

見え様を用いた移動ロボットの行動獲得

正員 川端邦明 (理化学研究所)

非会員 石川達也 (富士ソフトABC)

正員 藤井輝夫 (東京大学生産技術研究所)

正員 浅間一 (理化学研究所)

非会員 遠藤勲 (宇都宮大学)

A Behavior Acquisition for a Mobile Robot using View Information

Kuniaki Kawabata, Member (The Institute of Physical and Chemical Research(RIKEN)), Tatsuya Ishikawa, Non-member (FUJISOFT ABC Inc.), Teruo Fujii, Member (Institute of Industrial Science : University of Tokyo), Hajime Asama, Member (The Institute of Physical and Chemical Research(RIKEN)), Isao Endo, Non-member (Utsunomiya University)

In this paper, we propose a behavior learning method of a mobile robot using visual information in real environment. View information, which is a characteristic of image, is utilized for input value in proposed method. The input value is a sort compressed data that original image from camera is projected. Proposed system consists of two networks for state expression and behavior generation. State expression network, which is based on self-organizing algorithm, categorizes the robot's states from view information. Therefore, state expression network acquires how to express the state of system in real environment. Also, behavior generation network autonomously acquires the robot's behaviors using output value of state expression network. For training behavior generation network, we utilize Actor-Critic method as a sort of unsupervised learning scheme. We report some experimental running results using a mobile robot in real environment. As the result, the mobile robot generates adaptive behaviors utilizing visual information, autonomously.

キーワード：Behavior Acquisition, Self-Organizing Algorithm, Reinforcement Learning

1. はじめに

近年、ロボットや知的エージェントの自律的な行動実現の技術に関する研究・開発が盛んに行われている。特に実環境では、センシング情報に基づいて多様な状態を自律的に認識し、適正な行動を生成する制御技術が必要になる。Brooksは、それまでの人工知能のアプローチでは自律ロボットの実現は困難であると指摘し、サブサンプション・アーキテクチャを提案した⁽¹⁾。この手法は行動モジュールを重層的に組み合わせることで、センサ入力に対して行動を反射的に生成するものである。しかし、この手法では合目的行動の生成に関する能力に欠けている上、各モジュールは設計者の意図に依存して構成される。これに対して、環境内の試行を繰り返すことで適応的な行動生成を行う強化学習法に関する研究が近年盛んに行われている⁽²⁾⁽³⁾。浅田ら⁽⁴⁾は、移動ロボットによるボール押し作業の行動獲得を強化学習によって実現している。この手法では、画像処理によ

り抽出した物体に関する各種パラメータで入力ベクトル空間を構成（離散化）し、行動要素を用いることで状態空間を分割する手法を提案した。しかし、多様な状態が存在する実環境下でロボットが行動することを考えると、センサ入力情報に何らかの解釈を加えた離散化には限界があると考えられる。この点を考慮にいれて、小林ら⁽⁵⁾はセンサ入力に対して状態空間および行動空間を同時生成する手法について研究を行うことで自律的に適応するシステムの構築を目指している。また、矢入ら⁽⁶⁾は冗長なセンサ情報を抽象化し、状態の切り出しを行う手法について提案している。

また、神経科学においても感覚情報に基づく状態認知と行動生成に関する研究が行われており、ラットの海馬体に存在する場所細胞がナビゲーションに関与していると報告されている⁽⁷⁾⁽⁸⁾。N.Burgessら⁽⁹⁾⁽¹⁰⁾⁽¹¹⁾は、視覚入力から特定の場所を特徴づける場所細胞をモデル化して実験結果を報告している。青田ら⁽¹²⁾は、視覚入力のみで場所細胞をモデル化する場合、不自然な視覚情報の収集が必要にな

ると指摘し、視覚入力だけでなく行動も用いて場所細胞の発現をモデル化している。これらは、場所細胞の厳密なモデル化を目指した研究である。一方で、これらの研究から得られた情報処理に関する機能的な特徴は、自律的に実世界を認識・行動する技術を開発する上で参考になる点が多い。そこで、本研究では場所細胞の機能のようにセンサ情報から自律的に状態の特定を行い、それに基づいて行動獲得を行うシステムの構成法について検討する。特に本論文では、動的な状態変化を伴うシステムの典型である視覚センサを搭載した実移動ロボットの行動獲得に関して議論を進めていく。

