知的車椅子における環境適応のための状態空間の構成法

正員 濱上 知樹* 正員 平田 廣則*

State Space Composition Technique for Intelligent Wheel Chair Adapting to Environment.

Tomoki Hamagami*, Member, Hironori Hirata*, Member

This paper describes a state space composition technique for the adaptation to environment in the autonomous behavior of intelligent wheel chair (IWC). In the product like IWC with actual sensors, composing state space is difficult problem since environmental information can not be observed sufficiently from restricted sensor inputs. A lot of states observed from same environment position raise the fail of the learning and adaptation with active learning approach. In order to compensate for the effects of the sensor configuration, that is sensor position, angle and precision, a normalization processing of position detector is introduced. In sensor normalization process, IWC scans present environment via range sensors with executing spot-turn, and prepare scan-patterns of each sensor. Then the normalization process adjusts the phase and dynamic range of each pattern to the reference sensor scan-pattern, analyzing phase differences and scale factors of each pattern against reference pattern. Using phase difference and scale factors, automated state space composition is possible. From the simulation experiment with both artificial and real-world draft, the automated state space construction is confirmed as a practical approach for pre-processing for environment learning and adaptation.

キーワード：知的車椅子，自律移動ロボット，状態分節化

Keywords: intelligent wheel chair, autonomous robot, state space construction.

1. まえがき

近年の日本は世界に類をみない速さで高齢化が進んでいる。既に1994年には65歳を超える高齢者が全人口の14%以上を占める「高齢社会」に至っている。2016年には高齢者が25%を超える「超高齢社会」を迎える見込みである⁽¹⁾。高齢社会が抱える問題に対応していくためには、高齢者の自立的生活を支援し、積極的に社会と関わる機会を増やすことが必要である。

高齢者の自立を支援する福祉機器の中でも、電気駆動力を持つ電動車椅子は、足腰に支障のある高齢者の社会参加を促し、行動範囲を広げる手段として有望である。近年、多くの機種が開発され、種々の技術改良も行われている。しかし、現在の電動車椅子は、不慣れな使用者が事故を起こしたり、十分な安全性が得られないという理由から、一部の施設内での使用が禁止されるなど、普及を妨げる様々な問題が残されている。今後、電動車椅子が広く社会で使わ

れるようになるためには、更に高い安全性と機能性を実現するための知的な機構が必要である。

以上を背景として、筆者らは、車椅子自らが環境を学習し適応することで、自律的で安全な走行を実現する、自律移動ロボットとしての「知的車椅子」の研究を進めている⁽²⁾。知的車椅子が持つ様々な機能の中でも、特に自律移動機能には、強化学習をはじめとする機械学習が応用できる。

自律移動ロボットは、学習・適応に必要な環境情報を取得するために、障害物を検知するセンサを必要とする。センサを用いて環境情報を取得し、ロボット内の状態空間を構成する場合、センサ情報の不完全性から二つの問題が生じる。一つは、異なった環境を同じ状態と認識してしまう「知覚のみなし問題」⁽³⁾と呼ばれる問題である。もう一つは、同じ環境を異なった状態と認識してしまう問題である。

前者の問題に対しては、根本的な解決方法は得られていないものの、いくつかの有効なアプローチが存在する⁽⁴⁾⁽⁵⁾。後者については、センサ数・配置・角度などの構成を理想的に設計したり、同じ環境を異なった状態としてとらえたまま重複して学習を進める手法がとられてきた。しかし、実機においては、センサ取り付け位置の制約や取り付け精度の誤差のため、十分な環境情報が取得できない場合がある。

* 千葉大学大学院自然科学研究科

〒263-8522 千葉市稲毛区弥生町 1-33

Graduate School of Science and Technology, Chiba University
1-33, Yayoi-cho, Inage-ku, Chiba 263-8522

また、状態数の増加は、学習時の計算負荷を増大させる。

これらの問題に対し、本論文では、限られたセンサ情報から、学習に必要な状態空間を自動構成する簡便な方法を提案する。ここで状態空間とは、強化学習においてエージェント内部に構成される空間⁽⁶⁾と同義である。適切に構成された状態空間を用いることで、自律行動獲得のための効率的な学習が可能になる。

