

影で形を計測する：時間差を利用したロボットセンサの位置推定

杉浦 孔明^{†‡}, 松原 大輔[†], 片井 修[†]

[†] 京都大学大学院 情報学研究科

[‡] ATR 音声言語コミュニケーション研究所

Construction of Robotic Body Schema based on TDOA

Komei Sugiura^{†‡}, Daisuke Matsubara[†], Osamu Katai[†]

[†] Graduate School of Informatics, Kyoto University

[‡] ATR Spoken Language Communication Research Laboratories

Abstract: This paper proposes a method that incrementally develops the “body schema” of a robot. The method has three features: 1) estimation of light-sensor positions based on the Time Difference of Arrival (TDOA) of signals and multidimensional scaling (MDS); 2) incremental update of the estimation; and 3) no additional equipment. We carried out simulation experiments in which a mobile robot moves around environments or follows another robot. Each robot has several light sensors that collect data from which cross-correlation functions are derived and the TDOA is computed. Experimental results show that our method can estimate the positions of sensors deployed on the body and identify the sensors on the same part of the body.

Keywords: embodiment, robotic body schema, localization, incremental mapping, cross-correlation

1. はじめに

身体図式とは、身体の各部位に関する無意識的表象であり、模倣や空間認知などに必要であると考えられている。近年の研究によって、身体図式の可塑性が明らかになってきた [4, 7]。いかにすれば、このような適応的な身体モデルをロボットに持たせることができるのだろうか？

従来のロボット研究では、設計者がロボットの形態に関するモデルを与えることが多い。しかし、形態が変化あるいは劣化するようなロボットを扱う場合には、身体モデルを自己組織的に獲得することが望ましい。このような背景から、ロボットの身体上に設置されたセンサ位置の推定 [3, 6] や、ロボットにおける身体図式の拡張 [5, 9] について研究が行なわれている。

他方、ロボットの位置推定 [8, 10] やセンサノードの位置推定 [1, 11] については、様々な手法が提案されている。ここで、ロボット身体図式の獲得を「身体上でのセンサ位置推定」として捉えれば、地表面上でのマッピングを身体上でのマッピングに置き換えることで、同様の手法を利用できることが想像される。

本論文では、信号到達時間差 (TDOA) と多次元尺度構成法 (MDS) に基づき、ロボットの表面に設置したセンサの位置を推定する手法を提案する。ここで本論文では、「ロボット身体図式」を相対スケールでのセンサ位置と定義する。本手法の独自性は、データから時間情報を TDOA の形で抽出することである。これにより、位置推定を逐次的に行ない、可塑的なロボット身体図式を得ることができる。

ヒトの身体図式はマルチモーダルな感覚入力によって構築されることが知られている [7]。これに対し本研究では、ロボット身体図式を光センサのデータをもとに構築する。この理由は、1) 実装のしやすさ、2) 工学的応用、3) 統計処理のしやすさ、の3点による。すなわち、ロボッ

トの身体表面上にタッチセンサや圧力センサを設置した場合、疎なデータが生成されることが多い。これに対し光センサでは、ロボットの姿勢が変わるだけでデータが変化し得るため、統計処理が容易である。

2. TDOA に基づく身体図式獲得

2.1 提案手法の概要

提案する手法の概略を Fig. 1 に示す。本手法は 2 つのモジュール、Similarity Extraction Module (SEM) および Incremental Mapping Module (IMM) から構成される。まず、SEM がセンサ入力間の相互相関を計算し、次に IMM がセンサの位置を逐次推定する。

本手法の特徴は、ロボットの動きに従ってできる影を利用する点である。Fig. 2 に示すように、ロボットの動きに従い、センサは物体や自身によって遮蔽されるので、センサ値に変化が生まれる。本手法は、この変化の信号到達時間差 (TDOA) からセンサ位置を推定させる。

以下では、各モジュールについての詳細な説明を行う。

2.2 Similarity Extraction Module

本モジュールは相互相関関数を利用して、各センサが受信するセンサデータの類似度およびセンサ間の相対距離を推定する。相互相関関数とは、時系列 $X_i(t)$ と時刻を Δt だけシフトした別の時系列 $X_j(t - \Delta t)$ との相関係数を Δt の関数とみなしたものである。本研究では相互相関関数を以下の式で定義する。

$$R_{ij}(t, \Delta t) = \frac{C_{ij}(t, \Delta t)}{\sqrt{C_{jj}(t, \Delta t)C_{ii}(t, 0)}}, \quad (1)$$

