ブースティングアルゴリズムを用いた自律移動ロボットの制御ルール獲得

井谷 久博*・古橋 武**

Control Rule Acquisition Using Boosting Algorithm for Autonomous Mobile Robot

Hisahiro ITANI* and Takeshi FURUHASHI**

This paper presents a method for acquiring control rules for autonomous mobile robots by the Boosting algorithm. This algorithm is to search a set of rules with a high control performance by assembling simple low performing control rules one by one using teaching results by teaching play back. In this search process, the rules that contribute to the improvement of the control performance are found and they can be applied to a tuning of control rules described and given beforehand by a designer. This algorithm achieves a combination of merits of teaching play back and those of rule description, i.e. the given rules by the designer work fairly well against environmental/task changes, and the performance improving rules obtained by the boosting algorithm are effective for enhancing the control performance under limited conditions. The proposed method is applied to a corridor passage problem for a mobile robot. It is shown that the extraction of performance improving rules is easier by the proposed method than by the conventional method, and the performance improvement of the existing rules under a limited environment is achieved by adding the obtained rules, and against a change of the corridor the control performance of the rules is kept by the existing rules.

Key Words: Boosting algorithm, k-means clustering, teaching, rule acquisition

1. はじめに

ロボットは工場の生産ラインだけでなく、医療・福祉の現場やさらには家庭内など多様な分野において、今後ますます利用が広がるものと期待されている。幅広い分野での利用促進を目指して、ロボットの機能を高める研究が盛んに進められている。行動ルール獲得の自律化は、ロボット利用促進の重要な技術の一つであるが、現在のところその進歩は十分でなく、人間の教示によるロボット作業実現の効率化が見直されている¹⁾。

産業用ロボットの分野においては、実際のワークに対してロボットに作業を直接教示するオンライン教示と、ロボットとその周りの環境をモデル化して、シミュレーションを基に教示するオフライン教示が実施されている。近年、オフライン教示の高度化・自動化を目指してティーチングシステムの開発が進められている²⁾。

ティーチングプレイバックによる教示は、製造業の現場など単純繰り返し作業において古くから広く用いられ、限定さ

れた作業・環境下では高度な性能を発揮している。しかし、作業・環境の変化に脆弱で、それらの変化により制御性能は著しく低下する。また、見まねによる学習^{3),4)}、人間の操作支援により作業を遂行するシステム⁵⁾、人間の主観的評価に基づいてシステムを最適化させる手法⁶⁾などの研究もなされているが、高度な計測システムが必要であること、人間への負荷が大きいことなどの問題点が指摘されている⁷⁾。

一方、入出力関係を記述したルールによる教示はさまざまな作業・環境変化に対応する能力をロボットに与えることができる。しかし、特定作業の精度向上にはルールのチューニングを必要とする。ロボットの行動獲得における制御器の設計負荷を軽減する手法として、強化学習⁸⁾など自律的に制御則を学習する手法が研究され、その有用性が認められつつある。近藤ら⁹⁾は学習後の制御器から拘束条件をルールとして抽出し、それを複雑なタスクを学習する際の拘束条件として利用する手法を提案し学習の効率化を図っている。しかし、獲得ルールのチューニングに関する視点の研究は見当たらない。

学習したルールの解析が容易な手法としてID3を用いた制御ルール獲得手法^{10),11)}がある。これらは相互情報量を基準に決定木を生成する手法であり、精度の良い制御ルールの獲得を目指したものではない。

本研究では、ルール教示の高い汎化性の利点とティーチングプレイバック教示の高い精度の利点を生かした教示の実現を目指す。本論文ではルール教示のチューニング手法を提案する。このチューニングに利用する詳細知識獲得のために、

* 名古屋市工業研究所 名古屋市熱田区六番 3-4-41

** 名古屋大学大学院工学研究科計算理工学専攻 名古屋市千種区不老町

* Nagoya Municipal Industrial Research Institute, Nagoya

** Dept. of Computational Science and Engineering, Graduate School of Engineering, Nagoya University, Nagoya
(Received January 12, 2007)

(Revised May 22, 2007)

ティーチングプレイバック教示からの知識獲得手法を提案する。本獲得手法にはブースティングアルゴリズム^{12),13)}を適用する。本手法は、ティーチングプレイバック教示の結果を利用して、単純な構造の制御ルールを順次組み上げて性能の良いルールセットを探索する。その過程で、制御性能の向上に寄与したルールを特定できる。