提案する手法は、車椅子の旋回（スポットターン）から得られる測距センサからの測距空間パターンを用い、ある基準となるセンサからのパターンに合わせて、他のセンサからのパターンを正規化する。その際に分析された正規化パラメータを用いて、実測時の離散情報を正規化する。更に、正規化されたセンサ値を、あらかじめ環境から分析された空間パターンと照合することにより環境情報を特定する。環境からあらかじめ求めておく空間パターンは、自律的に行動する過程で自動的に取得できる。これらの手続きにより、センサ数・配置・角度などの構成上の相違から生じる学習の失敗を防ぎ、学習結果の再利用が可能になる。

以下、2. では、本研究が目指す知的車椅子の概要と、実環境を学習する上で問題となる、測距センサの構成について述べる。3. では、測距センサ情報の正規化方法と、正規化された結果から得られる正規化パターンの作成法について述べる。4. では、シミュレータを用いた正規化パターンの自動抽出実験について述べ、シミュレーションによる実験結果を示す。5. は本論文の総括である。

2. 知的車椅子の自律走行と技術的課題

〈2・1〉 知的車椅子 知的な機構により高い安全性と自然な操作性を実現し、その応用範囲を広げることを目指した車椅子を「知的車椅子」と呼ぶ。既に、同様の目的の知的車椅子及び関連システムの研究がいくつか報告されている。足立らは、操作者と車椅子とのインタフェースとして顔の向きを検出する機構を導入し、自然な操作性を目指し

た知的車椅子を開発した⁽⁷⁾。Kotani らは、画像情報を用いたティーチングによる自律行動機構を提案し、視覚障害者のための歩行ガイドロボットに応用した⁽⁸⁾。

本研究では、これらの知的車椅子の研究アプローチとは異なり、自律性を重視した知的車椅子を提案している⁽²⁾。具体的には、次の三つの機能を併せ持つ自律移動ロボットとして、より安全で自律性の高い知的車椅子の開発を行っている。

- (1) 車椅子自身が環境に適応し自律行動する機能。
- (2) 操作者と車椅子との協同行動により操作者の意図を反映しながら安全に行動する機能。
- (3) 他の車椅子と協調行動をとり車椅子集団として適切な振る舞いをする機能。

本研究では、市販の電動車椅子をプラットフォームとし、これに複数のセンサ、無線 LAN を搭載したコントローラを具備する知的車椅子を開発している。図 1 に、本研究で用いている市販の電動車椅子及び環境情報取得のためのセンサ取り付け例を示す。本電動車椅子は両輪に独立したダイレクト・ドライブモータを持ち、サーボ制御により車輪を制御する。そのため、正確な位置決め制御や、その場での旋回動作（スポットターン）が可能になっている。

〈2・2〉 知的車椅子シミュレータ 知的車椅子の知的機構を実現するためには、環境を学習し適応するための試行実験が必要である。しかし、強化学習などの自律学習では、学習主体者自身による多くの試行錯誤が必要となる。そのため、学習の初期の段階から実環境にて実機を用いることは現実的ではない。

そこで、本研究では、前述の電動車椅子のハードスペックをもとにした知的車椅子シミュレータを作成し、これを用いた予備実験を行っている。本シミュレータは、環境に相当するサーバと、個々の知的車椅子に相当する複数クラ

図 1 知的車椅子プラットフォーム電動車椅子
(ワコー技研製 エミュー)

Fig. 1. Electric wheel chair for platform of IWC.

図 2 知的車椅子シミュレータ画面

Fig. 2. A snapshot of IWC simulator window.

クライアントからなるサーバ・クライアントシステムである。本シミュレータを用いることで、複数の知的車椅子クライアントを同じサーバ環境において同時に動作させ、自律行動、協調行動等の知的機構のシミュレーション実験を行うことができる。知的車椅子クライアントは、ビットマップで表された二次元環境情報から、走行可能領域を自動判断すると共に、近接する周辺の障害物までの距離を、測距センサを想定した仮想センサビームを用いて取得する。

図2に知的車椅子シミュレータ画面の一部を示す。

〈2・3〉 測距センサによる環境情報の取得と問題 本研究では、知的車椅子自律行動のための環境情報の取得に、複数の測距センサを組み合わせて状態空間をサンプリングする方法を採用している。これは、障害物の検知のみが目的であること、CCDカメラによる画像情報やAGV用の平面障害物センサに比べ小型で安価であること、少ない次元数で効率よく状態空間をサンプルすることで、学習の負荷を抑えられることなどの利点による。

