

移動ロボットの見え方の変化に基づく教師なしカテゴリ分類

塚田 真敬[†] 間所 洋和[†] 佐藤 和人[†]

[†] 秋田県立大学大学院システム科学技術研究科 〒015-0055 秋田県由利本荘市土谷字海老ノ口 84-4
E-mail: †{m11a013,madokoro,ksato}@akita-pu.ac.jp

あらまし 本論文では、ART-2 (Adaptive Resonance Theory-2) の追加学習機能と CPN (Counter Propagation Networks) の自己写像特性を組み合わせたネットワークによる、画像データの教師なしカテゴリ分類法を提案する。本手法では、SIFT (Scale-Invariant Feature Transform) の各特徴点における 128 次元の SIFT 記述子ベクトルから、SOM (Self-Organizing Maps) を用いてコードブックを生成し、そのヒストグラムを特徴量として、ART-2 による教師なしラベル形成、CPN が生成する 2 次元マップによるカテゴリ間の空間関係の可視化を行い、教師なしカテゴリ分類を可能とする。ロボットの視覚から得られる時系列画像を用いた評価実験では、ロボットの移動とともに見え方が変化する複数のオブジェクトの多様性を表現するとともに、各オブジェクトをカテゴリとして分類することができた。キーワード ART-2, CPN, 自己組織化マップ, SIFT, 教師なしカテゴリ分類, 遺伝的プログラミング, 世界像

Unsupervised Category Classification Based on Appearance Changes Using Mobile Robot

Masahiro TSUKADA[†], Hirokazu MADOKORO[†], and Kazuhito SATO[†]

[†] Graduate School of Systems Science and Technology, Akita Prefectural University 84-4 Aza Ebinokuchi Tsuchiya, Yurihonjo City, 015-0051 Japan
E-mail: †{m11a013,madokoro,ksato}@akita-pu.ac.jp

Abstract This paper presents an unsupervised category classification method that combines incremental learning of ART-2(Adaptive Resonance Theory-2) and self-mapping characteristic of CPN(Counter Propagation Networks). Our method consists of the following procedures: 1)generating codebooks using SOM(Self-Organizing Maps) from 128-dimensional descriptors in each characteristic point of SIFT(Scale-Invariant Feature Transform), 2)forming labels with unsupervised learning of ART-2, and 3)labeling category maps using CPN for visualizing spatial relations between categories. We evaluated our method for using a mobile robot for taking time-series images from the camera. The experimental result shows our method can classify objects that change appearance with the movement of the robot in each category.

Key words ART-2, CPN, SOM, SIFT, Unsupervised Category Classification, GP, World Image

1. はじめに

近年、知能ロボットに関する研究が多視点から行われている。特に、ロボットが人間の制御なしに自分で判断する自律行動の研究は活発化しているが、実現には多くの課題を抱えている。中でも、ロボットの視覚機能の実現が重要であると考えられている [1]。ロボットによっては、視覚以外の様々なセンサが取り付けられていて、一定の柔軟性を持っているものもある。しかしながら、ロボットの自律行動には、視覚情報によって自分の置かれた環境を把握したり、対象物を見分けてカテゴリに分類して、世界像を獲得する必要があると考えられる。ロボッ

トビジョンの研究においては、ロボットが人間の感覚に類似した視覚を獲得するためには、視覚と同時に知識を使わなければならないと述べられている [1]。移動とともに得られる視覚情報をカテゴリごとに分類し、記憶として蓄積することで、視覚に求められる知識となると考えられる。

コンピュータビジョンの分野では、画像中の未知の物体をそれが属するカテゴリに分類する一般物体認識が、知識システム獲得のための技術として実現が期待されている [2]。最近の一般物体認識の研究では、あらかじめ分類カテゴリを決めて、それに対応する学習画像を手で集める教師ありカテゴリ分類法とは異なり、分類カテゴリ自体が未知な問題に対して自動的にク

