簡易 SDM を利用した強化学習による AGV の経路獲得に関する研究*

渡辺 美知子^{*1}, 加藤 龍^{*2}, 古川 正志^{*1}
木下 正博^{*3}, 嘉数 侑昇^{*3}AGV Autonomous Driving Based on Scene Recognition
by Use of the Simplified SDMMichiko WATANABE, Ryu KATOH, Masashi FURUKAWA^{*4},
Masahiro KINOSHITA and Yukinori KAKAZU^{*4} Asahikawa National College of Technology, 2-2 Shunkodai Asahikawa, 071-8142 Japan

An intelligent material-handling system is an important part of an autonomous decentralized manufacturing system (ADMS). Especially, an automatically guided vehicle (AGV) is the core of the material-handling system. This paper reports on a method to drive the AGV autonomously in the ADMS. The new method proposed here combines the sparse distributed memory neural network (SDM) with Q-learning (Q-L). The SDM explores and acquires feature scenes required for AGV driving. The Q-L finds a direction to take at a particular scene acquired by the SDM. Numerical simulation verifies that the SDM can extract the feature scenes necessary for driving the AGV, and that the Q-L can instruct the right direction to the AGV at each extracted scene so that the vehicle may move towards the target location.

Key Words: AGV, Autonomous Distributed Manufacturing System, Q-Learning, SDM, Navigation Problem

1. 緒 言

自律分散型生産システムを確立する上でマテリアルハンドリングシステムは重要な位置を占めている。特に、無軌道方式の無人搬送車 (Automatically Guided Vehicle; AGV) は、自律運転が可能であれば工場内の各ショップを自由に移動して仕事を遂行可能とする高い自由度をもち大きな注目を浴びている。

しかしながら、こうした AGV の自律運転を可能とするには AGV の知能化が必要とされ、知能化を実現するための技術として2つの大きな問題が存在している。その一つは、現在地あるいは出発点から指定された目標地点への経路をどのように自律的に獲得できるかとして知られる経路獲得問題である。他は、AGV が複数で走行するときの AGV 間の衝突回避と速度協

調をどのように自律的に獲得し、実現するかである。

前者の問題は 1980 年代から幾何推論⁽¹⁾や人工知能の分野⁽²⁾での研究が実施され、近年では遺伝アルゴリズム⁽³⁾やファジィ推論を利用した方法が提案されている。また、著者等も Barto の Q-学習⁽⁵⁾を利用した方法⁽⁶⁾を開発している。

一方、後者の問題に対しては衝突回避問題の立場から AGV の行動を獲得するいくつかの研究⁽⁷⁾、⁽⁸⁾が行われている。

本研究では前者の問題に焦点を当てる。AI の分野によって影響を受けた幾何推論による経路獲得問題は地勢ナビゲーション問題といわれる⁽¹⁾。この問題は AGV が移動する場が凹凸をもつ地勢によって与えられるとき、出発点からゴールまでの最短経路を求めようとするものである。その代表的な解法は地勢を凸多角形に細分化し、細分化された領域を傾斜のウェイトによって平面マップとし、領域間の経路を光学におけるスネルの法則からヒューリスティックに導き出すものである。このために地勢を適正な凸領域に分割する必要があるが、計算幾何の問題となっている。また、経路探索は分割された領域の辺に沿うか、辺をスネルの法則によって決定された角度で横切るかの経路を組み合

* 原稿受付 1999 年 8 月 12 日。

^{*1} 正員, 旭川工業高等専門学校 (☎ 071-8142 旭川市春光台 2 条 2 丁目)。^{*2} 北海道大学工学部 (☎ 060-8628 札幌市北区北 13 条西 8 丁目)。^{*3} 正員, 北海道大学大学院工学研究科。

E-mail: michy@asahikawa-nct.ac.jp

わせて最短経路をヒューリスティックに発見する。このような方法はマップの作成に対して知能化というよりは計算幾何の問題となり、また工場内では AGV は平面を走行することが予想されるので実用的ではない。

GA による経路決定⁽⁹⁾は地図を持たない解法といえるが、獲得された経路による AGV の走行はオフラインの学習となるためオンラインで走行させるときにはその柔軟性を失うことが予想される。

ファジィ推論を用いた経路獲得問題は、壁伝い方法を主体とし壁、障害物、及び他の AGV を検出したときの行動をファジィ推論⁽⁴⁾によって定める方法を採用している。このような経路獲得はむしろ先に述べた後者の問題に属する。