本研究で用いる測距センサは、PSD (Position Sensitive Detector) センサである。PSD センサは、超音波等による他の測距方式に比べ、応答性が良く、温度、周辺光の影響を受けにくく、高い精度が得られるという利点がある。

一方、PSD センサは指向性が高く、ビームの向いている方向に存在する障害物にしか反応しないという特徴をもつ。そのため、複数のPSD センサを取り付けた場合でも、ビーム間の死角の発生は避けられない。その結果、同じ環境状態に知的車椅子が位置していても、センサの数・位置・角度、また車椅子そのものの向いている方向により、知的車椅子にとっての状態空間は大きく変化する。

更に、既製の電動車椅子に測距センサを取り付ける場合、次のような現実的な制約も考慮しなくてはならない。

- (1) 車椅子の機能を制限せず、センサを安定に取り付けられる位置や数は限られている。
- (2) 取り付け角度や、ビーム方向には誤差が生じる。
- (3) センサの性能にはばらつきがあり、測定ごとの誤差が生じる。

これらの制約により、センサ数・位置・角度・精度に依存して、学習結果が異なったり、ある知的車椅子による学習結果が、他の知的車椅子では利用できなくなるなどの問題が生じる。また、同様の理由で、シミュレータの学習結果をそのまま利用することも困難である。

この問題に対する最も単純な解法は、なるべく死角がなくなるよう十分な数のセンサを取り付け、より多くの環境情報を取得することである。しかし、前述の取り付け位置の制約から、十分な数のセンサが取り付けられないことや、たとえ多数のセンサが利用できた場合でも、状態の次元数が増え、学習が困難になるなどの問題が残る。

この問題に対し、本研究では、知的車椅子の状態空間を構成する手段として、センサの構成によってばらつきが生じる測距情報を直接用いるのではなく、構成に依存する誤差を正規化により除去する方法を用いる。更に、正規化に

よって得られる離散的な状態空間を、車椅子のスポットターンにより補間することで、車椅子の向きによらない状態空間パターンを取得する。以下の章では、これらの手法の詳細について述べる。

3. センサ空間の正規化法

〈3・1〉 スキャンパターン 知的車椅子が観測する環境情報から、センサの数・位置・角度・精度に依存した影響を取り除くために、知的車椅子自らが各センサの出力を正規化する手法を提案する。

センサの総数を K とする。 $k \in K$ 番目の測距センサを車椅子の取り付け可能な場所 P_k に適当な角度 θ_k [rad] で取り付け。ここで θ_k は、車椅子のスポットターン中心点 O から P_k へ向けて伸ばした線から反時計回りを正としてみた角度である。図3に、左前方 (P_1) 及び側面 (P_2) に、それぞれ $\theta_1 = \theta$, $\theta_2 = 0$ で測距センサを取り付けた例を示す。また、図4に、シミュレータ上に作られた仮想環境において、(a) P_1 に $\theta_1 = \pi/6$, (b) P_1 に $\theta_1 = 0$, (c) P_2 に $\theta_2 = 0$ とした場合の、それぞれのビームの向きを示す。次に、センサを取り付けた状態で車椅子をスポットターンさせて測距を行う場合について考える。スポットターンにより、 k 番センサは O を中心として $O-P_k$ を半径とした円弧に沿って回転する。センサビームは円の接線の法線方向から、 θ_k の角度に向けられ、障害物までの距離 L_k [cm] を出力する。スポットターンの単位角度 ρ_0 [rad] ごとに測距情報を取得するこ

図3 スポットターンによるスキャンパターンの取得
Fig. 3. Scanning of scan-pattern by a spot-turn.

図4 仮想環境とセンサ位置、ビームの向きの例
Fig. 4. An example of sensor positions and beam directions in artificial environment.