ラスを探し出し、画像をカテゴリ分類する教師なしカテゴリ分類法が提案されている。Sivicらは教師なしカテゴリ分類として、Bag-of-keypointsを用いて、大量の画像に対して文書分類手法のpLSA (probabilistic Latent Semantic Analysis) を適用することによって、自動的に画像のカテゴリ分類を行う手法を提案している [3]。Zhuらは、PCFG (Probabilistic Context-Free Grammars) と MRF (Markov Random Fields) を組み合わせた生成的モデルのPGMM (Probabilistic Grammar-Markov Models) を用いて、物体検出と教師なしカテゴリ分類のための物体カテゴリのモデル化を行っている [4]。また、Todorovicらは、マルチスケール画像の分割により、それぞれの画像をツリー構造で表現し、2次元物体で構成されるマルチスケール領域の光学的、幾何学的、位相幾何学的な特性による教師なし識別を提案している [5]。中村らは、人間の感覚に即した物体のカテゴリ分類として、ロボットの身体性を利用し、視覚・聴覚・触覚のマルチモーダル情報を用いた教師なしカテゴリ分類法を提案している [6]。このように近年、視覚情報処理において、知識システム獲得のための技術として、教師なしカテゴリ分類の研究が非常に注目されている。しかしながら、従来手法の多くは、分類カテゴリ数が既知でなければならないという条件があるため、カテゴリ数が一意に決まらない実環境でのカテゴリ分類には適用できない。

そこで本研究では、カテゴリ数が未知な問題にも適用できる教師なしカテゴリ分類法を提案する。本研究では、環境内の多様な見え方を獲得する知的な行動を GP (Genetic Programming) によって生成し、GPの行動によって得られた視野画像列をカテゴリ分類の対象データとする。本手法では、Grossbergらによって提案された ART-2 (Adaptive Resonance Theory-2) [7] の追加学習機能と、Nilsenによって提案された CPN (Counter Propagation Networks) [8] の自己写像特性を組み合わせたネットワークを用いて、教師なしカテゴリ分類を行う。ART-2は、安定性と可塑性を保ちながら適応的にカテゴリを形成する追加学習型の自己組織化ニューラルネットワークである。ART-2を用いることにより、事前にカテゴリ数の知識を必要としない教師なしカテゴリ分類を可能とする。また、移動ロボットの視覚から得られる視野画像列の情報は、時間の経過と共に変化する。そのため、時間軸に沿った学習を進めることができる ART-2の適用は、時系列変化を扱う上でも有用であると考えられる。CPNは、SOM (Self-Organizing Maps) の Kohonen 層の上部に Grossberg 層を追加した3層で構成され、写像とラベリングを同時に行う教師ありニューラルネットワークである。また、CPNは入力データの位相関係を学習し、出力結果は2次元マップ上に写像される。そのため、2次元マップ上にカテゴリ分類結果を表現できる。これらを組み合わせた本手法の特徴は以下の3つとなる。1つ目は、ART-2では不明瞭となっているカテゴリ間の空間的な関係を CPNにより可視化できる点である。2つ目は、CPNのラベリングに用いる教師データとして ART-2のラベルを与えるため、教師なし学習として CPNを用いることができる点である。3つ目は、CPNの2次元マップ上にカテゴリ分類結果とともに、各カテゴリ内の見え方の変化などの

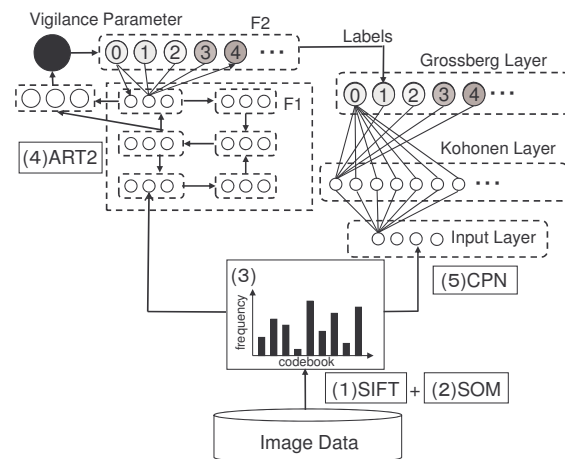


図1 提案手法のネットワーク構成
Fig. 1 Network architecture of our method.

