

自己組織化マップを用いた移動ロボットによる 行為系列からの環境認識

山田 誠二*1 室田 盛道*2

Recognizing environments from action sequences using a self-organizing map

Seiji Yamada*1 and Morimichi Murota*2

In this paper, we describe development of a mobile robot which does unsupervised learning for recognizing environments from action sequences. Most studies on recognizing an environment have tried to build precise geometric maps with high sensitive and global sensors. However such precise and global information may not be obtained in real environments. Furthermore unsupervised-learning is necessary for recognition in unknown environments without help of a teacher. Thus we attempt to build a mobile robot which does unsupervised-learning to recognize environments with low sensitive and local sensors. The mobile robot is behavior-based and does wall-following in enclosures. Then the sequences of actions executed in each enclosure are transformed into input vectors for a self-organizing map. Learning without a teacher is done, and the robot becomes able to identify enclosures. Moreover we developed a method to identify environments independent of a start point using a partial sequence. We have fully implemented the system with a real mobile robot, and made experiments for evaluating the ability. As a result, we found out that the environment recognition was done well and our method was adaptive to noisy environments.

Key Words: Action sequence, Self-organizing maps, Environment recognition, Mobile robot

1. はじめに

移動ロボットによって環境をモデリングする従来の研究は、占有グリッド (occupancy grid) に代表されるようにセンサデータから絶対座標をもつグローバルな幾何学的地図を獲得することを目指したものが多く [5] [7] [8] [2] [10] [6]。一般に移動ロボットに装備されたセンサで得られる情報は、環境全体に対して部分的でしかないため、移動ロボット自身が環境をモデリングするためには、部分的に得られた情報をデッドレコニング (dead reckoning) などで得られる絶対座標に基づいて統合する必要がある。

しかし、例えば、局所的かつ相対的な情報しか得られない近接センサと精度の悪い内界センサしか持たず、さらにアクチュエータの精度も高くないような移動ロボットによる環境モデリングを考えたとき、絶対的な基準をもとに局所情報を統合することは、非常に困難である。なぜなら、そのような低精度の内界センサしかもたない移動ロボットのデッドレコニングは、大きな累積誤差を含むため、絶対座標を維持することは実際的には難しいからである。一方、精度のよいセンサを持たない単純

な生物でも環境の認識は行っているし、例えば、現在いる環境を過去訪れたことのある環境と同定するという、重要ではあるが比較的簡単な環境認識のためには、必ずしも精度の高い幾何学的地図が必要ではない。

また、当然のことながら、ロボットによる環境認識は、ノイズ等に対し頑健でなければならぬし、さらに未知環境における探検を考えると、明示的な教師なしに識別が可能である学習能力も要求される。

以上のような背景から、我々は、低精度かつ局所的なセンサしかもたない移動ロボットによって、いかにして環境をモデリングし、さらにはいかにしてそのモデルに基づく環境認識が可能かを模索する研究を行なう。また、明示的な教師がいなくても、環境をロボット自身が学習により識別できるようになる能力も合わせ持ったシステムを目指す。このような単純な移動ロボットによる環境認識の実現は、ロボット製作のコスト面、あるいは、光が全くない環境などの外界から得られる情報が非常に少ない環境において価値があると考えられる。

本研究では、頑健な識別能力と教師なし学習を実現するために、まず 2 つの赤外線近接センサだけを用いる行動ベースト (behavior-based) 移動ロボットを設計し、そのロボットを実際に環境において行動させる。そして、環境において実行された行為の系列を環境の構造を表現する環境ベクトルに変換し、その環境ベクトルをコホーネンの自己組織化マップに入力とし

原稿受付 1998年6月15日

*1 東京工業大学大学院総合理工学研究科知能システム科学専攻

*2 大阪大学大学院基礎工学研究科 (現在、日本電信電話株式会社)

*1 Tokyo Institute of Technology

*2 Osaka University

て与えることにより、教師なし学習を行なわせ、形状の異なる環境の識別を行う [21] [22]。なお、本研究では、ロボットが行動する、壁で囲まれた閉領域を部屋と呼ぶ。

Nehmzow と Smithers は、直角のコーナーをもつ単純な囲いの中で、移動ロボットを壁沿い移動させることにより得られた情報から、自己組織化マップの学習により、コーナーの同定を行なった [16] [17]。さらに、Smart と Hallam は、Nehmzow のシステムを用いて、追加実験を行ない、その結果とラットの位置認識との類似性を議論している [18]。彼らが用いた表現は、既に訪れたのコーナーの形状 (凹、凸) と壁の長さからなる <方向、期間> 対というものであり、それが自己組織化マップに入力され、学習の結果、コーナーが同定されるようになった。しかし、センサ入力から <方向、期間> 対への変換は、小さな障害物などのノイズに弱いという欠点がある。これに対し、我々は、まず環境の情報を再現性のある行為系列から得ることを考え、行為系列をさらに BI 変換と呼ばれる方法により環境ベクトルに変換することで、ノイズに対して頑健な認識を実現する。また、彼らの研究における認識対象は、コーナーであり、本研究における認識対象である部屋全体とは異なる。

Mataric は、ランドマークをノードとするオートマトンにより環境を表現した [14]。その表現は、幾何学的なものよりも頑健であるが、移動ロボット自身がセンサデータからランドマークを抽出し、さらにその同定を行なう必要がある。しかし、一般に、低い精度のセンサを用いたランドマークの抽出と同定は困難なため、Mataric の手法は、我々の目的にはそぐわないと考えられる。