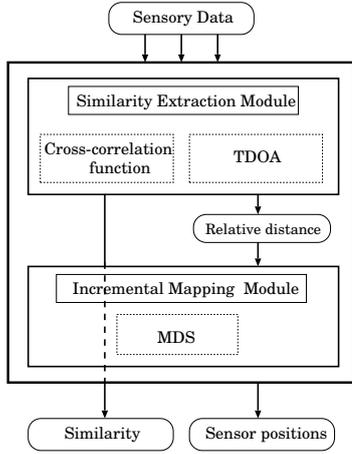


Figure 1: Schematic of method

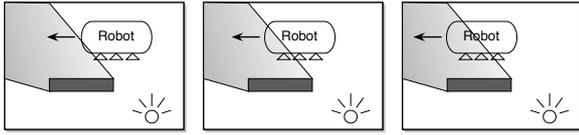


Figure 2: Shadow casted on a robot moving left. Each triangle represents a light sensor.

ここで C_{ij} は相互共分散関数であり、以下の式で表される。

$$C_{ij}(t, \Delta t) = \frac{1}{w} \sum_{t=0}^{w-1} (X_i(t) - \bar{X}_i)(X_j(t - \Delta t) - \bar{X}_j), \quad (2)$$

ただし、 w はデータ数であり、 \bar{X}_i , \bar{X}_j は対応する区間における X_i , X_j の平均値を表す。いま、時刻 t において Δt を $-T$ から T まで変化させたときの最大値 $R_{ij}(\Delta t)$ について考え、

$$\Delta T_{ij} = \operatorname{argmax}_{\Delta t} R_{ij}(t, \Delta t), \quad (3)$$

$$\mathbf{f}_i = [\Delta T_{1i}, \Delta T_{2i}, \dots, \Delta T_{ni}]^T, \quad (4)$$

となる ΔT_{ij} , \mathbf{f}_i を計算する。ただし T は定数とする。

信号源が等速で移動するとすると、 \mathbf{f}_i はセンサ i と他のセンサ間の信号到達時間差 (TDOA) となり、センサ間距離に比例する。Wren は室内の人間の動きが生み出す TDOA からセンサ位置の推定を行なった [11]。このような位置推定問題においては、センサ位置が環境に固定されている。これに対し、本論文では対象とするセンサが環境に固定されていない場合においても TDOA によって位置推定ができることを示す。

相互相関行列 $\mathbf{R}(t)$ および相対距離行列 $\mathbf{F}(t)$ を以下のように定義する。

$$\mathbf{R}(t) = [R_{ij}(t, \Delta T_{ij})] \quad (i, j = 1, 2, \dots, n) \quad (5)$$

$$\mathbf{F}(t) = [\mathbf{f}_1 \ \mathbf{f}_2 \ \dots \ \mathbf{f}_n]^T. \quad (6)$$

2.3 Incremental Mapping Module

IMM は以下の式に従い、前節で述べた行列を学習率 λ を用いて逐次更新する。

$$\hat{\mathbf{F}}(t) = (1 - \lambda)\hat{\mathbf{F}}(t - 1) + \lambda\mathbf{F}(t), \quad (7)$$

ここで $\hat{\mathbf{F}}(t)$ は相対距離行列の推定を表す。

次に、推定されたセンサ間距離から、多次元尺度構成法 (MDS) を用いてセンサ位置を復元する。MDS は、「対象間の類似度性を示す測度が与えられたとき、対象を多次元空間内の点として表し、点間の距離が類似度と最も良く一致するように点の布置を定める」手法である [2]。このようにして各センサの相対位置を推定することにより、センサを設置した身体の形状認識が可能になる。

3. 実験: 身体形状マッピング

本節では、提案手法を評価するために行なったシミュレーション実験について述べる。本実験の目的は、推定位置の誤差を定量的に比較することである。実験 I-a では、移動ロボットを用いて 2 次元での位置推定を行ない、I-b では、4 足ロボットを用いて 3 次元での位置推定を行なう。