多様性も表現できる点である。評価実験では、GPによって生成した行動プログラムをロボットに適用し、移動とともに得られる視野画像列のカテゴリ分類を行う。本論文では、カテゴリ分類における本手法の有効性と、移動ロボットの見え方の変化に基づくカテゴリ分類と自律行動の関係性について報告する。

以下、2.では提案する教師なしカテゴリ分類法について詳しく説明する。また、評価実験および結果を3.で示し、4.でその考察について述べる。最後に5.で結論と今後の課題について述べる。

2. 教師なしカテゴリ分類法

本節では提案する教師なしカテゴリ分類法について述べる。本研究で提案するカテゴリ分類法のネットワーク構成を図1に示す。提案手法の処理手順は図1のように、(1)SIFT (Scale-Invariant Feature Transform) による特徴点抽出および SIFT 記述子ベクトルの算出、(2) 全学習画像の全 SIFT 記述子ベクトルの SOM を用いたクラスタリングによるコードブックの作成、(3) 各画像における SIFT 記述子ベクトルのコードブックによるヒストグラムの作成、(4)ART-2の教師なし学習によるラベルの作成、(5)CPNのラベリングによるカテゴリマップの作成 (カテゴリ分類)、となる。提案手法の前処理にあたる (1)~(3)は Bag-of-keypoints 表現をベースとしている。(1)の SIFT は、現在、一般物体認識において、局所特徴量の記述方法として最もよく用いられている。SIFT の処理は、特徴点の検出 (detection) と特徴量の記述 (description) の2段階からなるアルゴリズムである。また本手法では (2)のクラスタリング手法として SOM を用いる。k-means 法ではクラスタ中心以外のデータは考慮されないのに対し、SOM では位相情報を保存しながらの学習を行うことができるため、誤認識を最小に抑えることができる。更に、(4)、(5)のネットワークにより、大量の画像に自動でラベルを与えてカテゴリに分類する、教師なしカテゴリ分類を可能とする。以下に、各アルゴリズムの詳細を記す。

2.1 SOM によるコードブックの作成

本手法では、一般的な Bag-of-keypoints とは違い、k-means 法によるコードブックの作成を SOM で行う。SOM のネットワークは、入力データと類似したデータにも反応するような領域を作り出し、入力データの持つ特徴を判別できるように、ネットワークの内部状態を変更しながら学習する。よって、SOM では、学習時に提示されなかったベクトルでも、正確にクラスタリングされ、クラスタ数や初期クラスタの中心値が未知の場合でも誤認識を最小とするクラスタ抽出を行うことができる。なお、SOM の学習アルゴリズムは、2.3 節にて述べる CPN の Grossberg 層を除いた、入力層と Kohonen 層との間の処理となる [9]。

2.2 ART-2 によるカテゴリのラベル生成

ART には様々なバージョンが存在する [10]。その中で、本手法では、連続値入力が可能な ART-2 [7] を用いる。

ART-2 の学習アルゴリズムを以下に記す。

(1) トップダウン結合荷重 Z_{ji} 、ボトムアップ結合荷重 Z_{ij} 、F1 層サブレイヤの出力 p_i 、 q_i 、 u_i を次式により初期化する。

$$Z_{ji}(0) = 0, \quad Z_{ij}(0) = \frac{1}{(1-d)\sqrt{M}}, \quad (1)$$

$$p_i(0) = q_i(0) = u_i(0) = v_i(0) = w_i(0) = x_i(0) = 0.0 \quad (2)$$

(2) 入力 I_i を提示し、次式より各サブレイヤを伝播させる。

$$w_i(t) = I_i(t) + au_i(t-1), \quad (3)$$

$$x_i(t) = \frac{w_i(t)}{e + \|w\|}, \quad (4)$$

$$v_i(t) = f(x_i(t)) + bf(q_i(t-1)), \quad (5)$$

$$u_i(t) = \frac{v_i(t)}{e + \|v\|}, \quad (6)$$

$$p_i(t) = \begin{cases} u_i(t) & (\text{inactive}) \\ u_i(t) + dZ_{ji}(t) & (\text{active}) \end{cases} \quad (7)$$

$$q_i(t) = \frac{p_i(t)}{e + \|p\|}, \quad (8)$$

$$f(x) = \begin{cases} 0 & \text{if } 0 \leq x < \theta \\ x & \text{if } x \geq \theta \end{cases} \quad (9)$$