また、辻と李は、ルートに沿って移動したときに得られるシーンを視覚ベースで記憶する方法を提案し、実装した [19]。移動ロボットは、全方位の定性的表現を記録し、現在のセンサ情報とのマッチングにより、ルート上での位置決定が可能となる。高度な視覚システムをもつ移動ロボットでは、このような視覚ベースの環境認識が有効であろう。しかし、我々は視覚よりも情報量のはるかに少ない低精度のセンサだけの環境認識を目指す。

加藤らは、広い領域を徘徊できるように改良されたランダムウォークによりロボットを行動させ、その結果得られた行為系列の統計量を用いて、環境を分割する研究を行った [11]。環境において実行された行為を用いる点は、我々の研究と類似しているが、彼らの研究は我々の目的である環境認識を直接の目標としたものではない点と、統計情報のため非常に多くの行為の実行を必要とし、実機では実現が難しい点において、本研究と異なる。

また、本研究のように行為系列だけから環境モデリングをするのではなく、行動により得られたセンサ情報の系列を基に環境モデリングを行う中村らの研究 [15] がある。そこでは、障害物回避を行なう移動ロボットのソナーリングにより得られたセンサ値の系列から、主成分分析により局所的構造が取り出され、それらを統合した大局的地図が構成される。

通常ロボティクスにおいて、自己組織化マップは、高次元のセンサデータを低次元に圧縮するために用いられる場合が多い [3]。そのような応用では、センサデータがそのまま入力ベ

クトルとして自己組織化マップに与えられる。また、その出力 (勝者ノード) が直接的に何かを意味するわけではない。それに対し、本研究では、出力が直接部屋を指示するため、望ましい結果が得られるように、センサデータをいかに適切に入力ベクトルに変換するかという興味深い問題が生じる。

本論文の構成は、続く §2 において行為に基づく環境モデリング AEM の概要を説明する。そして、§3 において、AEM を構成する行動ベースの移動ロボットについて述べ、§5 でコホーネンの自己組織化マップの構造と学習アルゴリズムについて説明する。また、§4 では、本研究で用いた行為系列とその環境ベクトルへの変換について説明し、§6 では、部分的な行為系列を用いた環境認識の方法について述べる。続く §7 と §8 では、実際に環境の認識について行った実験について、その実験環境、方法、そして結果を示し、§9 では、問題点及び今後の課題について触れる。

2. 行為に基づく環境モデリング: AEM

本研究では、「ロボットが現在いる環境を、過去に訪れたことのある環境と同定すること」を環境認識と呼ぶ。赤外線近接センサしか持たず、精度の悪いデッドレコニングしかできない単純な移動ロボットに環境認識をさせることを考えよう。このとき、従来のように、局所的なセンサ情報を統合して、絶対座標のどの位置に障害物があるかを示す幾何学地図をつくる方法 [5] [7] [8] [2] [10] [6] は実現困難である。なぜなら部分的情報の統合に必要な絶対座標は、大きな累積誤差を含むものとなり、それからつくられた幾何学地図は、現実と著しく異なったものとなるからである。

よって、より頑健でかつ環境認識に必要な情報を含む環境のモデリングが必要になる。そこで我々は、ロボットの行動を環境の局所的な構造を反映するように与え、環境でロボットが実際に行動することにより得られる行為系列から環境の構造を抽出して、環境をモデリングする方法を提案する [21] [22]。行動を設計する際に、ある程度の幅をもったセンサ情報に対して行為を割り当てておけば、ノイズに対して頑健である抽象化された記述として行為系列を利用できる。我々は、このようにセンサ情報ではなく、実際に実行された行為系列を基に環境をモデリングする手法を行為に基づく環境モデリング: AEM (Action-based Environment Modeling) と呼ぶ。

2.1 AEM 手続きの概要

行為に基づく環境モデリング AEM の基本となる考えは、センサ情報により環境をモデリングするのではなく、環境において実行された行為の系列を基に環境をモデリングすることである。

全体の処理の流れを、Fig.1 に示す。AEM は、訓練フェーズと試験フェーズの 2 つからなる。まず、訓練フェーズ (Fig.1(a)) では、識別すべき複数の部屋 (訓練環境と呼ばれる) において行動ベースの移動ロボットが壁沿い移動 (wall following) を行って部屋内部を一周し、そのとき実行された行為系列 (文字列) を得る。このとき、それぞれの部屋に対し、少なくとも一回は壁沿い移動が行われるとする。次に、得られた行為系列を環境ベクトルと呼ばれる多次元ベクトルに変換した後、その環