2. 見え様を用いた視覚情報処理

本節では、画像情報を用いた情報処理系を自己組織的に構築する手法について検討する。

〈2・1〉 見え様 ここでは、外界情報に対して人為的な前処理による意味づけ等を行わず、自律的に状態を抽出・表現する手法について検討する。ここで、一般的な画像処理を行わずに視覚情報を入力に用いることすると、各画素を入力として扱うという方法が単純に考えられる。しかしながら、取り込んだ画像の各画素を入力として処理するために入力点数が莫大になり、現実的な方法とはいえない。また、画像情報の間引きが一般的な情報量軽減方法として考えられるが、この方法では大きな情報欠落を引き起こすことになる。しかしながら、本研究の目的の一部である自己組織的な状態特定処理の実現を現実的に考えれば、情報圧縮技術の導入は必要不可欠である。そこで、ここでは画像の特徴である見え様を入力情報として用いることを考える。見え様（画像の特徴）を表現する手法はいくつか考えられるが、本研究では画像の射影情報を特徴として扱う。射影とは図1の例が示すように、画像の列方向及び行方向の全画素の濃度情報をそれぞれ横および縦方向へ単純に積和することである。つまり、射影情報とは2次元画像情報を積和することで画像情報を圧縮したものである。ここでは、作業環境内の照明は一定であるものとし、單一色で画像が占められているような特徴の無い景色は対象外としている。この射影処理により、 $a[\text{pixel}] \times b[\text{pixel}]$ 個の要素からなる画像情報が $a + b$ 個に圧縮され、その率は $(a + b)/ab$ となる。これにより、各要素を連結することで1次元的な特徴情報として表現され、情報の圧縮および情報量の常時一定化が可能になる。この情報の常時一定化により、自己組織的に処理系を獲得する手法に適用する際に入力の規模が固定されることから、システム仕様に複雑な変更を加える必要が無くなる。このことは、システム構成を行う上で大きな利点である。さらに、射影を用いることで、形状等に基づいた意味づけのない画像の特徴量情報としての表現が可能になった。以下では、自己組織的に特徴を抽出する手法について検討する。

〈2・2〉 状態表現ネットワーク 実環境内で視覚情報から状態を抽出することを考えると、予めモデルや教師データ

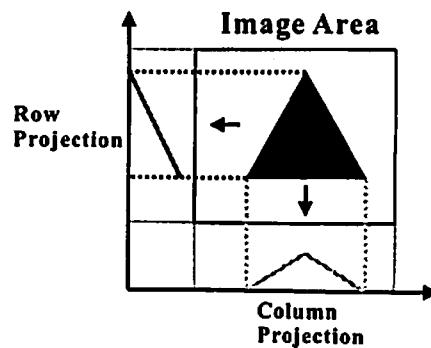


図1 画像の射影情報

Fig. 1. Projected Image Information

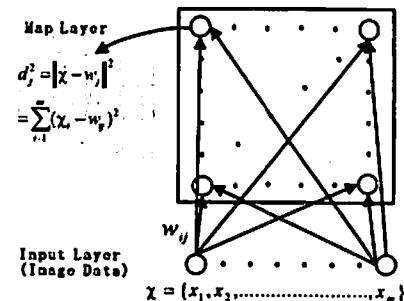


図2 自己組織化写像による状態表現ネットワーク

Fig. 2. State Expression Network

タを与えてパターンマッチングをとるといった手法は現実的ではない。そこでここでは、射影情報からの状態表現を自律的に行う手法として、自己組織化アルゴリズムの導入を検討する。自己組織化写像は、Kohonen⁽¹³⁾によって提案された教師無しニューラル・ネットワークの一種であり、高次元入力ベクトルの隣接関係を保持しつつ非線形写像を実現する場合等に利用される。

ここでは、図2に示す入力層とマップ層による2層構造ネットワークを用いて、見え様からの状態抽出を行う状態表現ネットワークを構成する。この際、時刻 k において状態表現ネットワークへの射影情報を用いた入力ベクトルを $x(k)$ とする。

$$x(k) = [x_1(k) \ x_2(k) \ \dots \ x_m(k)]^T \quad \dots \dots \dots \quad (1)$$

また、入力層の各ノード ($i = 1, 2, \dots, m$) からマップ層のノード j への結合荷重ベクトル w_j は以下で表される。

$$w_j(k) = [w_{1j}(k) \ w_{2j}(k) \ \dots \ w_{mj}(k)]^T \quad \dots \dots \dots \quad (2)$$

これらにより、 m 入力 n 出力の状態表現ネットワークは以下の自己組織化アルゴリズムに基づいて学習を進める。

- (1) 時刻 $k = 0$ において、ネットワークの結合荷重ベクトル $w_j(0)$ を初期化する。
- (2) 時刻 k におけるマップ層の各ノード j へ結合荷重ベクトルと入力ベクトルのユークリッド距離の自乗