ブースティングアルゴリズムは精度の低い学習機械を組み合わせることで精度のよい学習機械を構成する手法であり、画像・音声認識からデータマイニングまで、さまざまな分野で用いられている。ロボットの分野では下坂¹⁴⁾らがブースティングアルゴリズムをロボットの動作認識に適用し、各関節の姿勢情報の時系列データから動作を分類している。しかし、文献14)の研究は獲得知識の解析の視点からなされたものではない。

ブースティングアルゴリズムにより獲得された制御性能向上ルールは、暗黙知に基づく優先的適用法¹⁵⁾を用いて、ルール教示のチューニングに適用する。本手法をロボットの通路通過問題に適用する。従来法と比較し、本手法により、制御性能向上ルールの抽出が容易であること、獲得したルールの付加により既存ルールの限定環境下での性能向上が実現できること、また、通路の変化に対しても既存ルールにより制御性能の劣化を抑えられることを示す。

2. 制御ルールの獲得

2.1 ルール教示

本論文では、ルール教示にはファジィルール¹⁶⁾を用いる。ファジィルールは、2入力1出力の場合、次式のように記述される。

$$R^i: \text{if } x_0 \text{ is } A_{i0} \text{ and } x_1 \text{ is } A_{i1} \text{ then } y \text{ is } B_i \quad (1)$$

ここで、 R^i は i 番目 ($i = 1, 2, \dots, N_1$) のルール、 A_{i0} 、 A_{i1} は入力 x_0 、 x_1 のラベル、 B_i は出力 y のラベル、 N_1 はルール数を表す。このファジィルールを利用した、簡略化ファジィ推論¹⁷⁾は次式によりなされる。

$$\hat{y} = \frac{\sum_{j=1}^{N_1} b_j \mu_j(x)}{\sum_{j=1}^{N_1} \mu_j(x)} \quad (2)$$

ここで b_j は後件部シングルトン、 $\mu_j(x)$ は適合度である。

2.2 クラスタリング

筆者らはこれまで教示情報の理解を目的として、ファジィクラスタリングにより制御ルールを獲得する研究¹⁸⁾を行ってきた。クラスタリングはデータ間の近さの度合いに応じて、データを複数のクラスタに分類する手法である。それぞれのクラスタが制御ルールに対応づけられることで、全体として一つの制御器が構成される。本研究ではティーチングプレイバック教示から単純な構造の制御ルールを獲得し、これらをブースティングアルゴリズムにより組み合わせて制御器構築を行なう。ティーチングプレイバック教示からの単純な構造の制御ルールの獲得には、クラスタリングのなかでも最も単

純な方法の一つである k 平均法 (k -means) クラスタリングを用いる。

k 平均法のアルゴリズムを以下に簡単に示す。なお、ここでは x を p 次元の入力ベクトル、 y を出力値とし、教示データを $D = \{(x_1, y_1), \dots, (x_n, y_n)\}$ 、クラスタ数を k とする。

- STEP 1 $p+1$ 次元のクラスタ中心ベクトル v_i の初期値を乱数により決める。
- STEP 2 すべてのデータ D を最も近いクラスタ中心のクラスタに分類する。
- STEP 3 分類したデータを基に各クラスタの重心を計算し、新たなクラスタ中心とする。
- STEP 4 新たなクラスタ中心がすべて以前と同じであれば終了し、そうでなければSTEP 2に戻る。

次項のブースティングの際に用いるクラスタ個々の出力値はクラスタ中心ベクトルを用いて以下のように求める。

- STEP 1' 各クラスタ中心ベクトルから出力の第 $p+1$ 成分をのぞいた p 次元のベクトルを新たなクラスタ中心ベクトル v'_i とする。
- STEP 2' 入力データに最も近いクラスタ中心を求める。
- STEP 3' 最も近いクラスタ中心のクラスタ中心ベクトルの第 $p+1$ 成分を出力値とする。