これらの方法に対して Barto の Q-学習⁽⁵⁾による方法⁽⁶⁾は、強化学習として近年注目されている機械学習による方法である。この方法による経路学習は障害物のない工場に適用されているが、確率的ダイナミックプログラミングの原理によって最適経路が獲得されることが保証されている。また、障害物があっても適用可能である。しかしながら、Barto による方法は工場内の全座標（一般にメッシュによって表現される）に対して試行錯誤的に道しるべを作成する方法となり、最適経路の作成に長大な試行錯誤時間を要する欠点を備えている。にもかかわらず、この方法はオフライン・オンラインの学習が可能であり汎用的な方法である。

本研究ではこうした経路獲得問題に対してより人間が知識獲得を行う形態に近い方法として、簡易 SDM (sparse distributed memory; 疎分布メモリー)⁽⁹⁾を採用したシーン（風景）獲得に基づいた強化学習による経路獲得法を提案し、その数値計算シミュレーション結果を報告する。SDM は連想記憶とともに類似した記憶をクラスター化しそれらを識別する機能をもつ。提案する方法ではこの機能を用いてシーンが異なる地点を抜き出し、その地点で AGV の行動決定に強化学習を採用する。仮想工場を用いた数値計算シミュレーションでは多数の障害物をもつ工場で SDM を制御するハミング距離を適度を選択することで所望の経路が得られることが分かった。

2. 対象とする経路獲得問題

以下に本研究で対象とした問題を述べる。

2.1 前提条件 工場を AGV の走行フィールドとし、フィールドは格子分割によって各格子の位置を特定できるものとする。また、フィールド内には工作機

械、マテリアル・ハンドリング装置・バッファ等々の障害物が置かれているとする。このとき、フィールド内を走行する AGV に以下のような条件を設置する。

1. AGV は自身の周辺の $n \times n$ の格子について、壁、工作機械等の障害物を検出できる。
2. AGV は通過したシーン（風景）を必要に応じて記憶できる。
3. AGV は現在地点と目標地点の座標値を知ることができる。

条件 2 のために SDM を採用する。また、AGV が現在地を工場内で知ることが、工場内にナビゲーション用の 3 台の無線灯台を設置する等により、可能な技術である。

2.2 問題の記述 先に設定した条件の下で、経路獲得問題は以下のように記述できる。

$$\begin{aligned} \min_{Seq(S_c), n} & W_1 F_1(Seq(S_c)) + W_2 F_2(n) \\ \text{subject to} & F_1(Seq(S_c)) \leq T \\ & S_c \in S \end{aligned} \quad (1)$$

ここで、 S は工場内で AGV が観察できる全シーンの集合、 $Seq(S_c)$ は AGV が工場内で移動したときに獲得したシーンの順序、 $F_1(Seq(S_c))$ は獲得したシーン $Seq(S_c)$ に沿って AGV が移動した経路の目標地点までの移動時間の評価、 $F_2(n)$ は経路獲得に要したシーンの評価、 T は許容最大移動時間である。また、 W_1 、 W_2 は各評価のウェイトである。式 (1) で記述される問題は、できるだけ少ないシーンを獲得して AGV が目標地点までの経路を獲得することである。

Fig.1 Decoder neuron

3. 疎分布メモリー法 (SDM 法)

疎分布メモリー法 (SDM 法) は Kaneva 等によって開発されたニューラルネットワークに分類される連想記憶法である。その概要は以下に記述される。

3.1 SDM SDM は、アドレスとそのアドレスの 1 ビット毎に付加されたカウンターからなる。2 値表

現特徴ベクトルは最初はそのままアドレスとなり、アドレスから指定されたハミング距離内のアドレス全てのカウンターに特徴ベクトルが1ビットづつ格納される。特徴ベクトルが与えられる毎に同様の手続きが繰り返されるが、すでに一度カウンターに特徴ベクトルが格納されているアドレスでは、特徴ベクトルが1ビット毎にカウンターに加算される。カウンターはビットの2進値が1であれば1加算され、0であれば1減算される。同じクラスと考えられるハミング距離内の特徴ベクトルが多く与えられると、もっとも共通なアドレスのカウンターにクラスの特徴が集約されるようになる。ある特徴アドレスが与えられるとそのクラスは、カウンターの各ビットを非負であれば1、負であれば0として共通の特徴ベクトル及びアドレスを生成する。また、これを繰り返すと連想メモリーを構成することもできる。