図3 網膜チップカメラモジュール
Fig. 3. Articifial Retina LSI with Lens

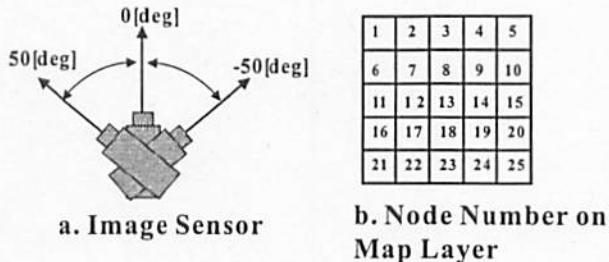


図4 状態分け基礎実験
Fig. 4. Basic Experiment

値 $d_j^2(k)$ を式(3)で計算する。

$$d_j^2(k) = \|\chi(k) - w_j(k)\|^2 \\ = \sum_{i=1}^m \{x_i(k) - w_{ij}(k)\}^2 \quad \dots \dots \dots (3)$$

(3) $d_j^2(k)$ が最小となるノードを勝者ノード c として選択する。

(4) 式(4)により、勝者ノードと近傍ノードの結合荷重ベクトルを更新する。

$$w_{ij}(k+1) = w_{ij}(k) + h_{cj}(k) \{x_i(k) - w_{ij}(k)\} \quad (4)$$

ここで $h_{cj}(k)$ は近傍関数であり、式(5)に表されるガウス関数を用いた。

$$h_{cj}(k) = \alpha(k) \exp\left(-\frac{\|r_c - r_j\|^2}{2\sigma^2(k)}\right) \quad \dots \dots \dots (5)$$

r_c, r_j はそれぞれマップ層における勝者ノード c とノード j の位置ベクトルである。さらに $\alpha(k), \sigma(k)$ は学習率係数および近傍関数カーネルの幅であり、両者とも k に関する単調減少関数である。

(5) $k = k+1$ として、(2)へ戻る。

この演算を十分に繰り返すことで、勝者ノードによる状態判別が可能になる。ただし、入力状態を十分に判別するためには相当数のマップ層ノード数を用意しなければ、入力ベクトルの多様性に対して対応できない。この点を解決する手法に関しては、後述の基礎実験のところで併せて検討していく。



図5 実験環境
Fig. 5. View for Experiment

〈2・3〉 状態表現に関する基礎実験 ここでは、状態表現ネットワークの評価を行うためにネットワークの出力が実際の視覚入力に対してどのように振る舞うかを観測する。実際には、視覚センサにパン機構を設置してセンサ部を左右に回転させて実験を行った。ここでは、視覚センサとして射影機能が付加されている三菱電機社製の網膜チップにレンズを付加した解像度 $128[\text{pixel}] \times 128[\text{pixel}], 8[\text{bit}]$ モノクロ仕様のカメラモジュールを視覚センサとして用いた(図3)。このカメラモジュールを用いて、画像の射影情報を取り出すことで状態表現ネットワークへの入力ベクトルを構成する。実際の入力ベクトル $\chi(k)$ は画像の縦横方向の射影情報を連結して用いるため、式(6)のように 256 の要素から構成される。

$$\chi(k) = [X_{pr1}(k) \ X_{pr2}(k) \ \dots \ X_{pr128}(k) \\ Y_{pr1}(k) \ Y_{pr2}(k) \ \dots \ Y_{pr128}(k)]^T \quad (6)$$

X_{pr}, Y_{pr} は、それぞれ時間 k における各画素の行方向および列方向に関する積和値である。また、添え字は行および列の位置を表すものである。一方、状態表現ネットワークの出力ノード数は、 5×5 の 25 個として正方形に配置し、図4b のように番号を付加することでノードを特定した。ここで、出力層の端ノードが勝者ノードとして選択された場合にも前述の近傍関数を用いた滑らかかつ均等な学習効果をあたえるため、正方形に配置された出力層の上辺、下辺および左辺、右辺はそれぞれリング状に連結しているとして結合荷重の更新を行った。ここで視覚センサの稼働範囲は、正面を $0[\text{deg}]$ として左へ $50[\text{deg}]$ 、右へ $-50[\text{deg}]$ とし、回転速度値は $13[\text{deg/sec}]$ とした(図4a)。実験は、屋内環境の任意の場所に設置して行った。図5は、このときの実験環境を示している。ここで、学習中の単位サンプル時間は $100[\text{msec}]$ とし、結合荷重ベクトル w は乱数により初期化した。この条件で、カメラモジュールが左右往復運動する間に 1000 回の自己組織化演算を行った。その後、自己組織化演算を止めて任意の入力を与えて状態表現ネットワークの出力を観測した。図6は、本実験での各位置における状態表現ネットワークの勝者ノードを示したものである。これより、 $-10[\text{deg}] \sim 20[\text{deg}], -50[\text{deg}] \sim -30[\text{deg}]$ の範囲においては同じノードが勝者ノードとして選択されている。これは、この区間の各場所での入力ベクトルの変化が少ないことが原因の一つと考えられる。また、前述のように実験