2.3 制御ルール獲得のためのブースティングアルゴリズム

本研究では学習により獲得した制御ルールの中から有用なルールを抽出するため、ルール解析の容易性の観点から、入力空間の判別に前項のクラスタの組み合わせを用いることとし、その組み合わせの探索にブースティングアルゴリズムを適用する。また、制御利用のために判別器の組み合わせから連続値を出力する工夫を行なう。ブースティングアルゴリズムとは、精度の低い判別器を組み合わせることで精度のよい判別器を構成するための高速学習法であり、画像処理などの2値判別問題でよく用いられている。本研究ではブースティングの代表的なアルゴリズムである Adaboost^{19),20)}を用いる。Adaboost は、候補の中からまず一つの判別器を選択し、その判別器が誤判別したデータの重みを大きくして、つぎのステップでその重みを基に新たな判別器の一つ選択・追加し、このステップを繰り返すことで判別器全体の性能向上を図る手法である。

いま、判別器の候補の集合 $H = \{h_1(x), \dots, h_K(x)\}$ が与えられているとする。ただし、 x は p 次元の入力ベクトル、 y_L は x に対する出力ラベル $\{-1, 1\}$ である。判別器 $h(x)$ の出力は次式により表わされる。

$$h(x) = y_L \quad (3)$$

以下の手順により学習を行なう。ただし、ブースティング回数

を T 回, 学習データ $D = \{(x_1, y_{L1}), \dots, (x_n, y_{Ln})\}$ とする.

STEP 1 次式により重みベクトル $w = (w_1, \dots, w_n)^T$ を初期化する.

$$w_i = \frac{1}{n} \quad (4)$$

STEP 2 (5)~(8) 式を $t = 1 \sim T$ まで計算する.

$$h_t = L_H(D, W) = \arg \min_{h \in H} \sum_{i=1}^n w_i I(y_{Li} \neq h(x_i)) \quad (5)$$

ただし, $L_H(D, W)$ は個々の学習用データに対する重みを考慮した学習用データ D に対してもっとも誤りが少ない判別器の組み合わせで, $I(A)$ は A が真のとき 1, 偽のとき 0 をとる.

$$err(h_t) = \frac{\sum_{i=1}^n w_i I(y_{Li} \neq h(x_i))}{\sum_{i=1}^n w_i} \quad (6)$$

$$\alpha_t = \frac{1}{2} \log \frac{1 - err(h_t)}{err(h_t)} \quad (7)$$

$$w_i \leftarrow w_i \exp(-\alpha_t h_t(x_i) y_{Li}) \quad (8)$$

STEP 3 次式により最終的な判別器の組み合わせを得る.

$$\text{sgn}(F_T(x)) \quad (9)$$

ただし,

$$F_T(x) = \sum_{t=1}^T \alpha_t h_t(x) \quad (10)$$

である.

本研究では, h_t は前節の k 平均法クラスタリングにより得られた単純な構造をもつ制御ルールの出力を 2 値化した判別器, 出力ラベルは右回転: -1 と左回転: 1 を用いた.

Adaboost は 2 値判別のための学習アルゴリズムであるが, 回転角度のような連続値を出力とする問題ではそのまま適用することはできない. そこで, ブースティングは入力空間を分割するためだけに使用し, ブースティング結果を制御ルールとして用いるには, 分割された入力空間に所属する教示データの出力値の平均値を用いることとする. ブースティングアルゴリズムには, 多値判別を学習するためのアルゴリズムがある. しかしながら, 出力値の区分をあらかじめ決定しておく必要があり, そのための知識が事前に必要になってしまう. 本研究では, 知識の抽出を容易にする視点から 2 値判別の Adaboost を適用する.

k 平均法クラスタリングにより得られた制御ルール (以下 KMCR とよぶ) は, その出力が負のときは -1, 正のときは 1 として, 2 値判別器としてブースティングの候補とした. Fig. 1 はこの KMCR を模式的に示す. 図中の R, L は出力ラベルであり, それぞれ -1, 1 に対応する. 1 回目のブース

Fig. 1 Output label of k-means clustering

Fig. 2 Division of input space using Boosting

Fig. 3 Division of input space and refinement of rules

ティングによって入力空間は R を出力する空間と L を出力する空間に 2 分割される. このとき, この分割は KMCR の入力次元とは無関係である. 2 回目のブースティングにおいて, 1 回目に 2 分割された入力空間はそれぞれ R と L の空間に分割され, 4 分割となる. T 回目のブースティングで空間は 2^T 分割される (Fig. 2).