(3) 最大活性化ユニット T_j を探索する。

$$T_j(t) = \max_j \left(\sum_i p_i(t) Z_{ij}(t) \right) \quad (10)$$

(4) トップダウン結合荷重 Z_{ji} 、ボトムアップ結合荷重 Z_{ij} を更新する。

$$\frac{d}{dt} Z_{ji}(t) = d[p_i(t) - Z_{ji}(t)], \quad (11)$$

$$\frac{d}{dt} Z_{ij}(t) = d[p_i(t) - Z_{ij}(t)] \quad (12)$$

(5) ビジランス閾値 ρ を用いて、カテゴリに属するかを判定する。

$$\frac{\rho}{e + \|r\|} > 1, r_i(t) = \frac{u_i(t) + cp_i(t)}{e + \|u\| + \|cp\|} \quad (13)$$

判定条件が成立する場合は、選択されたユニットをリセットして (3) へ戻り再探索する。不成立の場合は、F1 層内の変化率が小さくなるまで (2) と (4) を繰り返す。なお、 a と b は u 層から w 層及び q 層から v 層のフィードバックループにかかる係数である。 c は p 層から r 層への伝搬係数、 d は学習率係数であり、両者間には $cd/(1-d) \leq 1$ の制約が与えられている。 θ は v 層におけるノイズの除去を制御するパラメータである。なお、本手法では θ を 0.1、 ρ を 0.850 に設定した。

2.3 CPN によるカテゴリマップの生成

CPN はパターンマッピングを行う [8]。すなわちパターンの全集合において一つのパターンを別なパターンにマッピングする。パターンが提示されると、学習後のネットワークは結合荷重を使って、そのパターンを特定のカテゴリに分類する。本手法では、Grossberg 層のユニットに与える教師データを ART-2 のラベルとすることでラベリング処理を自動化した。

CPN の学習アルゴリズムを以下に記す。

(1) $u_{n,m}^i(t)$ は、時刻 t における、入力層ユニット i ($i = 1, \dots, I$) から、Kohonen 層ユニット (n, m) ($n = 1, \dots, N, m = 1, \dots, M$) への結合荷重とする。 $v_{n,m}^j(t)$ は、時刻 t における、Grossberg 層ユニット j から、Kohonen 層ユニット (n, m) への結合荷重とする。これらの結合荷重は、ランダムに初期化される。 $x_i(t)$ は、時刻 t における入力層ユニット i に提示される学習データである。 $x_i(t)$ と $u_{n,m}^i(t)$ の間のユークリッド距離 $d_{n,m}$ は次式で計算される。

$$d_{n,m} = \sqrt{\sum_{i=1}^I (x_i(t) - u_{n,m}^i(t))^2} \quad (14)$$

(2) $d_{n,m}$ が最小となるユニットが、勝者ユニット c として定義される。

$$c = \operatorname{argmin}(d_{n,m}) \quad (15)$$

(3) $N_c(t)$ は、勝者ユニット c の近傍領域である。 $N_c(t)$ の内部の結合荷重 $u_{n,m}^i(t)$ は、Kohonen の学習アルゴリズムを用いて更新される。