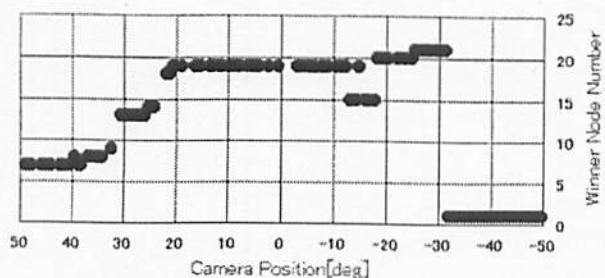


図 6 勝者ノード

Fig. 6. Winner Node Number

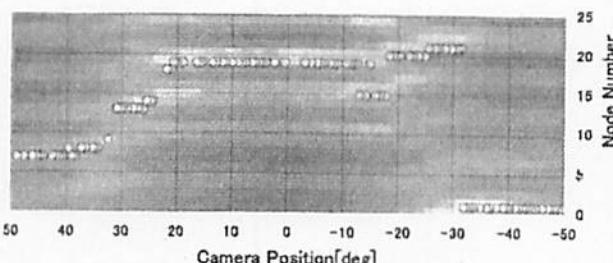


図 7 勝者ノードおよび各ノード出力

Fig. 7. Winner Node and Output of Each Node

で用いたマップ層ノード数が入力の多様さに対して十分用意されていないことも大きな要因の一つと考えられる。ただし、入力ベクトルの複雑さに対応できるほどのマップ層ノード数を用意することは現実的ではない。ここで、勝者ノードのみを用いた状態判定は不十分であることをうけて、我々は状態表現ネットワークのマップ層の全ノード出力値に注目した。図 7 は、視覚センサの各位置におけるマップ層の各ノード出力値をグレイスケールで、勝者ノードを白抜きの円で表示したグラフである。グレイスケールは白が最も出力が大きいことを示しており、色が濃くなるにつれて出力が弱くなることを表している。これにより、各ノードの出力値が場所に応じて連続的に変化していることが確認できる。ここでは、場所によって出力パターンが変化することが確認されれば良く、その意味づけは必要はない。ここで図 8 は実験での実例 2 つを示している。各ウインドウの左上は実画像の例であり、左下、右上はそれぞれ X 軸方向および Y 軸方向への射影情報を表している。また、各ウインドウの右下は状態表現ネットワークの出力を示しており、各ノードの出力のレベルは色の濃さによって表現されている。実験後、同一の勝者ノードが選択された全ての状態についてそれぞれ調べたところ、ノードの出力パターンが同一であるものは確認されなかった。また、新規の入力に対しても十分な自己組織演算を追加することで対応可能であると考えられる。