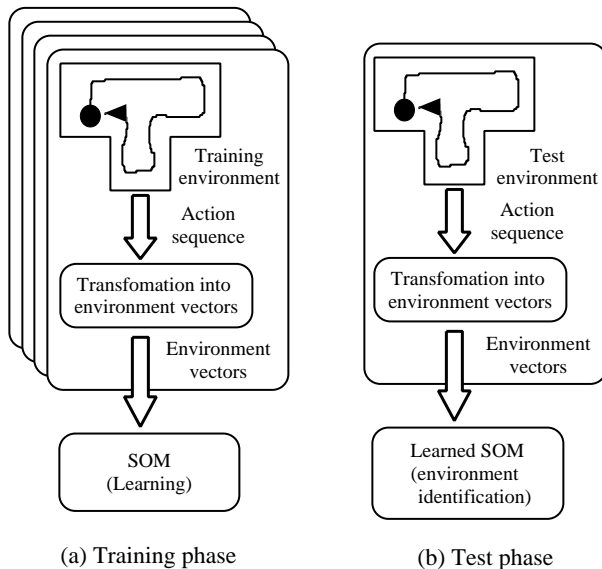


Fig. 1 An overview of AEM

境ベクトルを自己組織化マップに入力して、教師なし学習が行われる。このとき、どの環境ベクトルがどの部屋に対応するかという情報を明示的に与える教師は存在しない。そして、自己組織化マップに対し、それぞれの部屋の環境ベクトルが繰り返し与えられて学習が進んで行き、十分な訓練が行なわれた後、学習は終了する。

学習が終了すると、次は試験フェーズ (Fig.1(b)) になる。このフェーズでは、一つの試験環境 (通常は、訓練環境のうちの一つ) が与えられ、ロボットはその試験環境と訓練環境との同定を行なう。試験環境において、移動ロボットは訓練フェーズと同様に壁沿い移動を行ない、その結果行為系列とそれを交換した環境ベクトルが得られる。そして、その環境ベクトルが、訓練フェーズで学習済みの自己組織化マップに入力され、その競合層の勝者ノードを調べることにより、その試験環境と訓練環境が同定される。これにより、環境認識が行なわれる。以上の手続きの詳細を、次節以降で説明していく。

3. 行動ベース移動ロボット

本研究では、マイクロマウス用の小型の移動ロボット (日本システムデザイン製マイクロマウス 1, 100mm(W)×165mm(D)×135mm(H)) を実験で用いる。移動ロボットの外観を Fig.2 に示す。以下に、移動ロボットのセンサと駆動系について述べる。

3.1 センサ

パルス点灯により物体までの距離を反射強度で測定する赤外線近接センサを 4 個搭載している。前方を向いているものが 2 個、45° 斜め前方ものが 2 個、それぞれ左右に搭載されている (Fig.3)。ただし、この赤外線近接センサは、移動ロボットの近く (0cm から約 15cm) しか探知できず、さらに障害物が小さいものだと探知されにくい傾向がある。本研究では、移動ロボットの近くに壁があるかどうかの判定に赤外線センサを使用




Fig. 2 A mobile robot




Fig. 3 Positions of sensors and actuators

する。また、4 つの赤外線近接センサを搭載しているものの、壁沿い移動のために実際必要となるのは、左右どちらかの 2 つの近接センサだけである点に注意してほしい。左右いずれのセンサが使われるかは、移動ロボットの壁沿い移動する方向に依存する。時計回りなら左側に付いている 2 つのセンサだけが用いられ、反時計回りなら右側の 2 つだけが使われる。

さらに、精度の低い慣性型方向センサと移動距離センサも搭載している。慣性型方向センサは、マウスを回転させるときの角度の指定に、移動距離センサは、凸型のコーナーを曲がるときの行動に使用した。なお、このような知覚能力の低い移動ロボットを用いることは、我々の研究目的に沿ったものである。

3.2 駆動系

タイヤの配置は、Fig.3 のように、左右に 2 個の駆動輪、そして前後に各 1 個の操舵輪を配置している。この駆動輪はそれぞれ 1 個のステッピングモータでタイミングベルトを介して駆動される。前後の操舵輪は、それぞれの軸が逆回転するようにタイミングベルトを介して 1 個の DC サーボモータで駆動される。駆動輪と操舵輪は、サスペンションによって接続されており、路面状態に関わらず 4 輪を確実に接地することができ、さらにその場での回転が可能である。

また、移動ロボットは、シリアルポート (RS232C) を介して、ホスト計算機とのデータ送受信が可能である。

3.3 行動ベースアプローチ

移動ロボットは、壁沿い移動という単純な行動を行うが、環境変化への適応性を高めるため、多少の障害物に対してもほぼ同様の移動が可能なが望ましい。そのため、本研究では、Brooks の提案 [4] に始まる行動ベース (あるいは、リアクティブプランニング [23]) による移動ロボットを構築した。行動ベー

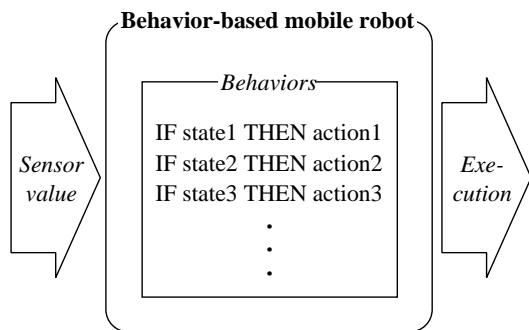


Fig. 4 A behavior-based mobile robot

スタブアプローチは、環境変化に対し頑健であり、精度の低い局所的なセンシングでも制御が可能である。また、環境モデル上でのプランニングなどの必要がなく、迅速な行動が可能である。なお本研究では、直接実行可能な断片的な行為からなる結論部と、センサ出力から直接判定可能な条件部で記述されたルールを行動 (behavior) と呼ぶ。行動ベースロボット構成を Fig.4 に示す。