3. 2 SDM の実装 各アドレス $y=[y_1 y_2 \dots y_m]^T$ はニューロンのウェイトを

$$w_i = \begin{cases} 1: y_i = 1 \\ -1: y_i = 0 \end{cases}, (i = 1, 2, \dots, m) \quad (2)$$

であるように設定する。ここでベクトル y は n ビットの2進値アドレスをベクトルとして置いたものである。入力ベクトル $x=[x_1 x_2 \dots x_m]^T$ が与えられると、各アドレスは図1のように

$$NET = \sum_{i=1}^m w_i x_i \quad (3)$$

を計算し、

$$OUT = \begin{cases} 1: NET \geq R \\ 0: NET < R \end{cases} \quad (4)$$

によって、 $OUT=1$ のときアドレスと同じ特徴ベクトルをもつクラス、 $OUT=0$ のとき異なるクラスと入力ベクトルを判定する。ここで、 R は閾値であり、クラスを定めるハミング距離により以下のように制御される。すなわち、アドレスのウェイト w_i が1である個数を SUM とし、ハミング距離を H で与えると、 $R=SUM-H$ として任意のハミング距離内の入力ベクトルを同じクラスかどうか制御する。これはデコーダ・ニューロンと呼ばれる。

3. 3 簡易 SDM 法 SDM は特徴ベクトルが m ビットの場合、 2^m 個のアドレスを必要とする。それは m が大きくなるに従い全アドレス空間に対する特徴ベク

トルの探索範囲の比が小さくなる特徴を備えるが、一方そのアドレスの空間は途方もなく大きくなる欠点を備えている。本研究では後述するように特徴の抽出のみを目的とするので、メモリー格納を以下のように変更する。

1. 特徴ベクトルを2次元配列の一方に2進値アドレス（アドレスデータ）として格納し、他方にはカウンターとして同じアドレス（カウンターデータ）を格納する。
2. 新たな特徴ベクトルをすでに格納された特徴ベクトルのデコーダ・ニューロンで比較し、同じクラスの特徴ベクトルと判定されれば、そのカウンターにすでに述べた方法で新たな特徴ベクトルを加算する。そうでなければ、新しい特徴としてこの特徴ベクトルを2次元配列のアドレスデータとカウンター・データに格納する。

このようにすることにより、アドレス空間を減少することができ、またカウンターには集約された特徴が格納されるようになる。

4. 経路獲得のためのシーン獲得と強化学習

ある地点から目的地までの経路の獲得を行う知識獲得の形態として、人間が実行していると思われる方法を AGV の経路獲得に採用する。すなわち、以下の行動を採用する。

(1) 目的地の方向に前方に進む。その間、シーン（風景）が同じであれば特に注意を払わない。

(2) 交差点あるいは障害があるとシーンが変化し、変化したシーンを記憶する。変化した場所で進行方向を決定する。

(3) 決定した進行方向に前進する。その間、シーン（風景）が同じであれば特に注意を払わない。もし決定した移動方向が誤りであることが分かれば、再度記憶したシーンに戻り別の進行方向を決定する。

(4) 目的地に到達したとき、経路を決定したシーンのみを記憶する。目的地に達しなければ(2)へ戻る。

このような方法を簡易 SDM と強化学習を用いて実現する。

4. 1 シーンの獲得 AGV には、2章で述べたように $n \times n$ セルの AGV を中心としたセンシング可能領域を設定する。各セルには障害物があれば1を、そうでなければ0を設定する。これを1次元ビット列とし、シーンの特徴ベクトルとする。経路獲得に必要なシー

Fig. 2 Scene acquisition

Fig. 3 A sensed region

(a) Before blinding. (b) After Blinding.