とで、各センサは知的車椅子の周辺環境を同時にスキャンすることができる。 k 番目のセンサが一回のスポットターン中に出力する測距系列 $\{L_k^{(1)}, L_k^{(2)}, \dots, L_k^{(N)}\}$ に対し、各測距情報の逆数をとることで、接近度 $S_k^{(n)} = 1/L_k^{(n)} [\text{cm}^{-1}]$ の系列 S_k を得る。ここで、上付き添え字 (n) は、一回転中の n 回目の測距であることを意味する。この系列をセンサ k のスキャンパタン S_k と呼ぶ。

$$S_k = \{S_k^{(1)}, S_k^{(2)}, \dots, S_k^{(N)}\} \dots \dots \dots (1)$$

$$= \{1/L_k^{(1)}, 1/L_k^{(2)}, \dots, 1/L_k^{(N)}\} \dots \dots \dots (2)$$

ここで $N = 2\pi/\rho_0$ である。すなわち、1 回のスポットターンにより、 N 次のスキャンパタンが K パタン得られる。

図 5 に、前述 (a) のセンサと (b) のセンサのスキャンパタンを重ねて示す。スキャンパタンは、北を 0 とし、時計回りに $\rho_0 = \frac{\pi}{16}$ 単位で回転しながら測距を繰り返している。このように、同じ位置に取り付けた場合であっても、ビーム角度が異なることにより、スキャンパタンの位相は異なってくる。

図 6 に、前述 (a) のセンサと (b) のセンサのスキャンパタンを重ねて示す。この場合、単に位相が $\frac{\pi}{2}$ ずれるだけではなく、2 つのセンサの回転半径の違いから障害物との相対距離も変化し、その結果、ダイナミックレンジも変化する。

以上のように、知的車椅子に取り付けられた各測距センサのスキャンパタンは、同じ環境をスキャンしているにもかかわらず、センサの位置・角度の違いから空間位相と回

転半径の相違が生じ、異なったスキャンパタンとなる。

〈3・2〉スキャンパタンの正規化 ここで、あるセンサのスキャンパタンが、別のセンサのスキャンパタンと同一の環境から取得したパタンであるか否かを調べる方法について考える。厳密には、スキャンパタン同士の対応づけは、幾何的には非線形な問題となる。しかし、実験的に得られるスキャンパタン同士はほぼ相似とみなせるため、ここでは、単にスキャンパタン同士の位相操作と定倍率操作により正規化を行い、パタン同士の対応づけをはかる。

知的車椅子の複数のセンサから得られる複数のスキャンパタンについて、以下の操作により正規化を行う。

- (1) K 個のセンサを取り付け可能な位置 ($P_k, k \in K$) に適当な角度 (θ_k) で配置する。
- (2) 知的車椅子を、正規化操作を行う環境 (図 4) に配置する。
- (3) 知的車椅子を北に向けた状態から、時計回りに $\rho_0 = \frac{\pi}{16}$ ずつ回転させ、その都度各センサからの測距情報 ($L_k^{(n)}, n = 1, 2, \dots, N = 2\pi/\rho_0$) を取得する。
- (4) 一回転する度に、各測距情報から、各センサごとにスキャンパタンを求める。
- (5) R 回転後、一回転ごとに求めた各センサのスキャンパタンを平均化し、これを改めてセンサごとのスキャンパタン S_k とする。
- (6) 各スキャンパタンのうち、基準となるセンサ (基準センサ k_0) を決定する。基準となるセンサは、スキャンパタンの接近度平均値 $\sum_{n=1}^N \frac{S_k^{(n)}}{N}$ が最も大きなパタンとする。すなわち、スキャン中に最も障害物に接近する機会が多かったセンサが基準センサとして選択される。
- (7) 基準センサのスキャンパタン (基準スキャンパタン $S_0 = S_{k_0}$) と他のパタン S_k との相関関数 $\langle S_k, S_0 \rangle$ をそれぞれ計算する。最大の相関値をとる位相遅れから、 S_0 との位相差 δ_k を算出する。
- (8) S_k を δ_k だけ位相補正し、更に、 S_0 との二乗誤差が最小となるように定数倍率 α_k を求める。測距センサの特性上、前に障害物がない場合、無限遠点までの距離の代わりに、知的車椅子にとって障害物を無視できる距離である比較的大きな定数距離 (50 cm) が出力される。そこで、 $1/50 = 0.02 [\text{cm}^{-1}]$ をバイアス値 b として考慮している。

以上の操作により、以下の式で正規化されたスキャンパタン $\bar{S}_k$ が求まる。

$$\bar{S}_k = \{\bar{S}_k^{(1)}, \bar{S}_k^{(2)}, \dots, \bar{S}_k^{(N)}\} \dots \dots \dots (3)$$

$$\bar{S}_k^{(n)} = \alpha_k (S_k^{(n-\delta_k/\rho_0)} - b) + b \dots \dots \dots (4)$$

図 7 にスキャンパタンの正規化手順を示す。正規化操作を行う環境は、図 4 のように、センサビームの到達する場所に適当な障害物があり、また、知的車椅子からみて、前後・左右非対称な環境であることが望ましい。これは位相

図 5 スキャンパタンの例 1 正面左側に取り付けたビーム角度の異なるセンサからのパタン
Fig. 5. An example of scan-patterns 1: the patterns with sensors fixed on front of the left of IWC with different angle ($\theta_k = 0, \theta_k = -\pi/6$).