観測されたセンサ情報が、複数の行動に直接与えられ、それぞれのルールが並列にその条件の適用を判定する。そして、条件が満たされたルールのうち、適切なものが選択され実行される。一つのルールが実行されると、また観測を行うというループが、環境の変化に対して十分に短い周期で繰り返される。

3.4 壁沿い移動

本研究では、部屋は形状の違いで識別される。そのためには、入力となる行動の系列が部屋の壁面の形状を反映したものでなければならない。例えば、ランダムウォークにより部屋の中を徘徊すると、どの2つの部屋についても、そこで得られる行為系列は類似したものとなってしまう、それらの差異を見つけることは難しい。また、過去の同じ部屋での移動との類似性を見つけるためには、再現性のある移動が必要である。以上の条件を満たす行動として、本研究では壁沿い移動を採用し、部屋を壁沿いで一周したときに移動ロボットは停止することにした。

壁沿い移動により、ある環境で実行された行為系列の長さからおおまかな部屋の大きさ (より正確には、壁面の長さ) を知ることができるし、コーナーに反応する行動を組み込むことにより、行為系列から部屋のコーナーの情報も獲得できる。さらに、経験的に同じ部屋での壁沿い移動の経路は大きく変化することはないため、再現性が期待できる。

本研究において壁沿い移動のために、我々の設定した行動は、以下の4つである。なお、ステアリングは、正面方向に向かって相対的であり、ロボットは時計周りに壁沿い移動をする。

- 行動 A (凹コーナーを曲がる)
IF 前方の壁が 10cm 以内に近づいて、左 10cm 以内に壁がある
THEN 時計方向に 40° 回転する (Fig.5(a) 参照)
- 行動 B (凸コーナーを曲がる)
IF 左右 5cm, 前方 10cm に障害物なし
THEN 10cm 前方に進み、反時計方向に 40° 回転する。




Fig. 5 Behavior A, B, C, D

(Fig.5(b) 参照)

- 行動 C (壁に近付きすぎたら離れる)
IF 壁に 5cm 以内に近づいた
THEN 右に 13.5° ステアリングを切る (Fig.5(c) 参照)
- 行動 D (壁から離れすぎたら近付く)
IF 壁から 5cm 以上離れた
THEN 左に 13.5° ステアリングを切る (Fig.5(d) 参照)

以上の4つの行動を適時実行するだけで、かなりスムーズな壁沿い移動が可能なのが実験的にわかっている。実際に移動ロボットを走らせてみると、壁に沿って移動している時は、行動 C と行動 D が大体交互に繰り返し実行され、凹と凸のコーナーでは、行動 A と行動 B がそれぞれ2回連続して実行されることにより、コーナーを曲がるのが観察された。

4. 環境ベクトルの生成

移動ロボットが壁沿い移動により各部屋を一周することで、そのとき実行された行為系列が獲得される。直観的に、この系列は、部屋の形状を反映していると考えられるので、この系列を入力ベクトルに変換して、自己組織化マップで学習させることで、形状の違う部屋の識別が可能になる。行為系列から変換されたベクトルは、環境の構造を表すものであり、我々はそれを環境ベクトルと呼ぶ。

4.1 行為系列から環境ベクトルへの変換

行為系列を自己組織化マップに入力するためには、行為系列を環境ベクトルに変換する必要がある。この際、様々な変換が考えられるが、環境ベクトルを自己組織化マップが適切にクラスタリングできるような変換を設定することが重要である。自己組織化マップは、単に入力ベクトル間のユークリッド距離の大小関係保持したまま、次元の低い疎な離散ベクトル値に変換するだけなので、元の環境ベクトルの空間上で望ましいクラスタリングができていないとよい結果が得られない。つまり、入力環境ベクトルの空間において1つのクラスタになって欲




Fig. 7 Robustness of BI-transformation




Fig. 8 A self-organizing map

の最大のものが先頭にくるようにシフトさせて用いる。

- (2) 試験フェーズ：試験環境で得られた環境ベクトルについても、(1)と同様にシフトをして用いる。

5. 自己組織化マップによる環境認識

5.1 自己組織化マップ

ここでは、コホーネンらにより開発された自己組織化マップ (self-organizing map) [12] [13] を簡潔に説明する。自己組織化マップは、入力層と競合層からなる 2 層ネットワーク (Fig.8) であり、入力層のノード (入力ノード) と競合層のノード (競合ノード) が重みつきリンクで完全結合されている。入力ベクトルが与えられると、入力ノードは入力ベクトルの対応した要素の値をとる。それから競合ノードは、入力と重みとの距離を計算し、最小の距離をもつ唯一の勝者ノードを決定する。そして、その勝者ノードの近傍のノードの重みが更新される。

