

複数の自律エージェントによる 環境認識の共有化と協調作業

藤澤 隆史, 林 武文, Rolf Pfeifer, Norman D. Cook

要 旨

近年, 人工知能研究において, 「行為主体」と「環境」の相互作用を重視するアプローチが徐々に形成されつつある. 環境に対して適応を試みる自律的な行為主体を「自律エージェント」よび, またその実装として, 本研究では小型ロボットKheperaを用いている. 自律エージェントを用いたアプローチによって, 物体認識や自己組織性, コミュニケーションといった知能に関する問題に対して, より深く理論的な洞察を加えることができる. またエージェントを複数用いることで, 社会心理学的な問題, 特に「知識の共有化」や「協調行動」といった問題を探求することも可能である. 本論文では, このような問題意識から, われわれが過去に行った, もしくは現在進行中である研究の概要について報告する.

Shared Cognition and Collaboration by Multiple Autonomous Agents

Takashi FUJISAWA*¹, Takefumi HAYASHI*²,
Rolf PFEIFER*³ and Norman D. COOK*²

Abstract

The use of autonomous agents has become a popular technique for studying cognition. We have used the micro-robot, Khepera, to study object recognition, self-organization and communication. By using multiple robots, we have begun to explore issues of interest in social psychology, namely, the sharing of knowledge and collaborative activity. Our previous and current work is reviewed here.

* 1 Graduate School of Informatics, Kansai University.

* 2 Faculty of Informatics, Kansai University.

* 3 Dept. of Computer Science, University of Zurich.

1. はじめに

従来の人工知能 (Artificial Intelligence: AI) 研究におけるアプローチは、その大半が直列的な記号処理によって高度な認知メカニズムの実現を試みてきた。それらのアプローチによって構築された知能システムは、大まかに言えば、1) 環境のセンシング, 2) 環境のモデリング, 3) 実行のプランニング, 4) 実行, といった枠組みによって機能している。このような枠組みのもとでは、システムは実験者によってあらかじめ定義された単純で静的な課題環境には十分に対処できるものの、実環境のようにシステムが予測できない複雑で動的な環境に直面した場合、システムは処理能力の著しい低下を招くという問題を有していた。

したがって従来のAI研究では、チェスを指す、病名を診断する、といったような探索空間の狭い問題に限った適用がなされ、またそれらの領域については多大な成功を収めることができた。しかしながら、予測できない、継時的に変化する、局所的にしか知覚することができない、といったような性質をもつ実環境において、従来のアプローチ法によって構築されたシステムでは、その適応能力の乏しさが露呈されることが多かった。これは、行為主体である「システム」とそれを取り囲む「環境」を分離して知能を議論しているために起こる問題であり、また、システム-環境間の相互作用については比較的看過される傾向にあった。

このような従来のAIアプローチに対して、近年、システム-環境間の相互作用を重要視する新しいアプローチが形成されつつある。徐々に形成されつつある研究分野はどれもがそうであるように、「新AI (New AI)」、「行動型AI (Behavior Based AI)」、「アニマト・アプローチ (Animat Approach)」など様々な名前と呼ばれ、それぞれはバックボーンとしている理論や主張の力点において多少の相違はあるものの、おおまかに言えば共通する部分が多く同一視してよいものと考えられる。

以下、第2章では、本研究の背景となっているこれらの新しいアプローチについて簡単に解説し、第3章ではこれらのアプローチにおいて主要なツールとなっている自律移動ロボットの概要について説明を行う。次に具体的な研究例として、第4章では大脳半球の両側メカニズムに基づいたロボットによる物体認識実験、第5章では複数のロボットによる協調作業シミュレーションのそれぞれについて、実験結果と考察について報告する。最後に、第6章では全体をまとめ、今後の展望について述べる。

2. 研究の背景となるアプローチ

第1章で述べたように、従来のAIアプローチでは、知能システムはある環境内での実行に際して、まず環境のモデリングを行う。しかしながら、実環境においては上記に挙げたさまざまな理由から、システムがふるまうために必要な知識をあらかじめ完全に定義することは不可能である。したがって、従来のAIアプローチでは、まず実験者が、ある課題に対する問題解決のための知識を全て定義できるような単純な課題環境を設定することで、システムのパフォーマンス向上を追

及するというような手法で研究が行われてきた。そのような手法によって構築されたシステムは、環境情報が無限に存在し、あらかじめ環境に対する知識の定義が不可能な実環境においては乏しい実行能力しか発揮できず、これはAI分野における「フレーム問題」としても一般的な問題であるといえるだろう。