$$u_{n,m}^i(t+1) = u_{n,m}^i(t) + \alpha(t)(x_i(t) - u_{n,m}^i(t)) \quad (16)$$

(4) $N_c(t)$ の内部の結合荷重 $v_{n,m}^j(t)$ は、Grossberg のアウトスター学習アルゴリズムで更新される。

$$v_{n,m}^j(t+1) = v_{n,m}^j(t) + \beta(t)(t_j(t) - v_{n,m}^j(t)) \quad (17)$$

ここで、 $t_j(t)$ は、Grossberg 層に提示される教師信号である。 $\alpha(t)$ と $\beta(t)$ は、学習率係数であり、学習の進行とともに減少する。CPN の学習は、以上のステップを事前に設定した学習回数だけ繰り返す。なお、本手法では、学習率係数 $\alpha(t)$ および $\beta(t)$ を 0.5、学習回数は 10,000 回とした。

3. 移動ロボットを用いた評価実験

本実験では、同一環境で 2 パターンの経路を設定し、経路に沿った 2 パターンの行動を GP によって生成し、ロボットの移




図 2 実験に用いたロボット (ネットタンサ)

Fig. 2 Robot used for experiments(NetTensor by Bandai).




図 3 オブジェクトと背景

Fig. 3 Objects and background.

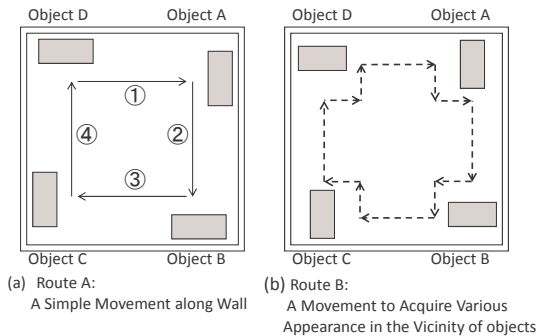


図 4 実験環境と走行経路

Fig. 4 Experimental environment and routes for robot.

動とともに得られる視野画像列のカテゴリ分類を行い、本手法の有効性の評価と視野画像列の違いによるカテゴリ分類結果の比較を行う。

3.1 実験環境

実験で用いるロボットとして、図 2 に示す、バンダイ社製のホームロボット「ネットタンサ」を用いた。本ロボットの大きさは、全高 190mm、全長 160mm、全幅 160mm である。搭載されているカメラは、1/4 インチ CMOS の 30 万画素、画像圧縮形式は JPEG、カメラ解像度は 320 × 240pixel、フレームレートは 15fps である。ロボットは、高さ 300mm の白い壁で囲まれた 1,150 × 1,150mm の環境内を走行する。走行環境内には、図 3 に示すパンチ (Object A)、ボンド (Object B)、本 (Object C)、セロハンテープ (Object D) の 4 つのオブジェクトを配置した。本ロボットの視覚の高さを考慮し、実環境での動作環境を机上と想定したため、対象オブジェクトとして形状に特徴のある事務用品を用いた。環境内におけるオブジェクトの配置とロボットの行動経路を図 4 に示す。図 4 (a) の単純な壁伝いの経路 (経路 A)、図 4 (b) のオブジェクト

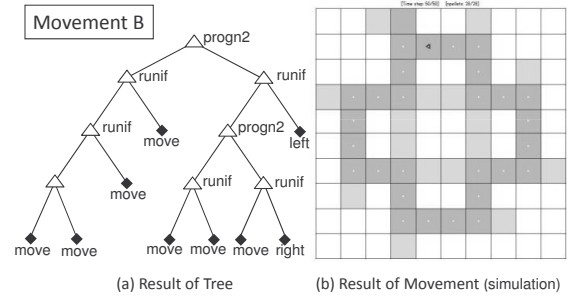


図 5 GP によって生成した木構造とシミュレーションの結果

Fig. 5 Results of tree and simulation generated by GP.