本手法ではブースティング回数が 1 回増えるごとに区分は 2 倍になり, 制御ルールは複雑になる. しかし, 毎回のブースティングにおいては, Fig. 3 のように 1 回前の区分がそれぞれ 2 つの区分に分かれるだけなので, ブースティングの前後における制御性能の改善にかかわる制御ルールの解析は, ブースティング前後の 3 つの区分にだけ着目すればよい. Fig. 3 の例では, t 回のブースティング ($BSTR(t)$) の j 番目の区分 $(t)-(j)$ が, $BSTR(t+1)$ では区分 $(t+1)-(2j-1)$ と $(t+1)-(2j)$ に分割されている.

2.4 暗黙知を利用したルールの優先適用

前節の手法により獲得された制御性能向上ルールを 2.1 節において与えられた既存ルールに付加し, 制御性能の向上を図る. 本論文では暗黙知に基づく優先度決定の手法¹⁵⁾を適用する. いまつぎの 2 つのファジイルールがあるとすると,

$$\begin{aligned} R_j : & \text{ if } x_0 \text{ is } A_{j0} \text{ and } \dots \text{ and } x_{p-1} \text{ is } A_{jp-1} \\ & \text{ then } y \text{ is } B_j \end{aligned} \quad (11)$$

$$\begin{aligned} R_k : & \text{ if } x_0 \text{ is } A_{k0} \text{ and } \dots \text{ and } x_{p-1} \text{ is } A_{kp-1} \\ & \text{ then } y \text{ is } B_k \end{aligned} \quad (12)$$

これらの p 次元入力の 2 つのファジイルールに対して, 包含関係 $A_{ki} \subseteq A_{ji}$ ($i = 0, 2, \dots, p-1$) が成り立っているとき, ファジイルール R_k 条件部はファジイルール R_j の条件部に包含されるという. このようなファジイルール R_j と R_k の間での包含関係を $R_k \subseteq R_j$ と表わす. 包含関係が成立するファジイルール間での暗黙の階層構造を表現するために, (2) 式の簡略化ファジィ推論はつぎのように変形される.

$$\hat{y} = \frac{\sum_{j=1}^{N_1+N_2} \phi(R_j, \mathbf{x}) b_j \mu_j(\mathbf{x})}{\sum_{j=1}^{N_1+N_2} \phi(R_j, \mathbf{x}) \mu_j(\mathbf{x})} \quad (13)$$

ここで、 N_2 は付加するルール数、 $\phi(R_j, \mathbf{x})$ はファジィルール R_j の重みで、次式より表わされる。

$$\phi(R_j, \mathbf{x}) = \prod_{R_k \leq R_j} (1 - \mu_k(\mathbf{x})) \quad (14)$$

上記の包含関係に基づくファジィ推論により、ブースティングの過程で抽出された制御性能向上ルールは、ティーチングプレイバック教示のなされた限定環境下で優先的に利用される。

3. コンピュータシミュレーション

本研究では、提案する手法を自律移動ロボットによる通路通過問題に適用し、制御性能向上ルールの抽出が容易であること、これらルールの付加により限定状況下での性能向上が実現できること、また、通路の変化に対しても既存ルールにより制御性能の劣化を抑えられることを示す。

3.1 コンピュータシミュレーション

自律移動ロボットは直径 20 cm の円形とし、Fig. 4 に示すように進行方向に対して ± 60 度、 ± 40 度、 ± 20 度、0 度方向（反時計回りを正とした）の最大 400 cm までの障害物と移動ロボットとの距離が検出できるものとした。Fig. 5 に通路を示す。通路は入口から出口まで一定幅 200 cm、入口から角まで 200 cm、角から出口まで 200 cm で左に直角に曲がっている。自律移動ロボットは 1 ステップに 2 cm だけ進行し、壁面との衝突回避行動を方向転換のみで行なった。教示の際、自律移動ロボットは 1 ステップごとに教示者に操作され通路通過行動を行なった。教示者は、通路全体とロボットの位置を鳥瞰でき、大域的に状況を判断して、移動ロボットを操作した。壁面に衝突することなく入口から出口に到達するまでに Table 1 の 14 種類の入力情報と 1 種類の出力情報 (y : 回転角度) を記録した。教示は初期位置を通路の左右の壁からそれぞれ 40 cm と 70 cm および通路の中央の計 5 点、初期方向を入口から通路に向かって進行方向の正面と左右 30 度の 3 方向を組み合わせた 15 通りとした。この初期位置に対して通路の中央を通るような意図をもって教示が行なわれた。Fig. 6 に得られた軌跡を示す。記録したデータを基に 1 入力または 2 入力の (2.2 項のアルゴリズムにおいて入力ベクトルの次元 $p = 1$ または 2 として) 制御ルールをクラスタ数 4 として k 平均法クラスタリングにより獲得した。本シミュレーションでは入力変数が 14 種類、経路が 15 通りであったので 1575 種類の行動ルールが獲得された。この KMCR を候補として BSTR を獲得する。ただし、出力が 0 のデータは除外した。従来法として BSTR と入力変数の数およびクラスタ数を同等として獲得した KMCR と比較し、本手法により得られたルールの解析が容易であることを示す。