これに対して、新AIをはじめとする新しいアプローチでは、ある特定の状況におけるシステムの知能的なふるまいは、その状況自身との相互作用の結果、生成されるものとして捉えられている。同様にPfeiferらは、認知科学の分野においてもシステム-環境間の相互作用が「知能」の発現にとって本質的なものであると主張し、「具体化認知科学 (Embodiment Cognitive Science)」と呼ばれる新しい方法論の構築を試みている^[1]。したがって新AI、もしくは具体化認知科学では、システムの知能的ふるまいを理解するにあたり、そのシステムの実環境における「自律性 (Autonomy)」、「具体化 (Embodiment)」もしくは「状況に埋め込むこと (Situatedness)」を重要視している^[2]。システムが実環境に対して柔軟に適応し、われわれが一般的に考えるような意味において知能的であるためには、環境を知覚し働きかけるための物理的機構を有していなければならない。またシステムが物理的機構を有しているならば、そこには物理的機構に沿った形でその知能というものが存在するはずである。

また、生体システムの認知メカニズムやその他の行動（例えば社会的行動）を研究・モデル化する場合においても同様のことが言えるだろう。生体システムにおける認知や行動は、物理的な機構を通じた実環境との相互作用を基盤として成立していることを考えれば、物理的な機構を捨象してしまったモデルは、そのモデルが予測・説明するべき部分的な現象の射程内では有効であるかもしれないが、実環境においてそのシステムが適応することができるか否かとは別の問題である。したがって、生体の適応行動に関するモデルは最終的には具体化されるべきである、というのが具体化認知科学の主張に沿った見解であるということになるだろう。「新AI」では純粋に実環境に対する適応的な知能の実現を目指すことに力点をおいているのに対し、「具体化認知科学」では生体における（最終的には高次的な認知機能を有している人間の）認知メカニズムの理解に力点を置いている。したがって、具体化認知科学では新AIに比べ、理論の説明的側面として上記のようなアプローチをとる傾向が強いといえるだろう。しかしながら、これらはあくまで力点における程度の相違であって、具体化認知科学が知能の実現を放棄しているわけでもなければ、新AIが生体メカニズムとの理論的整合性を放棄しているわけではないことを留意するべきである。

これらの新しいアプローチにおいて、コンピュータ・シミュレーションは軽視されているわけではない。むしろ、場合によってはシミュレーションをモデル構築の際における有効なツールとして用いる。これは、「具体化」の精神とは矛盾しているように思えるが、具体化認知科学が重要視しているのはモデルである知能システムが「環境」を知覚し、推論し、働きかけるという相互作用を通して、適応するという意味における「具体性」であり、環境との相互作用をもたない、閉じた世界において「知能」を議論することの危険性である。本研究では、実環境・仮想環

境を区別せず、与えられた環境との相互作用を通じ、能動的に環境に対して適応を試みる自律的な行為主体を「自律エージェント (Autonomous Agent)」, もしくは単に「エージェント (Agent)」と呼ぶことにする。またエージェントが物理的に実装された場合には、物理的な実体を指して「(自律) ロボット」と呼ぶことにする。

3. 実験に用いられた自律エージェント

具体化認知科学では生体の認知メカニズムを研究する際に、仮定されたモデルが実環境との相互作用において適切な適応行動を導くかどうかを確認するために、モデルの物理的な具体化を行う。モデルの具体化のために用いられる主な手法は、自律移動ロボットとその他の物理的環境による実験、もしくは自律ロボット (=自律エージェント) と環境を模した仮想現実上で行われるコンピュータ・シミュレーションである。




図1 小型移動ロボットKhepera

本研究で用いられたロボットは、研究・教育用として広く用いられている小型移動ロボット Kheperaである (図1)。Kheperaはその他の様々なロボットに比較して、1) 小型であるために小さなスペースで実験を行うことができる、2) 必要性に応じて、拡張することができる様々なモジュールをもつ、3) 広く、また一般的なツールによって制御を行うので、扱いが容易である、といった特徴をもつ^[3]。

Kheperaのもつ性能の概要について表1に示す。Kheperaは直径5.5cm、高さ3cmの大きさで、赤外線による近接センサと環境光センサを兼ねた小型センサを周囲に計8つ装備している。また、エンコーダ付きのDCモーターを装備した車輪を左右に持ち、それぞれ独立に制御することができる。電源はコネクタを通して交流電源に接続することができるが、Khepera自身にもNiCd電池が内蔵されており、30分間程度であれば電源供給なしでの単独走行を行うことができる。