付近で多様な見え方を獲得する経路 (経路 B) に沿ったランドマークを設定し、GP によってロボットの各行動プログラムを生成した。GP による行動の生成については、次節で述べる。本実験では、それぞれの行動における視野画像列をカテゴリ分類の対象データとする。また、環境内を 2 周し、学習とテストのデータを取得する。学習結果は、ART-2 のラベル形成の結果と CPN の分類結果の両方から評価する。また、テスト結果は CPN の分類結果で評価する。

3.2 GP による行動の生成

GP は、GA (Genetic Algorithms) の遺伝子型を木やグラフなどの構造表現を扱えるように拡張し、ロボットのプログラム生成などに応用される。木構造は、非終端ノード (関数)、終端ノード (変数あるいは定数)、ルートで構成する。本研究では、経路 A、経路 B の 2 パターンの行動プログラムを生成する。GP には以下のノードを使用した。

- 終端ノード: move, left, right, upleft, upright
- 関数ノード: runif, progn2, progn3

終端ノードはそれぞれ前進、左 90 度回転、右 90 度回転、左 15 度回転、右 15 度回転に対応している。関数ノードの runif は条件判断で、1 マス前方にランドマークがあれば第 1 引数を実行し、なければ第 2 引数を実行する。progn2, progn3 は 2 引数、3 引数を順次実行する関数である。シミュレーションには、走行環境を 10 × 10 マスに区切ったマップを用いた。1 マスは走行環境の 115 × 115mm に相当する。ロボットは、マップ内に置かれたランドマークを探索し、それらを見つけて適合度を得る。以上のような適合度のもとで、個体数 50 で世代数 100 の学習を実行した。ここで得られた最も成績の良い個体を、ロボットの行動プログラムとして適用した。経路 A では、runif の関数ノードと、move と right の終端ノードのみで最適な木構造を生成した。経路 B は、図 5 (a) に示すような木構造を生成し、シミュレーションの行動結果は図 5 (b) となった。経路 A, B で生成したプログラムを行動プログラム A、行動プログラム B とする。

3.3 行動プログラム A

ART-2 のラベル生成の結果を図 6、CPN のカテゴリマップを図 7 に示す。図 6 の結果より、行動プログラム A における視野画像列は 16 ラベルに分類した。環境内の 4 隅で 90 度旋回する際の画像は、1 画像に 1 ラベルとなり、全体のラベル数

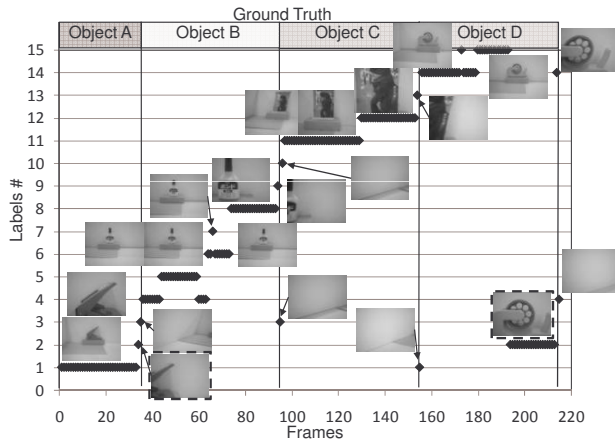


図 6 行動プログラム A における ART-2 の結果
Fig. 6 Result of ART-2 at Movement A .




図 7 行動プログラム A における CPN の結果
Fig. 7 Result of CPN at Movement A.

を増加させた．各オブジェクトについて観察すると，オブジェクト全体が写る画像と近づいて一部が写らない画像（オクルージョン画像）に異なるラベルを形成した．ART-2 では複数のラベルとして分類されたオブジェクトが，図 7 で示される通り CPN のカテゴリマップでは隣接するユニットに写像されている．Object A から Object B に旋回する際の画像と Object D に接近した画像は，ART-2 でラベルが混同した．しかしながら，カテゴリマップでは離れた位置のユニットへ写像し，各カテゴリに形成した．適合率を，正解データを全データで割って算出した．なお，各カテゴリのラベルが他のオブジェクトおよび背景画像のラベルと混同したデータを誤分類とした．学習データの適合率は 99.1 % を示した．本実験のテストデータにおける適合率を表 1 に示す．行動プログラム A の 2 周目のデータと行動プログラム B の 1 周目のデータを用いてテストを行った．行動プログラム A のテストデータにおける適合率は 98.8 % を示したが，行動プログラム B では 63.5 % となり，35.3 % 低下した．

表 1 各行動における学習およびテストデータの適合率
Table 1 Accuracy of test data in each learning of movement .