3.2 結果と考察

Table 2 にブースティングで選択された KMCR の入力変

Fig. 4 Configuration of robot and allocation of sensors

Fig. 5 Corridor

Table 1 Input variables

Variables	Index
x_0	Distance of obstacle that exists from the front to the left side in direction of 60 degrees
x_1	Increment of x_0
x_2	Distance of obstacle that exists from the front to the left side in direction of 40 degrees
x_3	Increment of x_2
x_4	Distance of obstacle that exists from the front to the left side in direction of 20 degrees
x_5	Increment of x_4
x_6	Distance of obstacle in direction of the front
x_7	Increment of x_6
x_8	Distance of obstacle that exists from the front to the right side in direction of 20 degrees
x_9	Increment of x_8
x_{10}	Distance of obstacle that exists from the front to the right side in direction of 40 degrees
x_{11}	Increment of x_{10}
x_{12}	Distance of obstacle that exists from the front to the right side in direction of 60 degrees
x_{13}	Increment of x_{12}

Fig. 6 Teaching tracks

数を示す。Fig. 7 (a)~(f) にブースティングの 1, 5~9 回目の軌跡を示す。初期位置を通路の左右の壁からそれぞれ 40 cm および通路の中央の 3 点、初期方向を入口から通路に向かって進行方向の正面と左右 30 度方向の 3 方向を組み合わせた場合の軌跡である。BSTR1 から BSTR5 では一番壁寄りの初期位置の経路が失敗し、BSTR6 から BSTR9 はすべての初期位置で成功した。ブースティング回数が増すにつれ教示の経路に近い軌跡になっていった。

Table 2 Input variables of selected KMCRs

Boosting numbers	Input variables
1	x_0, x_{12}
2	x_7, x_{10}
3	x_6, x_9
4	x_2, x_8
5	x_{12}
6	x_0
7	x_{13}
8	x_0, x_1
9	x_0, x_{13}

Fig. 7 Tracks using BSTR **Fig. 8** Tracks where an improvement was observed between them **Fig. 9** Division of input space and refinement of rules

ブースティング前後の制御ルールを比較する。Fig. 8 に BSTR5 と BSTR6 においてルール改善が見られた壁際の軌跡を示す。図中の○で囲った部分の軌跡には、Fig. 8 (a) の BSTR5 では区分 5-30 のルールが関与していた。これに対し、

Fig. 10 Tracks where another improvement was observed **Fig. 11** Division of input space and refinement of rules **Fig. 12** Tracks using k-means clustering that used input variables ($x_0, x_2, x_6 \sim x_{10}, x_{12}, x_{13}$)

Fig. 8 (b) の場合では、区分 6-60 のルールが関与していた。Fig. 9 に示すように BSTR6 では KMCR6 により BSTR5 の区分 5-30 は区分 6-59 と 6-60 に分割されていた。Fig. 8 (b) の状況では区分 6-60 が選択され、5-30 よりも大きな出力値により大きく左回転をしたことがわかる。

Fig. 10 に BSTR8 と BSTR9 の場合について示す。BSTR8 では Fig. 10 (a) の○で囲った部分において、区分 8-240 のルールで行動していた。これに対して、Fig. 10 (b) では、区分 9-480 のルールで行動していた。Fig. 11 に示すように BSTR8 の区分 8-240 は区分 9-479 と 9-480 に分割されていた。Fig. 10 (b) の状況では区分 9-480 の出力値は、8-240 の出力値よりも 4 倍程度大きいため左に急旋回していたことがわかる。