今、入力ベクトルと、入力ノード全体から一つの競合ノード i へのリンクの重みを、それぞれ次の E , U_i とする。

$$E = [e_1, e_2, \dots, e_n]$$

$$U_i = [u_{i1}, u_{i2}, \dots, u_{in}]$$

自己組織化マップは、まず入力ベクトルに対する各競合層のノードの一致度 $\|E - U_i\|$ を計算する。この一致度は、下式のような重みと入力ベクトルのユークリッド距離で計算される。

$$\|E - U_i\| = \sqrt{\sum_j (e_j - u_{ij})^2}$$

一致度の最も低い (最も一致する) ノードを勝者ノード (winner node) と呼ぶ。勝者ノードを c とすると、 c は以下の式を満たす。

$$\|E - U_c\| = \min_i \{\|E - U_i\|\}$$

ここで、最小値はすべての競合ノードから選択される。複数のノードが最小の一致度を持つなら、 i が最小のノードが選ばれる。

勝者ノードが決まると、その近傍の競合ノードの重みが更新される。近傍は、競合層の次元に応じて定義される。例えば、競合層が 2 次元なら、勝者ノードを重心とする正方形がよく用いられる。近傍のノードの重みの更新式は下式である。なお、 α は、学習率であり、1 回の重み更新により、学習が進む程度を決定する。

$$u_{ij}^{\text{new}} = u_{ij}^{\text{old}} + \Delta u_{ij}$$

$$\Delta u_{ij} = \begin{cases} \alpha(e_j - u_{ij}) & : \text{ノード } i \text{ が近傍にある} \\ 0 & : \text{それ以外} \end{cases}$$

以上の処理を入力ベクトルが与えられる毎に繰り返す。また、学習率と近傍のサイズは、学習が進むにつれて減少させる場合が多い。後述するように、本研究の実験においても、学習の進展につれて、学習率と近傍のサイズを小さくしていく方法を採用している。

5.2 試験フェーズでの環境同定法

自己組織化マップの更新がほとんど無くなり、学習が収束してくると、いくつかの限られた競合ノードだけが勝者になるという状態が生じる。それらの勝者ノードは、部屋に対応していると考えられ、我々はそれらを r ノードと呼ぶ。更新が無くなると学習は終了し、 r ノードが得られる。得られた r ノードの個数が部屋数に対応している。

次に、判定すべき部屋の環境ベクトルが、これまで学習された部屋のどれと同じであるかを同定する必要がある。そこで、試験環境から得られた環境ベクトルと各 r ノードの重みとのユークリッド距離が計算され、その距離が最小の r ノードに対応する部屋と同定される。

6. 部分判定

これまで述べてきた方法では、移動ロボットが部屋を一周した後に、その一周分の行為系列を入力として、部屋の判定を行っていた。しかし、特徴的な情報が含まれていれば、完全に一周しなくても、部分的に壁沿い移動して得られた行為系列から部屋の認識を行なうことも可能と考えられる。そこで、部分的な情報から部屋の判定を行なう手続きを考案した。その手続きを以下に示す。最も長い壁が先頭になるように環境ベクトル




Fig. 9 An experimental environment

をシフトして比較し、 r ノードとの距離がしきい値以下になったら同定したと見なす方法である。

部分情報からの部屋の判定手続き

- (1) 最も長い壁が先頭になるように行為系列をシフトして、自己組織化マップで学習させる。
- (2) 移動ロボットから、逐次的に部分情報を受け取り、コーナーの検出毎に行為系列を BI 変換により環境ベクトルに変換し、下記のシフトを行なう。
 - (a) すべての履歴の中で最も長い壁を見つけ、それを先頭にそれから以後に得られたベクトルを残し、他のベクトル値は 0 として、部分環境ベクトルをつくる。
 - (b) もし最も長い壁が複数ある場合は、それぞれについて (2a) の処理を行ない、部分環境ベクトルをつくる。
- (3) (2) で得られたそれぞれの部分環境ベクトルと (1) で得られたそれぞれの r ノードの重みベクトルとの距離を計算し、それがしきい値 ξ 以下なら、その r ノードの部屋と判定。最も長い壁を先頭にするようなシフトを行なうため、壁沿い移動が部屋の壁面のどの位置から開始されてもよい。問題は、しきい値 ξ の決定であるが、ここでは実験をしながら経験的に決めるとする。

7. 実験方法

7.1 実験環境

前述の移動ロボットを用いて、実機による実験を行った。ホスト計算機は、IBM-PC/AT 互換機 (Intel Pentium 133MHz, RAM64M) を用い、PC-UNIX の Linux 上で C++ を用いてプログラミングをした。また、ホスト計算機と移動ロボットは、RS232C を介して通信する。壁沿い移動を行なうための処理は、移動ロボット上で行ない、得られた行為系列をホスト計算機に送り、自己組織化マップでの学習と部屋の認識の処理は、ホスト計算機上で行なう。

実験環境は、白いプラスチック板により高さ 13cm の囲いをつくることで部屋を構成し (Fig.9)、そこで実機の移動ロボットが壁沿い移動を行なった。なお、部屋を壁沿い移動で一周したことの認識は、ロボットの内界センサ (慣性型方向センサと移動距離センサ) を用いたデッドレコニングで行なった。

7.2 実験方法

まず、訓練フェーズでは、移動ロボットに、 N 個の部屋を 6 回づつ壁沿い移動させ、合計 $6N$ 個の行為系列および変換され

た環境ベクトルを得た。そして、それらのうち各部屋について一つづつランダムに選んだ N 個の環境ベクトルを順序固定で繰り返し自己組織化マップへの入力ベクトルとして与えて学習を行なった。

そして、試験フェーズでは、残りの各部屋につき 5 個の環境ベクトル (総数は、 $5N$) が学習済みの自己組織化マップに与えられ、訓練環境と試験環境の同定、つまり環境認識が行なわれる。