Kheperaの制御には、主に2通りの方法が存在する。1つめの方法は、コンピュータ上で制御プログラムを作成し、そのプログラムをバイナリコードに変換、そのコードをKheperaにダウン

ロードするというものである。この方法には、制御マシンとKheperaを独立に動かすことができるという利点が存在するが、一旦プログラムを実行してしまうと終了時まで制御側から割り込みをかけることができないという欠点がある。

表1 Kheperaの性能

プロセッサ	モトローラ68331
RAM	256キロバイト
ROM	128もしくは256キロバイト
運動	2つのDCモーター（インクリメントエンコーダー装備）
最大スピード	60cm/秒
センサー	8つの赤外線近接センサーと光センサー
電源	外部もしくはNiCdバッテリー電池
自律性	30分
拡張バス	K拡張バスにモジュールを付加することで可能
サイズ	直径55mm 高さ30mm
重量	約70g

2つめの方法は、広く一般的に用いられている方法であり、ホストマシンにおけるRS232Cシリアルポートを介して制御を行うというものである。この方法では、実験者は自由にコンピュータ（PC, SUN, MAC, etc.）を選択することができ、またプログラミング言語（C, C++, Lisp, etc.）も同じく選択することができ実験環境における自由度の高さが利点である。Kheperaは「SerCom」とよばれる実行モードを有しており、そこではロボットの全ての機能はRS232Cシリアルポートを介して単純なASCIIコマンドによって制御することができる（図2）。

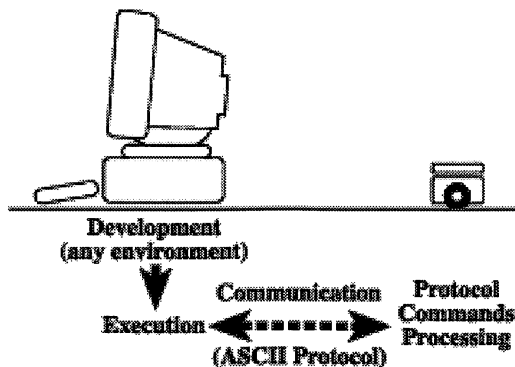


図2 Kheperaの制御方法

例えば、"D,5,3"というコマンドは左車輪のスピードを5、右車輪のスピードを3にセットする（1単位は8mm/s）。ロボットがコマンドを受信した時、ロボットは認識信号として"d"を返信する。

またKheperaには機能拡張タレットとして、様々なオプションが用意されている。環境に配置

された物体に働きかける効果器としてはGripperよばれるアクチュエータがあり、視覚モジュールとしてはカメラが2種類ほど用意されている。またホストマシンとKhepera, もしくはKhepera間どうしの無線通信のためにラジオ通信モジュールも用意されている。

4. 大脳半球の両側性に基づいた自律移動ロボットの物体認識実験

本章では生体における大脳半球の両側性メカニズムを考慮したニューラルネットワーク・モデルを構築し、知能ロボットの物体認識実験に適用することでモデルの有効性を確認する^[4]。

4.1 実験目的

人間の左右大脳半球の構造はほぼ対称的であるが、他の生物種とは異なって、いくらかの機能については著しく非対称であり、また脳梁を介して協調動作していることが知られている^[5]。人間が他の生物種とは異なり、また道具もしくは言語の使用といった高度の知能を有するといった点において、これら2つの関連性について研究することは、高度な知能システムを構築する上において重要な意味を持つと考えられる。大脳半球に倣ったニューラルネットワーク・モデルに、このような両側性の機能を付加することによって、物体の認識効率が向上することはシミュレーションによって確認されている^[6]、^[7]。本章ではニューラルネットワークをインプリメントした移動ロボットによる物体認識を取り上げ、両側性を付加した場合と、しなかった場合の認識率について比較実験を行った。

4.2 両側性ニューラルネットワーク・モデル

本研究で用いられたニューラルネットワークは自己組織化マップと呼ばれるものであり^[8]、ネットワークは外界から得られた多次元情報を、その情報間の距離に基づいて2次元上にマッピングする。すなわち、ネットワークはよく似ている情報はマップ上でより近い位置に、似ていない情報はより遠い位置に配置するといった学習を行う(図3)。これは生体の大脳皮質上においても、よく似た刺激情報はよく似た位置に情報が蓄えられているという神経生理学上の知見と対応している。

a. 感覚マップ

本研究の目的は、生体に倣った知能システム・モデル、特に人間の両側性大脳半球における両側的な情報処理形態の有効性を確認することである。本研究において用いられたネットワークは左右大脳半球における両側性を考慮したものとなっており、それぞれ左半球(LH)と右半球(RH)に相当する2枚の自己組織化マップを1組のものとして用いている。ただし物体認識の際、その認識対象となる物体の特徴数は複数であるために、2枚1組のネットワークが複数枚用いられる。したがってモデルは最終的に、構造的には全く同じように自己組織化されたマップがLH・RHそれぞれ1枚ずつ(そのペアが特徴数に応じて複数枚)できあがる。これを「感覚マップ」と呼ぶ(図4a)。