3.1 実験設定

実験 I-a Fig. 3 左図に本実験で用いたロボット (Khepera) の外観を示す。Khepera は直径 55 mm の円筒形であり、周囲に光センサおよび近接センサが配置されている。本実験ではシミュレータとして Cyberbotics 社製の Webots を使用した。シミュレータ上において、受信する光の強度は光源から発生する光の方向ベクトルとセンサの方向ベクトルの内積から計算される。さらに、センサ入力には 10% のノイズが加えられる。なお、本実験では、光源からの距離は考慮せずに光の強度は一定とした。

本実験において、ロボットの行動パターンとして 3 つの行動、すなわち (a) 回転運動、(b) ランダム運動、(c) 障害物回避運動を用いた。行動 (c) で用いたタスク環境を Fig. 3 に示す。環境は 1 辺が 1 m の正方形であり、中央の 500 mm 上方に光源を置かれている。実験で用いたパラメータを Table 1 中央列に示す。

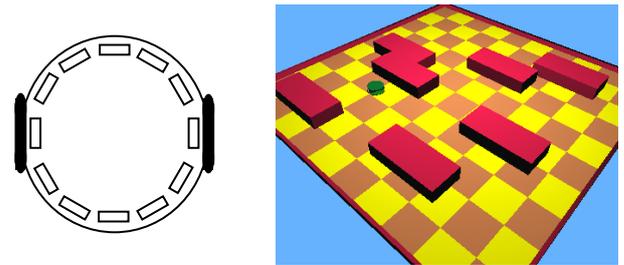


Figure 3: Left: Schematic view of robot. Boxes represent light sensors. Right: Task environment for condition (c).

実験 I-b Fig. 4 左図にロボット (Aibo) とタスク環境を示す。タスク環境は 2m 四方の凹凸のある面であり、中央の 2m 上方に光源が存在する。簡単のため、Fig. 4 右図に示すように対称的な位置にセンサを設置した。実験 I-b では、ロボットに 4 足歩行を行なわせた。実験で用いたパラメータを Table 1 右列に示す。

実験 I-a, I-b ともに、計算コスト削減のため TDOA の計算時間間隔を 10 ステップとした。

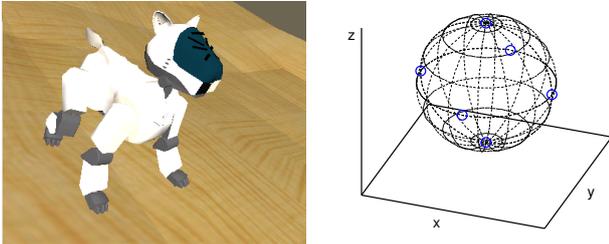


Figure 4: Left: Aibo and environment. Right: Sensor layout. Each sensor, deployed on the head of Aibo, is represented by a circle.

Table 1: Parameters used in Experiment I

パラメータ	実験 I-a	実験 I-b
シミュレーションステップ	64 ms	16 ms
行動ステップ数	10,000	40,000
窓の幅 w	60	80
T	90	200
学習率 λ	0.001	0.001

3.2 評価基準

ここで、本実験の有効性を評価する際に用いる相対誤差について説明する。本研究ではセンサ間の相対距離を計算するため、推定するセンサ位置は相対的なものになる。したがって、推定位置を評価するための指標が必要になる。

センサ i に関する実際の位置および推定位置を \mathbf{x}_i , $\hat{\mathbf{x}}_i$ とする。まず、 \mathbf{x}_i を $\|\mathbf{x}_1\|$ で除算することにより正規化する。次に、 \mathbf{x}_i を $\phi = -\arg \mathbf{x}_1$ 回転する。さらに、 $\hat{\mathbf{x}}_i$ に関して、 $\hat{\mathbf{x}}_1$ を基準として同様の操作を行なう。以上の操作により、相対誤差 e_r をユークリッド距離を用いて以下のように定義する。

$$e_r = \frac{1}{n} \sum_{i=1}^n \left\| \frac{\mathbf{G}(-\arg \mathbf{x}_1) \mathbf{x}_i}{\|\mathbf{x}_1\|} - \frac{\mathbf{G}(-\arg \hat{\mathbf{x}}_1) \hat{\mathbf{x}}_i}{\|\hat{\mathbf{x}}_1\|} \right\|, \quad (8)$$