つぎに、従来法との比較を行なった。BSTR7 で用いられた入力変数は $x_0, x_2, x_6 \sim x_{10}, x_{12}, x_{13}$ の 9 変数で、重複しない区分数は 95 であった。比較のためこの BSTR7 と同等のルール数となる 9 入力 95 クラスターの KMCR を計算した。ただし、入力変数は 14 種類あるので、すべての組み合わせ 2002 通りの KMCR を計算した。Fig. 12 に BSTR7 と同じ入力変数の組み合わせの KMCR による軌跡を示す。この KMCR は同じ入力変数を用いても適切な制御ルールを獲得できていない。これ以外に入力変数の組み合わせについて KMCR によりルール獲得を行ない、教示経路によく似た軌跡が得られた例を Fig. 13 に示す。KMCR の入力変数は $x_0, x_2 \sim x_4, x_6, x_7, x_{10} \sim x_{12}$ であった。Fig. 13 と Fig. 7 (d) を比較すると、KMCR のみの従来法でも同等のルール数であれば BSTR とほぼ同等のルールを獲得することは可能であった。しかし、従来法ではルール全体を一括して更新して

Fig. 13 Tracks using k-means cluster that used another set of input variables ($x_0, x_2 \sim x_4, x_6, x_7, x_{10} \sim x_{12}$)

Table 3 Fuzzy rules

x_2	Near	Middle	Far
Near	Center	Middle right	Right
Middle	Middle left	Center	Middle right
Far	Left	Middle left	Center

Fig. 14 Membership functions in the antecedent

Fig. 15 Singleton consequents

Fig. 16 Tracks using fuzzy rules

しまうために、性能改善前後の当該ルールの変更度合いを知ることが困難である。

つぎに、ブースティングの過程で抽出された性能向上ルールを事前に与えた既存ルールに付加する。既存ルールとして、Table 3 に示す入力 x_0 と x_{12} のファジィルールを用いた。前件部の x_0 と x_{12} に対するメンバシップ関数は Fig. 14 に示すものをそれぞれ用い、後件部 Singleton は Fig. 15 に示すものを用いた。このルールによる軌跡を Fig. 16 に示す。このファジィルールに上記の性能向上ルール (9-124, 9-442, 9-476, 9-480, 8-192, 7-29, 6-60, 5-17, 4-11, 4-16, 3-5) を付加した。このルールによる軌跡を Fig. 17 に示す。ファジィルールによる軌跡と比較して通路中央を通る軌跡が改善されていることがわかる。つぎに Fig. 5 の通路を左右反転した通路通過問題について通路通過のシミュレーションを行った。Fig. 18 にその結果を示す。このとき 2.1 節におい

Fig. 17 Tracks using fuzzy rules with tuning rules extracted from BSTRs

Fig. 18 Tracks using fuzzy rules with tuning rules extracted from BSTRs

Fig. 19 Tracks using BSTR6

て事前に与えたファジィルールが働くことで、制御性能の低下はあまり見られない。一方、ティーチングプレイバックの結果から得られたルールセットのみを右回転の制御に用いた結果では、BSTR1~9 のうち、すべての初期位置で成功したものは BSTR6 だけだった。Fig. 19 に BSTR6 による軌跡を示す。ティーチングプレイバックの結果から得られた左回転に特化したルールセットでは、右回転の通路において大きく制御性能が劣化している。

4. おわりに

本研究はルール教示の利点とティーチングプレイバック教示の利点を生かした教示の実現を目指して、ブースティングアルゴリズムによる制御性能向上ルール獲得手法と、獲得ルールによる既存ルールのチューニング手法を提案した。本知識獲得手法は、ティーチングプレイバック教示の結果を利用して、単純な構造の制御ルールを順次組み上げて性能の良いルールセットを探索する過程で、制御性能の向上に寄与したルールの抽出を容易にする。抽出した制御性能向上ルールは、暗黙知に基づく優先的適用法により既存ルールに付加し、既存ルールのチューニングをすることができる。本手法をロボットの通路通過問題に適用し、従来法と比較して、制御性能向上ルールの抽出が容易であること、獲得したルールの付加に