図 6 スキャンパタンの例 2 正面左側と左側面に取り付けた同じビーム角度のセンサからのパタン

Fig. 6. An example of scan-patterns 2: the patterns with sensor fixed on front of the left and left side of IWC with same angle ($\theta_k = 0$).

図7 スキャンパタン正規化手続き

Fig.7. The process of normalizing scan-patterns with multi fixed sensors ($K = 6$).

図8 スキャンパタンの正規化

Fig.8. Normalization of scan-pattern ($K = 6$).

図9 スキャンパタンの例

Fig.9. An example of scan-pattern with multi fixed sensors ($K = 6$).

図10 正規化されたスキャンパタンの例

Fig.10. An example of normalized scan-pattern with multi fixed sensors ($K = 6$).

差を検出する際の誤りを防ぐためである。本論文における以降の実験では、図4で示した環境で正規化を行っている。

回転数 R は、センサの精度により適宜調整する。すなわち、センサ出力にランダムな誤差が生じる場合は、より多くの回転によりスキャンパタンの精度を向上させる必要がある。ここでは、センサのオフセット誤差とランダム誤差が、それぞれ5%であることを想定し、経験的に $n = 10$ とした。更に、同じ環境であるにもかかわらず、平均から大きく異なる特異なパタンが現れた場合は、環境が一時的に変化したものとしてそのパタンを除外する。

あるセンサのスキャンパタンの正規化は、図8に示すように、基準センサの取り付け位置を通る円弧上に、他のセンサを移動させ、角度を変える仮想操作に相当する。また、正規化により、センサ間のばらつきも、定倍率中に含めて正規化することができる。巡回スキャンパタンを複数回行うことで、ランダムなノイズもある程度除去できる。従って、どのようなセンサの配置・角度であっても、正規化されたパタンは、一つの円上に配置されたセンサによって得られた離散センサ情報として扱うことができ、センサの取り付け位置・角度・精度等による影響は少なくなる。

図8に示すセンサ構成にて、図4の環境から得られた S_k を、図9に示す。また、 S_k を正規化した $\bar{S}_k$ を、図10に示す。ここで、基準センサは、1番のセンサである。

4. 正規化スキャンパタンによる状態空間の構成

〈4・1〉 正規化スキャンパタンの自動抽出 前節で求

めた正規化スキャンパタンは、基準センサが同じであれば、センサの総数・取り付け位置・角度・精度の影響を受けにくいという利点をもつ。この利点を用いて、状態空間を自動構成することができる。この処理は、実環境を反映したシミュレータを用いて行う。よって、実際に人が移乗して走行させる前に、自律走行学習に必要な状態空間を効率的に構成することが可能である。

知的車椅子を以下の手続きに従い自律走行させる。以下、スキャンパタンテーブルとは、複数のスキャンパタンを記憶するためのメモリである。

- (1) あらかじめ、当該知的車椅子に取り付けられたセンサに正規化操作を行い、基準センサと、他センサの正規化パラメータ δ_k 、定倍率 α_k を求めておく。
- (2) スキャンパタンテーブルを初期化する。
- (3) 適当な初期位置に知的車椅子を配置する。
- (4) 知的車椅子の現在の位置、方向において一度測距を行い、離散環境情報 $D = \{S_1, S_2, \dots, S_K\}$ を得る。ここで S_k は、 k 番センサの接近度である。
- (5) α_k から、環境情報を正規化された値 $\bar{D} = \{\alpha_1 S_1, \alpha_2 S_2, \dots, \alpha_K S_K\}$ に変換する。ただし、基準センサに対する α_k は1である。
- (6) $\bar{D}$ と δ_k を用いて、離散正規化パタン S_d を求める。すなわち、基準センサを基準に、各センサの接近度を δ_k だけの位相差の位置に配置する。
- (7) スキャンパタンテーブル上の各スキャンパタンとの照合を行う。ここでは、簡単のためとテーブル上各パタン $S_p, p \in P$ と、 S_d との相関関数を取り、最大の相関値をとるパタンを選択候補とする。

図 11 スキャンパターンによる状態空間の構成手続き

Fig. 11. Process of constructing state space with scan-pattern.