ただし、 n はセンサ数を表し、 $\mathbf{G}(\phi)$ は回転行列を表す。

3.3 結果

実験 I-a まず、定性的な結果の一例として、行動 b において身体図式が構成されていく様子を Fig. 5 に示す。ここで左図が 0 ステップ、中央図が 2000 ステップ、右図が

10000 ステップの結果を表している。○がセンサを配置した位置、×が本手法で得られた結果を表す。図より、ステップ数が増加するにつれて理論値に近づいている様子が分かる。

次に、定量的な結果を比較するために、相対誤差をプロットしたものを Fig. 6 に示す。横軸がステップ数、縦軸が相対誤差であり、ここで示したデータは 10 回の平均である。

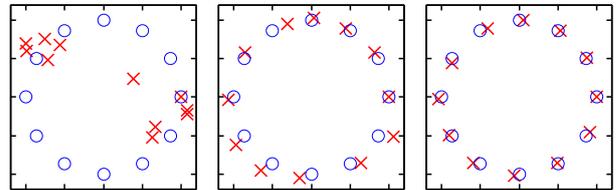


Figure 5: Estimated sensor positions under condition (c). ‘o’: actual positions, ‘x’: estimated positions. Left: At 0 steps. Middle: 2,000 steps. Right: 10,000 steps.

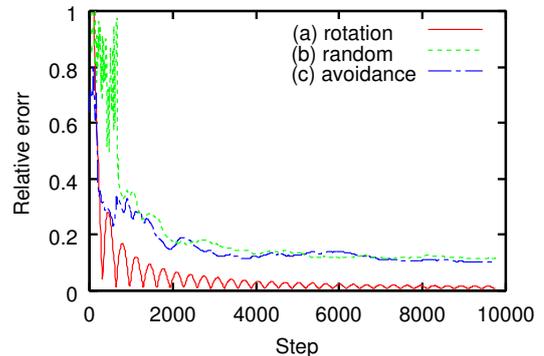


Figure 6: Experimental result I-a. Relative error of estimated sensor positions.

Experiment I-b Fig. 7 に相対誤差の変化を示す。相対誤差は 5000 ステップまで高くなっているが、10,000 ステップ後には 0.2 まで収束している。

さらに、Fig. 8 にセンサ位置の推定結果を示した。図では、0 ステップ (左図)、5,000 ステップ (中央図)、40,000 ステップ (右図) における推定位置がプロットされている。

3.4 考察

本節では本手法によって獲得された身体形状について、タスクおよび相対誤差の観点から考察を行う。

回転運動において、エージェントは一定の速度のまま定位置で回転運動を行っているため、等しいセンサデータを周期的に受信することになる。つまり、センサデータの相互相関の計測が容易に行えるため、早い時期に収束している。

次にランダム運動をする場合について考える。エージェントはランダムに行動するため受信するデータにばらつ

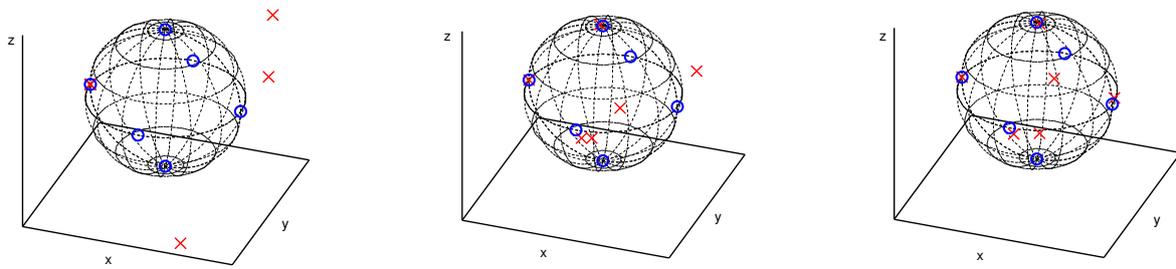


Figure 8: Estimated positions of sensors under condition (d). ‘o’: actual positions, ‘x’: estimated positions. Left: At 0 steps. Middle: 5,000 steps. Right: 40,000 steps.