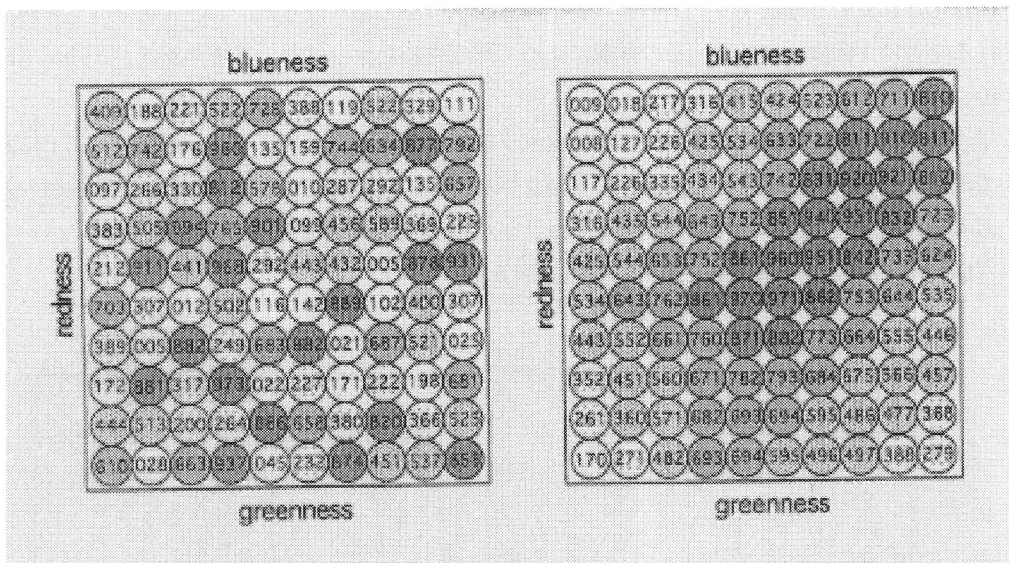


図3 マップ




図4 学習後のマップ

b. 言語マップ

感覚マップが教師なし学習によって自己組織化を終えると、ネットワークは物体認識によって

活性化されている感覚マップ上のユニットに言語ラベルを貼り付ける。この言語ラベルを貼り付ける学習は1回限りであり、その学習によって形成されたマップを「言語マップ」と呼ぶ(図4b)。

学習後の物体認識の際、言語マップは感覚マップ上に刺激が入力されると、感覚マップ上において活性化されたユニットから最も近い言語ラベルの位置を活性化させる。この時、側抑制の効果も考慮に入れるため、その次に近い言語ラベルの位置を抑制するようなメキシカンハット型(DOG)のフィルタを用いて処理を行う(図5)。




図5 言語マップにおけるメキシカンハット型の活性化

c. 両側性の効果

メキシカンハット型の活性化は両半球で起こっているが、「言語優位」な左半球では量的により強く活性化される。この時点においてシステムは、両半球における活性化の小さな量的な差異以外には、非対称的な情報処理メカニズムを持たないことが分かる。しかしながら、この量的な非対称性は、脳梁をシミュレートした他半球に対する抑制的な情報伝達によって、質的な非対称性へと変換される。その結果、左半球では、ロボットがある時点において知覚している物体の特徴に近い1つの言語ラベルが活性化され、右半球では、いくつかの言語ラベルを含んだより広い範囲が活性化される(図6)。このような右半球における「周辺的情報処理」が左半球を助け、認識率における精度の向上を期待することができる。

4.3 Kheperaによる物体認識実験

実験で用いられたネットワークは 20×20 の400ユニットのサイズを持つ。ネットワークに入力する物体の特徴量は、デッドレコニング法によって算出される。デッドレコニング法とは、左右両車輪の回転量の和差から、2次元平面上におけるロボットの位置と方位を測定する方法である。