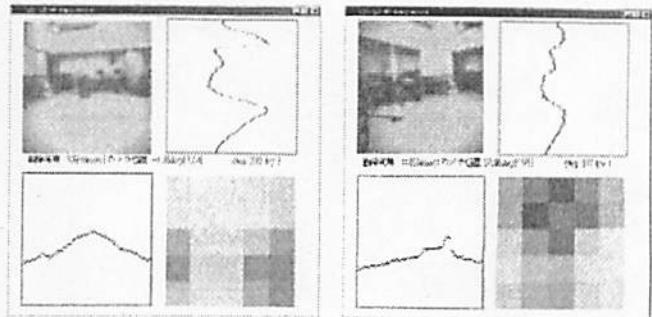


図 8 状態表現ネットワークの出力例

Fig. 8. Example of State Expression

3. 行動生成器の構築

〈3・1〉 学習手法 次に、前述の状態表現情報を用いてロボットの行動生成器を獲得する手法に関する検討を行う。状態表現ネットワークは自律的に獲得されることから、出力パターンは場所により異なることは観察できた。自律的な状態表現と行動獲得という目的から考えると、この見え様と出力パターンとの関係は我々に解る必要はない。一方で、ロボットのシステム内部ではこの出力パターンを認識し、行動生成を行わなければならない。さらに、身体を持つ実ロボットが行動を獲得するためには、比較的モデル化が難しい環境との相互作用による影響を考慮にいれなければならない。そこで、本システムでは教師無し学習を行動獲得アルゴリズムとして導入することを検討する。ここでは、環境の明示的な記述を行わずとも環境内での試行を繰り返すことで適応的な出力を獲得可能な強化学習法を用いることとする。状態表現ネットワークの出力パターンが複数ノードからの連続値によって表現されることを考慮にいれて、Actor-Critic アルゴリズムを採用する⁽¹⁴⁾⁽¹⁵⁾。Actor-Critic 法は Barto らによって提案されたニューラル・ネットワークの強化学習アルゴリズムであり、入力に連続値を使用可能である。ここでは説明の容易さから、Actor-Critic アルゴリズムによって行動獲得を行う部分を行動生成ネットワークと呼ぶ。図 9 に状態表現ネットワークの出力層を行動生成ネットワークに結合したシステムを示す。また、以下に行動生成ネットワークの学習アルゴリズムを示す。

(1) Actor 部は、時刻 t における状態表現ネットワークの各ノード出力 $d_j^2(t)$ の逆数を入力 $X_j(t)$ として行動 $a(t)$ を実行する。 $a(t)$ は式(7)で計算される。

$$a(t) = f\left(\sum_{j=1}^n W_j(t)X_j(t) + N(t)\right) \dots \dots (7)$$

ここで、 $W_j(t)$ は Actor 部への入力値に対する各結合荷重係数である。また $N(t)$ は、確率密度関数が正規分布に依存する正規乱数である。さらに、 $f(y)$ は温度定数 T を用いた式(8)で示されるシグモイド関数である。

$$f(y) = \frac{1}{1 + \exp(-\frac{y}{T})} \quad \dots \dots \dots \quad (8)$$

(2) Critic 部は報酬 $r(t)$ より、Actor 部への強化信号 $\hat{r}(t)$ を計算する。

$$\hat{r}(t) = r(t) + \gamma P(t) - P(t-1) \quad \dots \dots \quad (9)$$

$(0 < \gamma \leq 1)$

$$P(t) = \sum_{j=1}^n v_j(t) X_j(t) \dots \dots \dots \quad (10)$$

ここで、 $v_j(t)$ は Critic への入力に対する結合荷重であり、 γ は報酬の割引率である。

(3) $\hat{r}(t)$ を用いて、Actor 部の結合荷重を更新する。

$$W_j(t+1) = W_j(t) + \zeta \hat{r}(t) e_j(t) \quad \dots \dots \quad (11)$$

$(\zeta > 0)$

ここで、 ζ は Actor 部の学習率であり、 $e_j(t)$ は適性度履歴である。

(4) 適性度履歴を式(12)により更新する.

$$e_j(t+1) = \delta e_j(t) + (1 - \delta)a(t)X_j(t) \quad (12)$$

$(0 \leq \delta < 1)$

(5) Critic 部への結合荷重 $v_i(t)$ を式(13)により更新.

$$v_j(t+1) = v_j(t) + \eta \hat{r}(t) \bar{X}_j(t) \quad \dots \dots \quad (13)$$

$(\eta > 0)$

$$\bar{X}_j(t+1) = \lambda \bar{X}_j(t) + (1 - \lambda) X_j(t) \quad (14)$$

$(0 \leq \lambda < 1)$

η は Critic 部の学習率であり、 $\bar{X}_j(t)$ は $X_j(t)$ のトレースベクトルである。

(6) $t = t + 1$ して (1) から繰り返す.

ここで、時刻 t とは前述の自己組織アルゴリズム時に用いた時刻 k とはサンプル時周期を任意に設定できるよう別系統のものとして導入している。このアルゴリズムにより、状態表現ネットワークからの出力を入力とした行動生成ネット