表 1 正規化パラメータ分析結果

Table 1. Results of analysis of parameters for the normalization ($K = 6$).

k	1	2	3	4	5	6
δ_k [rad]	0.0	0.34	-0.12	1.43	-0.78	1.97
α_k	1.0	1.02	1.31	1.28	1.21	1.33

(a) 最大の相関値がしきい値 d 以上であった場合は、(8)の処理を実行する。

(b) 最大の相関値がしきい値未満であった場合は、微小角 $\pm\phi_d$ の回転を行い、再度測距を行う。合計三回の測定のすべてにおいて d 未満であった場合、新しい状態が検出されたとみなす。そして、その場でスポットターンを行い、基準センサのスキャンパターンをスキャンテーブルに登録する。

(8) 左右のモータをそれぞれ l だけ移動させ直進行動をとる。移動中、障害物に衝突した場合に、ランダムな角度にターンし、行動を続行する。

(9) (4)に戻る。

(10) 以上のサイクルを、規定の数だけ続行する。

以上の処理において、新たに正規化スキャンパターンを作る場合は、常に正規化パラメータ算出時に用いた基準センサからの出力を基準センサとして使用する。図 11 にスキャンパターンによる状態空間の構成手続きを示す。

〈4・2〉 シミュレーション実験 シミュレータによる状態空間の構成実験を行う。実験に用いた環境は、仮想的に作られた通路図面と、実際の建物の平面図の二つである。センサの構成は図 8 と同じである。ただし、他の車椅子や動的に変化する障害物は現れないものとする。

前節の状態空間の構成手続き中のパラメータは、 $d = 0.03$ [cm⁻¹], $l = 30$ [cm] とした。実験開始にあたり、求めた正規化パラメータを表 1 に示す。

図 12, 13 に、仮想環境のシミュレーション実験の結果を示す。測距回数は 300 回である。図 12 は、スキャンパ

図 12 仮想環境においてスキャンパターンが抽出された位置

Fig. 12. Locations selected for analysis of scan-patterns in an artificial environment.

図 13 仮想環境におけるスキャンパターン分析例

Fig. 13. Examples of analysis results of scan-pattern in an artificial environment ($K = 6$).

タンテーブルに登録されたパターンの抽出位置である。図 13 は、抽出された 6 つのパターンである。図 12 中の各番号は、パターン番号を意味する。

ここで、1 と 6 のパターンはいずれも単峰性の特徴をもっているが、1 が鋭角のパターンをしているのに対し、6 は比較的緩やかなパターンとなっていることがわかる。この特徴により、二方向をふさがれた状態か、壁などの平面上の障害物かが判別できる。また、2 と 4 のパターンは、いずれも双峰性の特徴を持っているが、やはり山の傾斜が異なっている。これは、狭い通路からやや広い空間を見た場合に現れるパターンであり、広い空間への視界角に応じて山の傾斜が異なるという特徴を持つ。以上のような特徴は、測距センサの情報を直接用いた場合は、センサの取り付け位置、角度によって見え方が異なるため、自動で判別することは容易ではない。これに対し、本手法は、各センサを基準センサに合わせた正規化を行うため、センサの構成の違いによる影響が少なく、状態空間の重複を減らすことができる。

図 14 に、実環境に対応した図面を用いてシミュレーション分析を行った結果を示す。測距回数は 500 回である。そ

図 14 実環境図面においてスキャンパターンが抽出された位置

Fig. 14. Locations selected for analysis of scan-patterns in real environment draft.