		Test Data	
		Route A	Route B
Training Data	Route A	98.8 %	63.5 %
	Route B	82.8 %	86.8 %

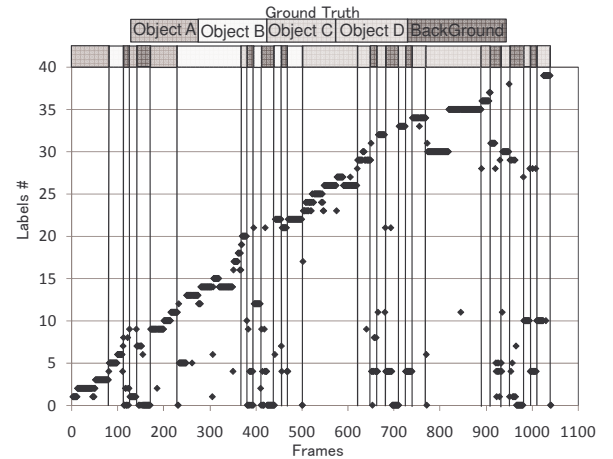


図 8 行動プログラム B における ART-2 の結果
Fig. 8 Result of ART-2 at Movement B.




図 9 行動プログラム B における CPN の結果
Fig. 9 Result of CPN at Movement B.

3.4 行動プログラム B

ART-2 のラベル生成の結果を図 8，CPN のカテゴリマップを図 9 に示す．図 8 の結果より，行動プログラム B における視野画像列は 39 ラベルに分類した．行動プログラム B では，旋回の動きが増えて環境内の見え方も多様となったためにラベル数が増加したといえる．オブジェクト付近での行動では，壁だけが写る画像や離れた位置にあるオブジェクトが写る画像を得るという見え方が含まれるため，ART-2 のラベル生成も複雑となった．また，壁だけの画像や旋回の際にオブジェクトが小さく写る画像では，ラベルが増加する傾向がある．各オブジェ




図 10 Object B のラベル生成の結果
Fig. 10 Labeling result of Object B .

クトの見え方とラベルの関係性を解析するために、図 8 の 80～498 フレームの Object B が写る画像の ART-2 の結果を図 10 に示す。この結果から、行動プログラム A に比べて旋回の動きが増えても、オブジェクトの見え方の変化に基づいたラベル生成ができたといえる。図 9 の結果では、ART-2 で複数のラベルに分類されたオブジェクトの視野画像列を、カテゴリマップの隣接するユニットへ写像してオブジェクトごとのカテゴリを形成した。形成したカテゴリと各ラベルの代表画像の関係から、カテゴリマップではオブジェクトの多様な見え方を 1 カテゴリとして表現可能であることがいえる。また、ART-2 の結果では不明瞭となった壁の視野画像列も、カテゴリマップでは隣接するユニットへ写像することで背景カテゴリとして形成した。学習データの適合率は 90.8 % を示した。行動プログラム A の 1 周目のデータと行動プログラム B の 2 周目のデータを用いて行ったテストの適合率を表 1 に示す。行動プログラム B のテストデータにおける適合率は 86.8 %，行動プログラム A では 82.8 % となり、4.0 % 低下した。

4. 考 察

一般物体認識では、同じオブジェクトには同じラベルを与えてカテゴリに分類している。しかしながら、ロボットビジョンにおけるカテゴリ分類では、環境内をセンシングする際の見え方の変化に積極的にラベルを与えてカテゴリに分類する必要がある。本手法の ART-2 のラベル生成では積極的に見え方の変化を学習できていると評価できる一方、行動が複雑になることで環境内の見え方も増えるため、ART-2 のラベル数は増加する。しかしながら、CPN では近傍学習によって見え方の変化を含むオブジェクトを隣接するユニットへカテゴリとして分類している。また、ART-2 では不明瞭となった壁や旋回の際の画像を、CPN では背景のカテゴリとして分類できた。本実験の結果では、2 周目の走行におけるテストに対して 98.8 % と 86.8 % の高い適合率を示した。この結果から本手法は、各オブジェクトと背景の見え方の変化を含む視野画像列を各カテゴリに分類できているといえる。また、学習とは異なる行動の視野画像列をテストデータとして与えた適合率の結果では、行動プ