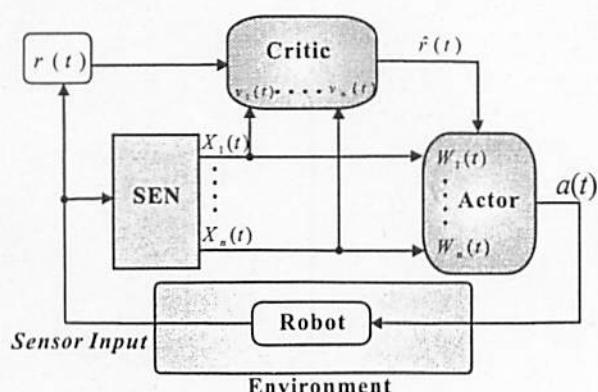


図9 システム構成

Fig. 9. System Configuration

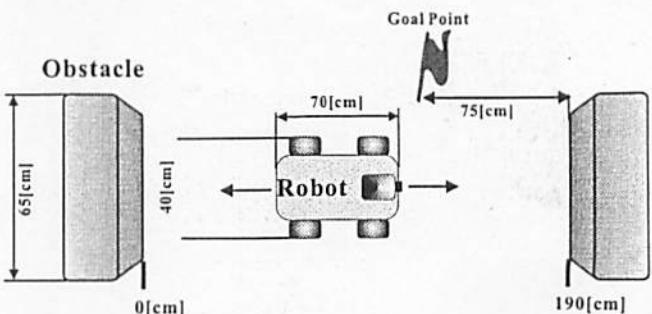


図 10 実験環境

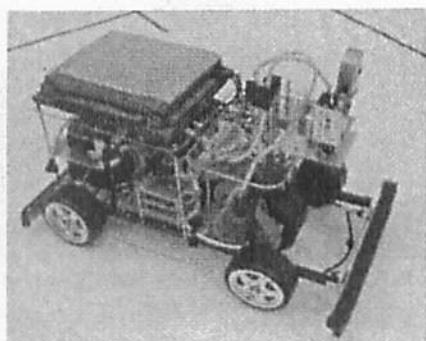


図 11 移動ロボット：ODYSSEY
Fig. 11. A Mobile Robot : ODYSSEY

トワークが獲得される。実際には効率的な学習を行うために、全ての期間（行動）に評価を行うのではなく、印象的な場面にとった行動に対してのみ評価を行い、学習を行うこととする。これに関する詳細については後述する。

〈3・2〉 移動ロボットによる実験 提案するシステムを評価するために、以下のような条件で実験を行った。本実験の目的とは高精度な移動ではなく、目標として与えられる視覚情報が得られる地点への自律的なナビゲーションである。ここで、制御対象プラットフォームとして図11に示す一輪駆動・操舵式移動ロボットを用いた。本ロボットは、ノートPC及びマイクロプロセッサにより制御系を構成しており、バッテリーによる自立走行が可能になっている。また、自由度としては車輪の駆動方向と操舵方向の2自由度およびカメラの首振り2自由度(パン・チルト方向)を所有している。しかし、本実験ではシステムの基本的な性能の確認のために、比較的簡単な駆動自由度による前後方向の動作課題に関する検討を行った。前述の通りタスクは目標地点到達とし、図10に示される環境で行った。環境内には前方および後方に障害物が設置されており、後方障害物の設置位置を0[cm]とした。ここで図11でも確認出来るが、移動ロボットにはこれらの障害物との接触を検出するための接触スイッチがボディ前後に取り付けられている。

一方、強化学習 1 試行間の単位サンプル時間は約 200[msec] とし、移動ロボットの行動は $a_t \geq 0$ なら前

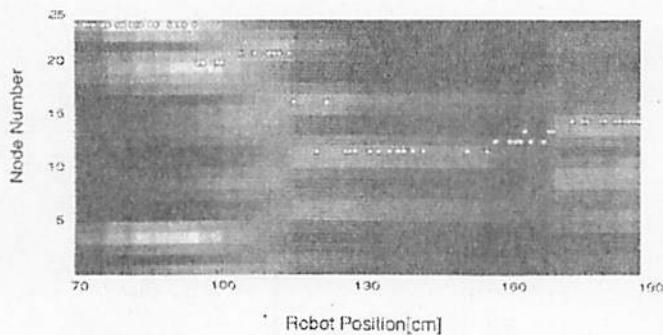


図 12 実験環境における勝者ノードおよび各ノード出力

Fig. 12. Winner Node Number and Output of Each Node in Experimental Environment

進、 $a_t < 0$ なら後進として割り当て、移動速度はそれぞれ±25[cm/sec]とした。また、行動に対する評価はロボットが目標地点から±5[cm]の評価対象範囲に入つてから10サンプル時間分(2[sec])の行動に対して行うこととし、これを学習期間とする。この学習期間においてCritic部へは、目標地点で得られる画像の射影情報を目標地点情報として与え、その目標地点情報と見え様のユークリッド距離を小さくするよう行動した場合は正の報酬+1、大きくするよう行動したら負の報酬-1を与えた。さらに、いかなる場合でもロボットが障害物に衝突したときは負の報酬として-1を与えた。目標地点を前方障害物から75[cm]の位置に、目標地点に留まる時間を4サンプル時間分(0.8[sec])に設定した。また、1試行の終了条件を次のように定義した。