7.3 自己組織化マップの設定

ここでの実験では、移動ロボットは、各部屋を 1 周するのに 1000 程の行為を実行する。当然ながら、自己組織化マップの入力層ノード数は、その実行される行為数よりも多く設定する必要がある。以下に、自己組織化マップのパラメータの設定値を示す。競合層のトポロジーと競合層のノードの重みの初期値に関しては、自己組織化マップのパフォーマンスに影響を与える可能性があるため、典型的な複数の設定を試してみることとした。

- 入力層ノード数: 1300
- 競合層ノード: 128
- 競合層のトポロジー: 1 次元の線分 (端あり) と環状 (端なし)。競合ノード数を一定にしておけば、計算コストを抑えたままで競合層の次元を上げていくことが可能である。しかし、競合層を 2 次元と 3 次元にして予備実験した結果、識別精度の向上はみられなかったため、1 次元の競合層を用いた。
- 競合層のノードの重みの初期値: $0.5 \pm 10\%$, $1.5 \pm 10\%$, $4.0 \pm 10\%$ の 3 種類。
- 総訓練回数 (訓練フェーズで入力として与えられる環境ベクトルの総数): 経験的に妥当とされている 100000 回に設定。

また、 t 回目の学習における、学習率 α と近傍の幅 d を下式を用いて、学習進行とともに減少させた。

$$\alpha_t = 0.8 \left(1 - \frac{t}{100000} \right) \quad d_t = 16 \left(1 - \frac{t}{100000} \right)$$

8. 各種実験と結果

8.1 7 種の部屋の認識

まず、Fig.10 に示す 7 つの部屋について実験を行なった。図には、部屋の形状とそこでの行為系列から得られた環境ベクトルが示されている。なお、大きい方の正方形の一辺が 146cm で、図中の各部屋は同じスケールである。また、この実験では部分判定は用いず、一周した行為系列を用いた。なお、部分判定の実験は、8.3 で行なわれる。

実験結果は、競合層のトポロジーと競合層のノードの重みの初期値に関するすべての設定において、すべての試験環境の正しい認識が行なわれ、認識精度 $\left(= \frac{\text{正しく認識された部屋数}}{\text{全体の部屋数}} \times 100 \right)$ は 100% であった。また、これらの行為系列は、障害物はないものの、同じ壁に沿って移動していても実行される行為は、センサとアクチュエータのノイズの影響によりまったく同じものにはならないことに注意してほしい。

8.2 20種の部屋の認識

次に、部屋を Fig.11 のような 20 個に増やして、実験を行った。ここでも、E-3 の一辺が 146cm で、図中の各部屋は同じスケールである。訓練フェーズで自己組織化マップに与えた環境ベクトルの系列は、[E-4, E-5, E-1, E-12, E-2, E-8, E-9, E-3, E-7, E-11, E-10, E-20, E-19, E-18, E-14, E-17, E-13, E-16, E-15, E-6] であり、一周した行為系列を用いた。この訓練により学習された自己組織化マップの認識精度は、Table 1 のようになった。

この結果から、まず自己組織化マップの重みの初期値と競合層の形状には認識精度はあまり依存していないことがわかる。また、7 種類の部屋の認識精度が 100% だったのに比べ、部屋数が増えた影響で、認識精度が低下していることがわかる。

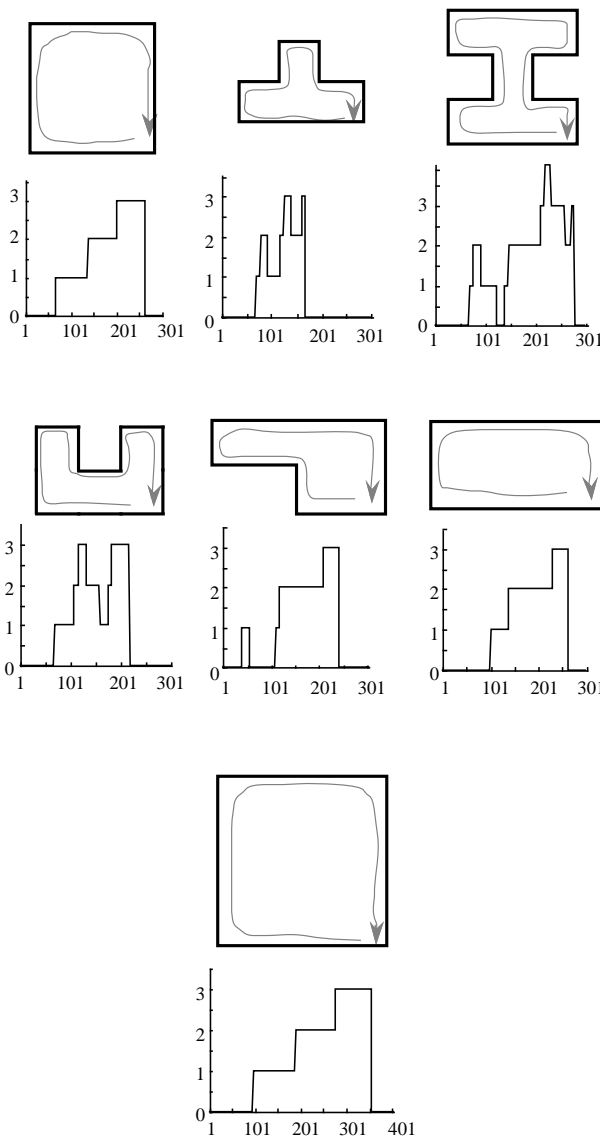


Fig. 10 Seven rooms

Table 1 Experimental results on 20 rooms

Initial weights	Sape: line	Sape: circle
$0.5 \pm 10\%$	74%	69%
$1.5 \pm 10\%$	74%	74%
$4.0 \pm 10\%$	74%	69%