Fig. 4 Blinding

ンの獲得は以下のように実施できる。

(1) 最初のシーンの特徴ベクトルを疎分布メモリに格納し、これをベクトル y としてデコーダ・ニューロンのウェイトを式 (1) を用いて設定する。また、デコーダ・ニューロンに対し、ハミング距離 H を設定する。

(2) 決定された進行方向について 1 ステップ進む毎に、新しく観測された特徴ベクトルを x と置き、デコーダ・ニューロンに設定する。もし OUT が 0 であれば、類似したシーンとしてこれをベクトル y のカウンターに設定し、同じ手続きを繰り返す。OUT が 1 であれば、異なるシーンとしてこのシーンの特徴ベクトルを疎分布メモリに追加格納し、(3) へ進む。

(3) 異なるシーンが現れた場所で移動方向を決定し、その方向に前進する。目標地点に達するとシーン獲得を終了する。そうでなければ、(2) へ戻る。

(1) ~ (3) の手続きにおいて、移動方向の決定は後述する強化学習によって行う。

4. 2 シーンのブラインド化 センサー情報は AGV が存在する中心から外へと右回りに順に行う。もしあるセルに障害物が存在するとセンサーが応答したときは、中心セルからそのセルへ直線を引き、直線と交わる外側にあるセルは障害物があるとみなし、その場所のベクトル成分値を 1 とする。これをシーンのブラインド化と呼ぶ。これは、AGV の近い場所に障害物が存在した場合、それより遠くはセンシング不可能を仮定する操作である。

4. 3 異なる地点での類似シーン 異なる地点においても類似したシーンが観測される可能性が生じる。例えば、ある地点においていつも左側に壁があり、同様なシーンが他の場所においても生じる場合である。このように、明らかに連続する類似したシーンではなく、シーンが変化するときこれまで獲得したシーンの中に類似したシーンを見つけだすことを避けるために、獲得したシーンのデータには獲得した場所の AGV の座標値を付加する。これによって、同じ様なシーンがデコーダ・ニューロンにより現れても、座標値によって場所の違いを明らかにできる。また、経路にループが生じた場合は、シーンと座標値が一致するからループであることを判断することが可能となる。

4. 4 移動方向の決定 移動方向の決定には試行錯誤に基づいた強化学習として知られる機械学習法である Q-学習を採用する。Q-学習は与えられた状態とエージェントの可能な行動から、学習に基づいて確率的に一つの行動を決定する方法である。今、エージェントを AGV とし、状態と行動を以下のように定義する。

S_c : シーンが変化し、獲得された新しいシーン

$A = \{F, R, L, Rv\}$: AGV の移動方向, F, R, L, Rv はそれぞれ前進, 右折, 左折, 後進を表す

このとき、 k 番目に現れた状態 $S_c(k)$ とその時の行動 $a(k) \in A$ によって AGV が得られた利益の期待値を $Q(S_c(k), a(k), t)$ と設定し、この期待値を Q-値と呼ぶ。AGV が得る利益は、目標値に近づくときに得られる値と定義する。4 つの行動から選択された行動によって、Q-値は以下のように更新される。

$$Q(S_c(k), a(k), t) = (1 - \alpha)Q(S_c(k), a(k), t-1) + \alpha[d(k) + \gamma \max_{a \in A} Q(S_c(k), a(k), t)] \quad (5)$$

ここで、 α と γ は学習パラメータであり、1 より小さな定数がとられる。 α はQ-値の急激な変動を回避するパラメータであり、ニューラル・ネットワークの修正バック・プロパゲーション法と同様の1次モーメント化の役割を果たしている。 α が大きい時は学習の速度が速くなるが、ときによりQ-値の変動が大きくなり学習の収束の安定性に欠ける結果を及ぼす。 γ は記憶の減衰率を表現する長期記憶のパラメータであり、その値が大きい程学習結果が長く影響を及ぼす。 γ の値が0の時は、そのときの行動評価のみが取り入れられ、過去の学習結果はまったく取り入れられない。 $d(k)$ は行動 $a(k)$ により得られる直接利益として、

$$d(k) = \begin{cases} \varepsilon_1 > 0: \text{AGV moves close to the target} \\ \varepsilon_2 < 0: \text{AGV moves far to the target} \end{cases} \quad (6)$$

と定義する。式(5)は右辺を左辺に代入するアルゴリズム式を表すものとする。行動の決定は、Q-値を基にボルツマン分布関数を採用して確率的に、

$$a(k) = \text{Prob}_{a \in A} \left(\frac{\exp(Q(S_c(k), a) / \text{Tmp})}{\sum_{a \in A} \exp(Q(S_c(k), a) / \text{Tmp})} \right) \quad (7)$$

から決定する。ここで、 $\text{Prob}(P_j)$ は確率 P_j に従って P_j の行動を選択する関数とする。 Tmp は計算温度である。

4. 5 バケット・ブリゲードによる学習強化 Q-学習によるQ-値は、その時点での状態(場所)における各行動に対して将来得られと思われる期待値であ

Fig. 5 A test field (1)

