scassellati: Active learning of joint attention, Humanoid Robots, 2006 6<sup>th</sup> IEEE-RAS International Conference, pp. 34-39, 2006.
- [羽岡 00] 羽岡哲郎, 岩橋直人: 言語獲得のための参照点に依存した空間的移動の概念の学習, 電子情報通信学会技術研究報告 PRMU2000-105, pp.39-46, 2000.
- [Kojima 08] T. Kojima, T. Kusumi: Spatial term apprehension with a reference object's rotation in three-dimensional space, Cogn Process, 9(2), pp. 107-19, 2008
- [Dhillon 03] S. Dhillon, S. Sra.: Modeling data using directional distributions, Technical Report TR-03-06, Department of Computer Sciences, University of Texas at Austin, Austin, 2003.