ログラム A の 35.3 % の低下に対して、行動プログラム B では 4.0 % の低下にとどまった。この結果から、多様な見え方が得られている分だけカテゴリ分類の精度は向上しているといえる。よって、複雑な行動における視野画像列のように、オブジェクトの構造などの見え方が大きく変わる画像データに対しても、本手法の ART-2 の時系列に沿った追加学習と、CPN の近傍学習によって環境内のカテゴリ分類を可能とする。本手法は、通常のコンピュータビジョン分野におけるカテゴリ分類（一般物体認識）だけではなく、カテゴリ数が未知で環境内の見え方も多様なロボットビジョンのカテゴリ分類手法として有効であるといえる。

5. ま と め

本研究では、ART-2 の追加学習機能と CPN の自己写像特性を組み合わせた教師なしカテゴリ分類法を提案し、GP によって生成した行動における視野画像列のカテゴリ分類実験から、本手法の特徴と有効性を示した。実験から、環境内の 4 オブジェクトおよび壁の見え方の変化を ART-2 のラベル生成で表現し、各オブジェクトと背景のカテゴリを CPN のカテゴリマップによって分類することができた。カテゴリ分類の適合率から、多様な見え方が得られる分だけカテゴリ分類の精度は向上する結果となった。今後の課題は、CPN のカテゴリマップから明確なカテゴリ数を決定することが挙げられる。また、GP の非終端ノードおよび評価関数に本手法の見え方に基づくカテゴリ分類の知識を適用し、自律行動に結びつけていく。

文 献

- [1] 金出武雄, "Computer Vision and AI Their Relation and Non-Relation", 人工知能学会誌, 18 巻 3 号, May 2003.
- [2] 柳井啓司, "一般物体認識の現状と今後," 情報処理学会論文誌: コンピュータビジョンとイメージメディア, Vol.48 No.SIG16(CVIM 19), Nov. 2007.
- [3] Josef Sivic, Bryan C.Russell Alexei A.Efros, Andrew Zisserman, William T.Freeman, "Discovering Objects and their Localization in Images," IEEE International Conference on Computer Vision, pp370-377, 2005.
- [4] Long(Leo) Zhu, Yuanhao Chen, and Alan Yuille, "Unsupervised Learning of Probabilistic Grammar-Markov Models for Object Categories," IEEE Truns. PAMI VOL.31, NO.1, Jan. 2009.
- [5] Sinisa Todorovic, Member, IEEE, and Narendra Ahuja, Fellow, IEEE, "Unsupervised Category, Modeling, Recognition, and Segmentation in Images," IEEE Truns. PAMI VOL.30, NO.12, Dec. 2008.
- [6] 中村友昭, 長井隆行, 岩橋直人, "ロボットによる物体のマルチモーダルカテゴリゼーション", 電子情報通信学会論文誌 D Vol.J91-D No.10 pp.2507-2518, 2008.
- [7] Carpenter, G.A. and Grossberg, S., "ART 2: Stable Self-Organization of Pattern Recognition Codes for Analog Input Pttterns," Applied Optics, Vol.26, pp4919-4930, 1987.
- [8] Hetch-Nielsen, R., "Counterpropagation networks," Proc. of IEEE First Int'l. Conference on Neural Networks. 1987.
- [9] T.Kohonen, "Self-Organizing Maps," Springer Series in Information Sciences, 1995.
- [10] Carpenter, G.A. and Grossberg, S., "Pattern Recognition by Self-Organizing Neural Networks," The MIT Press, 1991.