- a. 50サンプル分(10[sec])学習の終了
- b. 障害物接触
- c. ゴール地点到達

a. の場合は試行が終了した後に次の試行を開始した。また、b. の場合は、障害物から離れる方向に移動してから次の試行を開始した。さらに、c. の場合は、ランダムに前後どちらかの障害物付近まで移動してから次の試行を開始した。この際、状態表現ネットワークは、前述と同様の構造とアルゴリズムにより、ロボットが実環境内で前後に運動している間に1000回の自己組織化演算を実施して事前に構成されたものを用いる。また、図12には各地点での勝者ノードおよび状態表現ネットワークの出力パターンを示す。今回もここで図??は、この状態表現ネットワークおよび前述の移動ロボットを用いて300試行の学習を行った結果を示している。図13のグラフは各試行が達したそれぞれの終了結果を示している。実験結果および実験中の挙動を観察すると、学習160試行位までは障害物に接触することが多く、1試行が終了した場合でも目標値近辺で終了する比率は低かった。しかし学習180試行以降は目標地点への到達数は増加し、さらには230試行以降は障害物への接触がなくなっていることから学習が進んだことが確認できる。また、「50サンプル分(10[sec])学習の終了」は全域にわたって

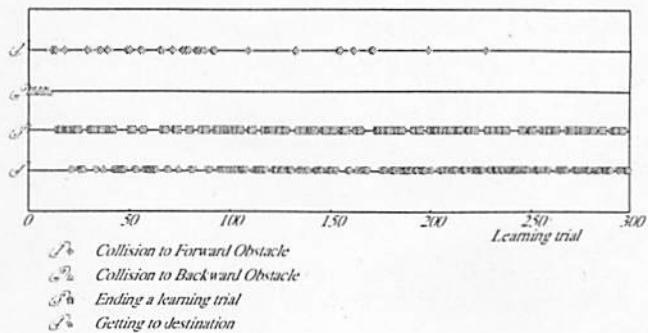


図 13 実験結果

Fig. 13. Experimental Result

出現しているが、およそ140試行以降では振動的に前後動作を行うことで目標地点に留まろうとしていたことが観察された。これは、ロボットが取り得る行動選択に停止がないことも影響していると考えられる。これにより、実験により提案手法を用いて移動ロボットの目標地点到達行動が実環境で獲得されたと判断できる。

4. まとめ

本論文では、センサ情報から自律的に状態表現を行い、ロボットの行動を獲得する手法について提案した。まず、見え様を用いて状態判別を行う状態表現ネットワークを自己組織化演算に基づいて構築した。ここでは実験を通じて、従来の勝者ノードによる状態判定だけでは不十分な場合があることを確認し、状態表現ネットワークの出力ノードの値を用いて状態を表現することとした。さらに、この状態表現ネットワークの出力値を用いた行動生成ネットワークを強化学習法により構成した。また、移動ロボットによる実環境下での実験により、見え様情報をもとに適忯的な行動生成可能であることを示した。今後は、状態表現部と行動生成部を同時に自律的な構成を実現する手法について検討を行っていく。

(平成12年4月27日受付、同12年12月7日再受付)

文 献

- (1) R. A. Brooks : "Intelligence Without Representation", *Artificial Intelligence*, 47, pp139-159, 1991
- (2) R. S. Sutton, *Reinforcement Learning*, Kluwer Academic Publishers, 1992
- (3) R. S. Sutton, A. G. Barto, *Reinforcement Learning*, MIT Press, 1998
- (4) 浅田、野田、依積田、細田：“視覚に基づく強化学習によるロボットの行動獲得”，日本ロボット学会誌，Vol.13, No.1, pp68-74, 1995
- (5) 小林、井上、太田、新井：“視覚・接触情報を用いた状態・行動空間の自律的生成”，第11回自律分散システム・シンポジウム資料, pp275-280, 1999
- (6) 矢入、中須賀、堀：“異種冗長なセンサー情報に基づく自律的状態抽象化法”，人工知能学会誌, Vol.14, No.4, pp667-679, 1999
- (7) C. H. Malsburg : "Self-organization of Orientation Sensitive Cells in the Striate Cortex", *Kybernetik*, 14, 85-100, 1973
- (8) A. M. Graybiel, M. Kimura : "Adaptive Neural Networks in the Basal Ganglia", *Models of Information Processing in the Basal Ganglia*, MIT Press, pp103-116, 1995