Fig. 6 A test field (2)

Table 1 Experimental condition

Experimental parameter	Given value
A velocity of AGV	Constant
A start direction of AGV	West
Hamming distance	0~30
ε_1 (reward)	0.08
ε_2 (penalty)	- 0.06
α (Learning ratio)	0.3
γ (Damping ratio)	0.8
β (Damping ratio)	0.5
Tmp(Computational temperature)	1.0
Initial values of Q	2.0
r (The number of bucket brigades)	8

る。従って、Barto 等のレーストラック問題にみられるQ-学習のように、目的地に到達してから逆に利益が過去の経路に遡る直接利益の与え方を先に述べた方法を行っていない。これを実施するためにバケット・ブリゲード・アルゴリズムを導入する。現在のシーン $S_c(k)$ に至るまでのシーンとそのシーンでの行動の対を $(S_c(k-1), a(k-1))$, $(S_c(k-2), a(k-2))$, ..., $(S_c(k-r), a(k-r))$ とする。ここで、 r は現在のシーンに至るまでに通過した遡るシーンの個数とする。これらのシーンと行動の対をもつQ-値について、

$$d(k-u) = \beta d(k-u+1); u=1, 2, \dots, r \quad (8)$$

なる直接利益を設定し、式(6)を用いて更新する。ここで、 β は $0 < \beta < 1$ になる定数である。過去に遡って利益を分配する方法はバケット・ブリゲードと呼ばれる。

5. 数値計算実験シミュレーション

提案したSDMに基づいたシーン獲得と経路生成法が有効であることを検証するために、いくつかの数値計算実験シミュレーションを行った。ここでは、代表的な二つの実験例について報告を行う。

5. 1 類似したシーンが連続する経路 図5に示すように、連続して類似したシーンが獲得され则认为られるテストフィールドに対して実験を行った。このテストではスタート地点からゴールに向かってAGVを走行させる。実験条件は、表1のように設定した。学習パラメータ α の設定は小さな値(0.1)から数値計算実験を行い、学習が速くかつ最も安定した値を事前にもとめた。また、学習パラメータ β の設定の場合には、その値を大きな値(0.9)から数値計算実験を行い、 α 同様に事前に決定した。その他のパラメータは学習速度及び安定性を評価とした事前の数値計算実験による経験的な値である。

シーンを表現する特徴ベクトルは AGV を中心に 7×7 セルを用いて表現する。従って、通常の SDM では 2^{49} のメモリー・アドレスが必要になる。簡易 SDM ではこのメモリー・アドレス数を 2000 とした。ハミング距離 2, 6, 12 のときに学習結果得られた経路を図 7 に示す。ハミング距離によって選択される経路が異なることがわかる。ハミング距離が 12 のときに、学習後に走行した経路のシーンを図 8 に示した。これから例えば 6 番目と 12 番目のシーン、7 番目と 13 番目のシーンでは同じシーンとなっているのが分かる。これらはシーンを獲得した場所の座標値で区別されている。図 9 は、学習回数（ゴールに至るまでを 1 回）とその時に要した AGV の所要時間の学習曲線である。ほぼ 4 万回の試行で経路が得られることが分かる。図 10 はハミング距離に対して、探索されたシーン数、学習によって経路生成に最終的に使用されるシーン数、その時の経路長を比較したものである。これから最小経路長を生成する適正ハミング距離が存在することがわかり、本実験の場合は 10~12 程度である。

H=2

H=6

H=12

Fig. 7 Acquired paths depending on the Hamming distance

Fig. 8 Scenes used for generating a path in the test field (1) when the given Hamming distance is 12

Fig. 9 A learning curve to obtain a suitable path

Fig. 10 Hamming distance vs. explored scenes, acquired scenes for generating a path and elapsed time from a start location to goal one

Table 2 Experimental condition for field 2

Experimental parameter	Given value
A velocity of AGV	Constant
A start direction of AGV	Arbitrary
Hamming distance	0~25
ϵ_1 (reward)	0.08
ϵ_2 (penalty)	- 0.04
α (Learning ratio)	0.3
γ (Damping ratio)	0.8
β (Damping ratio)	0.5
Tmp (Computational temperature)	1.0
Initial values of Q	2.0
r (The number of bucket brigades)	5