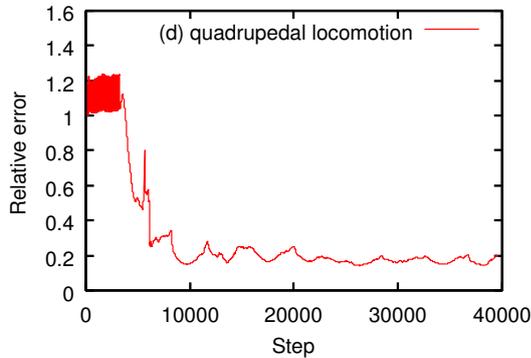


Figure 7: Experimental result I-b. Relative error of estimated sensor positions.

きがあるので、早い時期に位置推定を行うことは不可能である。しかし、データの蓄積と更新が繰り返されることによって、誤差が収束していく。回転運動より収束値が良くない理由として、ランダム運動は回転運動に比べて直進している割合が大きいため、同一の面を光源に向けている時間が長く、光センサが受け取る入力の変化が少ないことが問題点として考えられる。

さらに、障害物回避運動においてもランダム運動と同様に収束している様子が見られる。すなわち、障害物を回避するという行動が制限されるタスクにおいても、ランダム運動とほぼ同様の値に収束している。

Fig. 6 と Fig. 7 を比較すると、(d) が (a) から (c) に比べて誤差が最も大きい。これは、Aibo の顎の下に設置されたセンサのデータに変化が少なかったためである。本手法では、時系列の変化の間の時間差 (TDOA) を計算するので、データに変化がなければならぬ。Fig. 8 より当該センサが実際の位置より離れた場所にあると推定されていることがわかる。

4. おわりに

安価なセンサを用いて、ロボットの身体の適応的幾何モデルを構築することは、ロボット工学、センサネットワーク、生物学に貢献し得る。特に、モジュラーロボットなど形態が変化するロボットにおいて、身体に関するモデルが適応性を有することは重要である。本手法は、光セ

ンサから得られたデータから TDOA を計算することにより、センサの位置を推定する。本手法は、モーションキャプチャなどと比べ、外部デバイスを必要としない点が特徴的である。

参考文献

- [1] Bulusu, N., Heidemann, J. and Estrin, D.: GPS-less Low Cost Outdoor Localization For Very Small Devices, *IEEE Personal Communications Magazine*, Vol. 7, No. 5, pp. 28–34 (2000).
- [2] Kruskal, J. B. and Wish, M.: *Multidimensional Scaling*, Sage Publications (1978).
- [3] Kuniyoshi, Y., Yoroze, Y., Ohmura, Y., Otani, T., Nagakubo, A. and Yamamoto, T.: From Humanoid Embodiment to Theory of Mind, *Embodied Artificial Intelligence*, pp. 202–218 (2004).
- [4] Maravita, A. and Iriki, A.: Tools for the body (schema), *Trends in Cognitive Sciences*, Vol. 8, No. 2, pp. 79–86 (2004).
- [5] Nabeshima, C., Lungarella, M. and Kuniyoshi, Y.: Timing-Based Model of Body Schema adaptation and its Role in Perception and Tool Use: A Robot Case Study, *Proceedings of ICDL-05*, pp. 7–12 (2005).
- [6] Pierce, D. and Kuipers, B.: Map Learning with Uninterpreted Sensors and Effectors, *Artificial Intelligence*, Vol. 92, pp. 169–229 (1997).
- [7] Ramachandran, V. S. and Blakeslee, S.: *Phantoms in the Brain: Probing the Mysteries of the Human Mind*, Harpercollins (1998).
- [8] Smith, R., Self, M. and Cheeseman, P.: Estimating uncertain spatial relationships in robotics, *Autonomous Robot Vehicules*, Springer-Verlag New York, Inc., pp. 167–193 (1990).
- [9] Stoytchev, A.: Computational Model for an Extendable Robot Body Schema, Technical report git-cc-03-44, Georgia Institute of Technology, College of Computing (2003).
- [10] Thrun, S.: Robotic Mapping: A Survey, *Exploring Artificial Intelligence in the New Millennium* (Lakemeyer, G. and Nebel, B.(eds.)), Morgan Kaufmann, pp. 1–35 (2002).
- [11] Wren, C. R.: Large Networks of Ultra-low Resolution Sensors in Buildings, *Proceedings of International Conference on Integration of Knowledge Intensive Multi-Agent Systems*, pp. 373–389 (2005).