より既存ルールの限定環境下での性能向上が実現できること、また、通路の変化に対しても既存ルールの働きにより制御性能の劣化を抑えられることを示した。

参考文献

- 1) 植山 剛：ミニ特集「作業の教示とプログラミング」, 日本ロボット学会誌, **17-2**, 157 (1999)
- 2) 長尾, 尾上：産業用ロボットの教示作業とオープン化, 日本ロボット学会誌, **18-4**, 486/490 (2000)
- 3) C.G. Atkeson, J. Hale, F. Pollick, M. Riley, S. Kotosaka, S. Schaal, T. Shibata, G. Tevatia, S. Vijayakumar, A. Ude and M. Kawato: Using humanoid robots to study human behavior, IEEE Intelligent Systems: Special Issue on Humanoid Robotics, **15**, 46/56 (2000).
- 4) 宮本弘之：ヒト運動の最適化原理と見えねに基づくタスク学習, 日本ロボット学会誌, **19-5**, 547/550 (2001)
- 5) 石川, 古川, 鈴木：人間の操作支援により作業を遂行する移動ロボットシステム, 日本ロボット学会誌, **20-2**, 173/179 (2002)
- 6) 高木, 畠見, 寺野：対話型進化計算法の研究動向, 人工知能学会誌, **13-5**, 692/703 (1998)
- 7) 片上, 山田：実環境における進化ロボティクスと対話的設計, 計測と制御, **44-1**, No.1, 33/37 (2005)
- 8) 木村, 宮崎, 小林：強化学習システムの設計指針, 計測と制御, **38-10**, 618/623 (1999)
- 9) 近藤, 伊藤, 伊藤：拘束ルール抽出機構を用いた自律移動ロボットの段階的行動学習, 計測自動制御学会論文集, **40-3**, 353/360 (2004)
- 10) 亀井, 高木：ファジィクラスタリングを用いたファジィ ID3 と制御ルール獲得への応用, 日本ファジィ学会誌, **11-1**, 132/139 (1999)
- 11) 入月, 古橋：ファジィエントロピーに基づくファジィ ID3 の提案, 日本ファジィ学会誌, **14-3**, 329/333 (2002)
- 12) 金森, 畑埜, 渡辺：ブースティング—学習アルゴリズムの設計技法—, 森北出版 (2006)
- 13) 村田 昇：Boosting の幾何学的構造と統計的性質, 科研費特定領域研究「確率的情報処理への統計力学的アプローチ」平成14年度研究成果発表会資料 (2002)
- 14) 下坂, 祐次, 森, 佐藤：動作の時間的連続性を考慮した Boosting アルゴリズムに基づくオンライン日常動作認識, 第24回日本ロボット学会学術講演会予稿, 1M15 (2006)
- 15) 石淵, 中島：特殊化の度合いの異なるファジィルールにおける暗黙の階層構造を用いた多入力システムの言語的モデリング, 日本ファジィ学会誌, **12-1**, 114/126 (2000)
- 16) 萩原将文：ニューロファジィ・遺伝的アルゴリズム, 産業図書 (1997)
- 17) 水本雅晴：ファジィ制御の改善法 (III), 第5回ファジィシステムシンポジウム, 499/504 (1989)
- 18) 井谷, 古橋, 森井, 森川：記号に含まれるコツとパターンに含まれるコツの獲得に関する一考察, 計測自動制御学会論文集, **40-7**, 739/746 (2004)
- 19) Y. Freund and R.E. Schapire: A decision-theoretic generalization of on-line learning and an application to boosting, Journal of Computer and System Sciences, **55-1**, 119/139 (1997)
- 20) P. Viola and M.J. Jones: Robust real-time object detection, In Proc. of IEEE Workshop on Statistical and Computational Theories of Vision (2001)

著者紹介

井谷 久博 (正会員)

1991年名古屋工業大学大学院博士前期課程修了。同年名古屋工業研究所入所。現在、電子情報部電子計測研究室に所属。2007年より名古屋大学大学院工学研究科計算理工学専攻博士課程後期課程。ソフトコンピューティングの研究、振動試験に従事。計測自動制御学会、日本ロボット学会の会員。

古橋 武 (正会員)

1985年名古屋大学大学院工学研究科電気系専攻博士課程後期課程修了。同年(株)東芝、88年名古屋大学工学部助手、90年同助教授、2001年三重大学工学部教授、2004年名古屋大学大学院工学研究科教授、現在に至る。ソフトコンピューティングの研究に従事。工学博士。