5. 2 複雑な工場モデル 図 6 に示されるようなテストフィールドの工場を想定し、経路獲得の実験を行

った。中央に配置された4つの塗りつぶされた正方形は工作機械を示し、それ以外に塗りつぶされた部分は工場内の障害物を想定している。AGV は左下角の待機場から各工作機械への経路、各工作機械間での経路を学習するようにした。このときの実験条件を、表2のように設定した。図11に二つの対角に配置した工作機械間で学習後に生成された経路の二つ例を示す。これらの経路獲得に用いたハミング距離は7である。結果はほぼ満足できる経路を得ており、経路のループが作成されないことも検証される。図12は図11(a)におけるハミング距離に対して、探索されたシーン数、学習によって経路生成に最終的に使用されるシーン数、その時の経路長を比較を示している。図から、経路探索の適正なハミング距離がやはり存在し、この場合は4~8である。

(a) A path generated between two machine tools (case1)

(b) A path generated between two machine tools (case2)

Fig. 11 Paths acquired by learning

Fig.12 Hamming distance vs. explored scenes, acquired scenes for generating a path and its elapsed time

6. 結 言

工場内での AGV の学習に基づく経路獲得問題に対し、経路上のシーンの変化に着目した経路獲得の方法として、簡易 SDM と Q-学習に基づいた経路獲得法を提案した。更に、その数値計算シミュレーション実験の結果を報告した。これらから、以下を述べることができる。

(1) 通常の SDM では 2^{49} 必要とするメモリー・アドレスを 2000 前後の少ないメモリー・アドレスを用いてシーン獲得を実施することができる。数値計算実験では最大探索シーンの数はどちらの実験においても 1600 前後である。また経路生成に使用されるシーン数は、デコード・ニューロンの閾値によって左右され、これはハミング距離で制御される。

(2) Q-学習をシーン獲得と組み合わせることにより、準最適な経路を獲得できた。なお、この Q-学習にはバケット・プリゲージングによる報酬分配を行った。

(3) 学習によって得られた経路は、ハミング距離によって左右され、適切なハミング距離が存在する。

(4) 工場内の全座標を利用せず、シーン探索点のみの座標値で経路を得ることができる。また、これは経路のループや類似したシーンが多数生じるときに有効である。

今後、マルチ・エージェントの行動として複数の AGV 走行に関する研究とその場合の AGV 間の通信プロトコルの在り方を考慮した総合的なモデルの開発と実験を行う予定である。

なお、本研究は平成 10～12 年度の文部省科学研究費・基盤 C「マルチエージェントの学習・適応に基づいた自律分散型生産システムの研究」（課題番号 10650129）に基づいて実施したものである。

文 献

- (1) Edited by D. Kapur and J. Mundy; Geometric Reasoning, The MIT Press(1989),171-201
- (2) P. H. ウィンストン(長尾真, 白井良明訳); 人工知能, 培風館(1979), 261—266
- (3) 川上敬, 嘉数侑昇; クラシファイアースystemによる自律型ロボットナビゲーションに関する研究, 日本機械学会論文集(C編) 59, 564(1993), 2339—2345
- (4) B. Beaufre and S. Zeghloul; A mobil robot navigation method using a fuzzy logic approach, Robotica, 13(1995),437-448
- (5) A. G. Barto, S. J. Bradtke and S. P. Singh; Learning to act using real-time dynamic programming, Artificial Intelligence, 72(1995), 81-138
- (6) 谷昌彦, 渡辺美知子, 古川正志; 失敗と成功の2エージェントによる強化学習, 第7回インテリジェント・システム・シンポジウム講演論文集, 計測自動制御学会(1997), 369—372
- (7) 藤井誠, 古橋武; ファジイクラシファイアシステムを用いた言語指示からの意図抽出手法に関する一提案, 第7回インテリジェント・システム・シンポジウム講演論文集, 計測自動制御学会(1997), 579—582
- (8) 浅間一; マルチエージェントから構成された自律分散型ロボットシステムとその協調的活動, 精密工学会誌, 57, 12(1991), 2117—2122
- (9) T. Kaihara, S. Fujii and S. kunimasa; An evolutionary self-organization scheduling using coordinated autonomous work agents, Proc. of 1998 Japan-U.S.A. Symposium on Flexible Automation, III (1998), 1375-1381
- (10) N. Ono, T. Ohira, and A. T. Rahmani; Emergent organization of Interspecies Communication in Q-Learning Artificial Organisms, Proc. of European Conference on Artificial Life (1995), 396-405