の結果、24 のスキャンパターンが抽出された。抽出位置は、図面に現れる主な特徴点をほぼ網羅していると考えられる。これより、実環境のような様々な状態が入り組んだ場合においても、本手法に基づく状態空間の構成は有効であると結論づけられる。

5. むすび

知的車椅子における環境の学習・適応のために、環境情報取得に用いる測距センサの構成上の影響をできるだけ少なくする正規化手法と、これを用いた状態空間の自動構成について述べた。本手法は、比較的簡単な処理でセンサの数・取り付け位置・角度・誤差の影響を減らし、少ないセンサ数で状態空間を効率的に構成することが可能である。

本手法から得られた正規化スキャンパターンを用いて、環境中から自動的に類似パターンを抽出する方法を提案した。仮想の環境および実環境図面をシミュレータ上に構築し、状態空間の自動構成の実験を行った結果、本手法により構成された状態空間は、環境の特徴的な箇所を自動で抽出し、実環境への応用が可能であることが確認された。

今後は、本手法を、実機を用いて検証するとともに、自律行動学習への応用をはかる予定である。

(平成 14 年 9 月 25 日受付, 平成 15 年 2 月 5 日再受付)

文 献

- (1) 内閣府高齢社会対策調査・資料:「平成 13 年度 高齢化の状況及び高齢社会対策の実施の状況に関する年次報告書」(<http://www8.cao.go.jp/kourei/>) (2002)
- (2) K. Kawato, T. Hamagami, S. Koakutsu, and H. Hirata: "Design for Obstacle Avoidance Module in Autonomous Behavior for Intelligent Wheelchair", *Proc. of Electronics, Information and Syst. Conf. I.E.E. of Japan*, pp.922-923 (2002-9) (in Japanese)
川戸康司・濱上知樹・小坪成一・平田廣則:「知的車椅子における自律走行のための障害物モジュールの設計」, 電気学会電子・情報・シ

ステム部門大会講演論文集, pp.922-923 (2002-9)

- (3) S.D. Whitehead and D.H. Ballard: Active perception and reinforcement learning. In *Proc. Seventh International Conference on Machine Learning*, pp.358-362 (1990)
- (4) S.D. Whitehead and L.J. Lin: "Reinforcement learning of non-Markov decision process", *Artificial Intelligence*, **73**, pp.271-306 (1995)
- (5) T. Hamagami, S. Koakutsu, and H. Hirata: "Reinforcement Learning to Change Action Selection Probabilities by Motivation Values", *IEEJ Trans. EIS*, Vol.122-C, No.12, pp.2157-2164 (2002-12)(in Japanese)
濱上知樹・小坪成一・平田廣則:「誘因価値に基づいて行動選択確率に変化する強化学習法」, 電学論誌 C, **122**, 12, pp.2157-2164 (2002-12)
- (6) K. Samejima and T. Omori: "Adaptive internal state space construction method for reinforcement learning of a real-world agent", *Neural Networks*, Vol.11, pp.1143-1155, (1999-11)
- (7) Y. Adachi, S. Nakanishi, Y. Kuno, N. Shimada, and Y. Shirai: "Intelligent Wheelchair Using Visual Information from the Human Face", *Journal of the Robotics Society of Japan*, Vol.17, No.3, pp.113-121 (1999-4) (in Japanese)
足立佳久・中西 知・久野義徳・島田伸敬・白井良明:「顔の視覚情報処理を用いた知的車椅子」, 日本ロボット学会誌, **17**, 4, pp.423-431 (1999-4)
- (8) S. Kotani, K. Nishikawa, and H. Mori: "Empirical learning in mobile robot navigation", *Journal of the Advanced Robotics*, Vol.12, No.4, pp.317-333 (1998-4)

濱上 知 樹 (正員) 1966 年 3 月 7 日生。88 年千葉大学工学部電気工学科卒業。セコム(株)勤務を経て、99 年在職のまま千葉大学大学院自然科学研究科生産科学専攻後期博士課程修了。2001 年同助手となり現在に至る。大規模システムの数理、マルチエージェント、機械学習、創発システムの応用研究に従事。博士(工学)。IEEE, 電子情報通信学会各会員。

平 田 廣 則 (正員) 1948 年 6 月 2 日生。76 年東京工業大学大学院電気工学専攻博士課程修了。同年千葉大学工学部助手, 81 年同助教授, 94 年同教授, 97 年同大学院自然科学研究科教授となり現在に至る。大規模システムのモデリング, 解析と設計, 特に生態システム, VLSI レイアウト, 並びに分散型コンピュータの基礎的理論に興味を持つ。工学博士。2001 年電気学会業績賞受賞。IEEE (Fellow), ISEM, INNS, 電子情報通信学会, 情報処理学会, 計測自動制御学会, システム制御情報学会, 人工知能学会会員。