- (9) N. Burgess, M. Recce, J. O'keefe : "A Model of Hippocampal Function", *Neural Networks*, Vol.7, No.6/7, pp1065-1081, 1994
- (10) N. Burgess, J. G. Donnett, K. J. Jeffery, J. O'Keefe : "Robotic And Neuronal Simulation of The Hippocampus And Rat Navigation", *Phil. Trans. R. Soc. Lond.*, B, 352, pp1535-1543, 1997
- (11) K. J. Jeffery, J. G. Gonnett, N. Burgess, J. M.O'Keefe : "Directional Control of Hippocampal Place Fields", *Exp. Brain Res.*, Vol.117, pp131-142, 1997
- (12) 青田, 三宅, 鶴鉄: "場所細胞-その生成モデルと強化学習への適用-", 第4回ロボティクスシンポジア講演予稿集, pp50-55, 1999
- (13) T. Kohonen : *Self-Organizing Maps*, Springer, 1994
- (14) A. G. Barto : "Neuronlike Adaptive Elements That Can Solve Difficult Learning Control Problems", *IEEE Transactions on Systems Man and Cybernetics*, SMC-13, No.5, pp834-846, 1983
- (15) A. G. Barto : "Adaptive Critics and the Basal Ganglia", *Models of Information Processing in the Basal Ganglia*, MIT Press, pp215-232, 1995
- (16) 石川, 川端, 藤井, 植田, 淩間, 達藤: "移動に伴う動的視覚情報を利用した行動学習", 第12回自律分散システム・シンポジウム資料, pp457-462, 2000

川端邦明 (正員) 1970年2月3日生。1992年法政大学工学部電気工学科電気電子工学専攻卒業。1994年同大学院工学研究科電気工学専攻修士課程修了。1997年法政大学大学院工学研究科電気工学専攻後期博士課程修了。博士(工学)。同年、理化学研究所基礎科学特別研究員として生化学システム研究室勤務。2000年理化学研究所工学基盤研究部基盤技術開発室研究員、自律分散ロボットシステム、学習・進化システム、移動ロボットに関する研究に従事。RoboCup-98 Japan Open人工知能学会賞受賞、2000年ROBOMECH'00優秀講演。IEEE、日本ロボット学会、電気学会、計測自動制御学会、人工知能学会、日本原子力学会等の会員。

石川達也 (非会員) 1976年3月5日生。1998年東洋大学工学部情報工学科卒業。2000年東洋大学工学研究科電気工学専攻博士前期課程修了。この間、自律移動ロボットの視覚学習に関する研究に従事。現在、富士ソフトABCに勤務。

藤井輝夫 (正員) 1964年4月5日生。1988年東京大学工学部船舶工学科卒業。1991年~1993年日本学術振興会特別研究員。1993年東京大学大学院工学系研究科船舶海洋工学専攻博士課程修了。博士(工学)。同年東京大学生産技術研究所客員助教授。理化学研究所勤務を経て、1999年より東京大学生産技術研究所海中工学研究センター助教授。IEEE、ACS、日本ロボット学会等の会員。

淺間一 (正員) 1959年1月18日生。1984年東京大学大学院工学系研究科機械工学修士課程修了。1986年理化学研究所化学工学研究室研究員補。生化学システム研究室研究員、先任研究員を経て、現在工学基盤研究部技術開発促進室室長。1999年埼玉大学大学院理工学研究科客員研究員。自律分散型ロボットシステム、複数移動ロボットの協調に関する研究、バイオプロセスの知能化技術等の研究開発に従事。1995年日本機械学会ロボメック賞、1996年日本機械学会ロボメカ講演会Best Poster賞、RoboCup-98 Japan Open人工知能学会賞(Uttoni United Team)等受賞。工学博士(東京大学)。IEEE、ニューヨーク科学アカデミー、日本ロボット学会、日本機械学会、精密工学会等の会員。

遠藤勲 (非会員) 1940年8月14日生。1970年東京大学工学研究科博士課程終了。理化学研究所化学工学研究室勤務。生化学システム研究室主任研究員を経て、現在、宇都宮大学農学部生物生産科学科教授。生物工学、特にバイオプロセスエンジニアリングに関する研究に従事。1978年化学工学協会論文賞受賞。1994年ヘルシンキ工科大学名誉工学博士。1999年化学工学会賞受賞。2000年科学技术庁長官賞研究功績賞受賞。ニューヨーク科学アカデミー、アメリカ化学会、アメリカ化学会、化学工学会等の会員。