8.3 部分判定

次に、先の実験で用いた 20 の部屋について、部分判定の実験を行った。ここでは、各環境について、訓練環境と試験環境を合わせた 6 つの環境ベクトルを用いて、学習後の自己組織化マップによる環境認識を行った。実験結果として、各部屋での認識精度を Table 2 に示す。なお、自己組織化マップの設定は、競合層の形状は線分、競合層の重み初期値は $1.5 \pm 10\%$ を用いた。




Fig. 11 20 rooms

Table 2 Experimental results

E-1	50%	E-2	83%	E-3	100%	E-4	100%
E-5	33%	E-6	33%	E-7	83%	E-8	100%
E-9	100%	E-10	67%	E-11	100%	E-12	83%
E-13	17%	E-14	67%	E-15	17%	E-16	17%
E-17	67%	E-18	17%	E-19	67%	E-20	17%

部分判定の全体の認識精度は、60.8%で、周回率は、47.8%だった。ここで、 $\text{周回率} = \frac{\text{判定に要した行為系列の長さ}}{\text{行為系列の全長}} \times 100$ である。認識精度が悪いのは、BI変換は障害物の影響は小さくできるが、§6における部分判定の手続きでは、まだ移動していないところのベクトル値をすべて0としてしまうことが影響していると考えられる。一周回った場合の認識結果も80%弱なので、それを考慮するとまずまずの結果だといえる。ただ、Table 2からわかるように、認識精度は部屋の形状に強く依存しており、比較的小さい部屋の場合が認識率が悪かった。

8.4 障害物のある部屋の認識

さらに、8.1で用いた7つの部屋の壁面に障害物を置いた9つの部屋について、一周回った行為系列により実験を行なった。なお、自己組織化マップの設定は、競合層の形状は線分、競合層の重み初期値は $1.5 \pm 10\%$ を用いた。その結果、5つだけが正しく認識できた。正しく認識できた部屋とできなかった部屋を、Fig.12に示す。

Fig.12(a)では、壁に接した、一つの障害物が、2つの小さな障害物に関しては認識がうまくいっている。しかし、Fig.12(b)のように、2つの大きな障害物や、壁に対し斜めになっている障害物がある場合は認識に失敗していることがわかる。ただし、本来は、障害物が多く存在する場合、それらの部屋を同じ部屋と認識すべきか否かは、ロボットというエージェントがどのような目的のために部屋の認識を行なうのかに依存する。

9. 問題点及び今後の課題

AEMの問題点と、今後その問題に対しどのように対処するかについて議論する。

9.1 インクリメンタルな学習

自己組織化マップは、基本的に訓練例をバッチ的に処理する。つまり、新しい訓練例が得られたときに、それまでの学習結果と統合しながら学習を進めるインクリメンタルな学習はできない。よって、当然本研究のAEMもインクリメンタルな学習は不可能であり、大きな制約となっている。この問題に対しては、自己組織化マップの学習則を改良して、インクリメンタルな学習を実現する研究[9]が報告されており、その手法の適用が考えられる。

9.2 AEMに適した行動の獲得

本研究では、壁沿い移動をAEMにとって適切な行動として用いた。では、なぜ壁沿い移動が適切だったのかと言うと、それは、部屋の輪郭の形状を基に環境認識を行なうと仮定していたからである。よって、例えば、部屋の形状は同じでも、明かりがついているか否か、また部屋に障害物があるか否かで環境認識を行なう場合は、壁沿い移動ではうまくいかない。




Fig. 12 Environments with obstacles

本来なら、AEMで具体的にどのような環境を識別するのが決まった後に、その認識に対して適切な行動が設定されるべきである。しかも問題なのは、一般に状態から行為のマッピングである行動の候補は、非常にたくさんあり、その候補から様々な環境に対してAEMに適切な行動を見つけることは、人間の設計者にとって容易なことではない。よって、その適切な行動を自動的に獲得するメカニズムが必要となる。この問題に対処するために、現在我々は遺伝的アルゴリズムを使って、AEMに適切な行動を自動獲得する研究を行なっている[20]。そこでは、帰巢性、認識精度、認識効率を統合した適合度関数を用いて、AEMに適切な行動の探索が行なわれる。そして、予備的な実験では、実際に壁沿い移動以外の行動が獲得されている。

10. まとめ

精度の低いセンサをもつ行動ベースの移動ロボットが壁沿い移動することによって、得られる行為系列をBI変換により環境ベクトルに変換し、コホーネンの自己組織化マップによる教師なし学習を行ない、部屋の認識を行なう方法であるAEMを提案した。さらに、部分的に部屋を壁沿い移動するだけで、判定が可能である手続きを考案した。

マウスにより実機を用いた実験を行ない、その結果良好な結果を得た。また、障害物がいくつか置かれた部屋の認識についても、おおむね良い結果が得られた。これらの実験により、本研究の手法の有効性が検証された。また、このような結果から、単純な知覚能力でも、環境認識を達成するロボット

を構築できる可能性が示されたと考える。

参考文献

- [1] E. M. Arkin, L. P. Chew, D. P. Huttenlocher, K. Kedem, and J. S. B. Mitchell: "An Efficiently Computable Metric for Comparing Polygonal Shapes", IEEE Transaction on Pattern Analysis and Machine Intelligence, vol. 13, no. 3, pp. 209–216, 1991.
- [2] M. Asada: "Map Building for A Mobile Robot from Sensory Data", IEEE Transaction on Systems, Man, and Cybernetics, vol. 20, no. 6, pp. 1326–1336, 1990.
- [3] R. D. Berns and U. Zachmann: "Reinforcement Learning for The Control of An Autonomous Mobile Robot", Proc. of the 1992 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp. 1808–1815, 1992.
- [4] R. A. Brooks: "A Robust Layered Control System for A Mobile Robot", IEEE Transaction on Robotics and Automation, vol. 2, no. 1, pp. 14–23, 1986.
- [5] J. L. Crowley: "Navigation of An Intelligent Mobile Robot", IEEE Transaction on Robotics and Automation, vol. 1, no. 1, pp. 31–41, 1985.
- [6] R. Dillmann, F. Wallner, and R. Graf: "Real-Time Map Refinement by Fusing Sonar and Active Stereo-Vision", Proc. of the 1995 IEEE Int. Conf. on Robotics and Automation, pp. 2968–2973, 1995.
- [7] A. Elfes: "Sonar-Based Real-World Mapping and Navigation", IEEE Transaction on Robotics and Automation, vol. 3, no. 3, pp. 249–265, 1987.
- [8] A. Elfes: "Using Occupancy Grids for Mobile Robot Perception and Navigation", IEEE COMPUTER (June), pp. 46–57, 1989.
- [9] P. Gaussier and S. Zrehen: "A Topological Neural Map for On-line Learning: Emergence of Obstacle Avoidance in a Mobile Robot", Proc. of the Third Int. Conf. on Simulation of Adaptive Behavior, pp. 282–290, 1994.
- [10] 石岡宏治, 開一夫, 安西祐一郎: "複数の自律移動ロボットの個体差を考慮した地図獲得システムの設計と実装", 日本ロボット学会誌, vol. 12, no. 2, pp. 846–856, 1994.
- [11] 加藤浩仁, 石黒浩, 辻三郎: "統計的解析による複雑な環境における環境モデルの獲得", 日本ロボット学会誌, vol. 14, no. 5, pp. 660–667, 1996.
- [12] T. Kohonen: "Self-Organization and Associative Memory", Springer-Verlag, 1989.
- [13] T. Kohonen: "The Self-organizing Map", Proc. of the IEEE, pp. 1464–1480, 1990.
- [14] M. J. Mataric: "Integration of Representation into Goal-Driven Behavior-Based Robot", IEEE Transaction on Robotics and Automation, vol. 8, no. 3, pp. 14–23, 1992.
- [15] T. Nakamura, S. Takamura, and M. asada: "Behavior-based Map Representation for a Sonar-Based Mobile Robot by Statistical Methods", Proc. of the 1996 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp. 276–283, 1996.
- [16] U. Nehmzow and T. Smithers: "Map-building Using Self-organizing Networks in Really Useful Robots", Proc. of the First Int. Conf. on Simulation of Adaptive Behavior, pp. 152–159, 1991.
- [17] U. Nehmzow and T. Smithers: "Using Motor Actions for Location Recognition", Proc. of the First European Conference on Artificial Life, pp. 96–104, 1991.
- [18] Willian D Smart and John Hallam: "Location Recognition in Rats and Robots", Proc. of the Third Int. Conf. on Simulation of Adaptive Behavior, pp. 174–178. The MIT Press, 1994.
- [19] S. Tsuji and S. Li: "Memorizing and Representing Route Scenes", Proc. of the Second Int. Conf. on Simulation of Adaptive Behavior, pp. 225–232, 1992.
- [20] S. Yamada: "Learning Behaviors for Environment Modeling by Genetic Algorithm", Proc. of The First European Workshop on Evolutionary Robotics, pp. 179–191, 1998.
- [21] S. Yamada and M. Murota: "Applying Self-organizing Networks to Recognizing Rooms with Behavior Sequences of A Mobile Robot", Proc. of IEEE Int. Conf. on Neural Networks, pp. 1790–1794, 1996.
- [22] S. Yamada and M. Murota: "Unsupervised Learning to Recognize Environments from Behavior Sequences in A Mobile Robot", Proc. of the 1998 IEEE Int. Conf. on Robotics and Automation, pp. 1871–1876, 1998.
- [23] 山田誠二: "リアクティブプランニング", 人工知能学会誌, vol. 8, no. 6, pp. 729–735, 1993.

山田 誠二

1960年10月11日生。1984年大阪大学基礎工学部卒業。1989年同大学院博士課程修了。同年基礎工学部システム工学科助手。1991年より大阪大学産業科学研究所講師。1996年4月より、東京工業大学大学院総合理工学研究科助教授、現在に至る。工学博士。人工知能、特に知的エージェント、ロボット学習、WWWでの情報検索に興味をもつ。人工知能学会、情報処理学会、日本認知科学会、AAAI、IEEE各会員。

(日本ロボット学会正会員)

室田 盛道

1971年10月10日生。1995年大阪大学基礎工学部制御工学科卒業。1997年大阪大学大学院基礎工学研究科物理系専攻博士前期課程修了。同年日本電信電話株式会社入社。現在に至る。

(日本ロボット学会正会員)