特徴量は、測定した位置と方位から、Kheperaが物体を時計回りに移動した時における4方向（0度、90度、180度、270度）についての移動距離を用い、0～1の実数値に正規化している。ロボットに認識を行わせる物体は直径4 cm、高さ2 cmの円柱状ブロックを組み合わせて構成した10種類のクラスター（図7）であり、それぞれのクラスターについて100回の学習を行わせ、感覚マップを組織化させた。最後に、100回目の感覚マップ学習に付随する形で、1回だけ言語マップ学習が行われる。具体的には、最後の100回目の学習時において、感覚マップ上で活性化しているユニットと同じ位置の言語マップ上のユニットに対して、言語ラベルを貼り付ける。100回の学習によって感覚マップは十分に組織化しているので、同様の位置における言語マップ上のラベルは、そのクラスターを表象したものであると考えられるだろう。

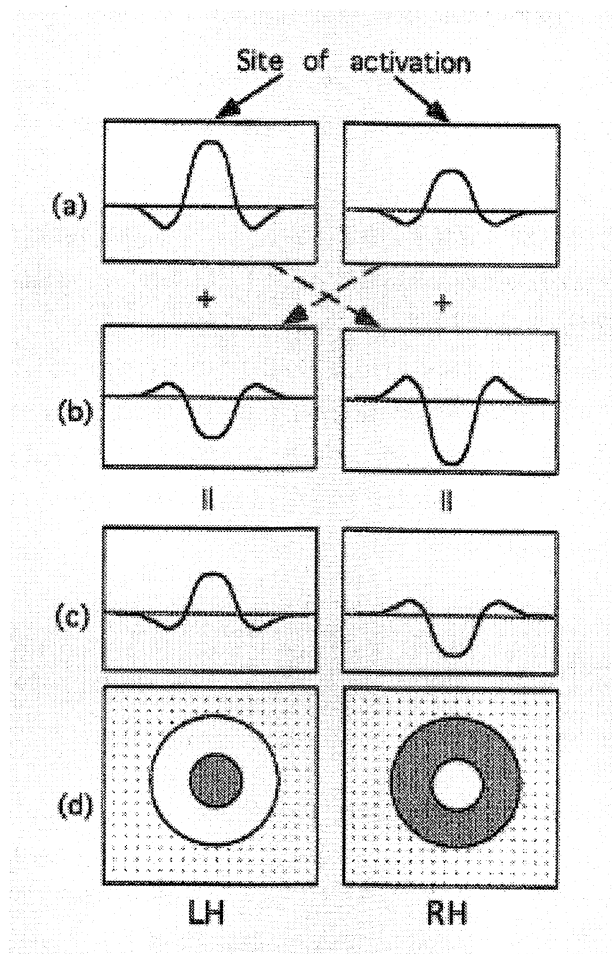


図6 脳梁による抑制効果と半球の活性化状態

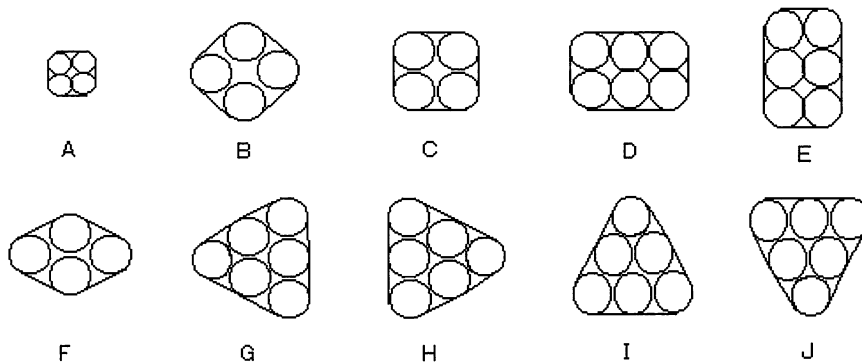


図7 認識実験に用いた10種類のクラスター

次に、各クラスターについて認識実験を行った。各クラスターについては20回の認識を行わせ、その内、正しく認識できた回数をもって、そのクラスターに対する認識率とした。

4.4 実験結果と結論

それぞれのクラスターに対する認識率を表2に示す。両側性の効果を確認するために、脳梁による抑制効果をもたない2枚1組の自己組織化マップと(LL条件)と、抑制効果をもつ両側性自己組織化マップ(LR条件)が比較された。

表2より、両条件ともに完全な認識率を示したD・E以外のクラスターにおいて一貫した両側性の効果が確認できる。比較的認識率が低い値を示したB・F・GのクラスターにおいてもLR条件ではLL条件に比較してわずかな優位性を示している。その他のクラスターについては、認識率においてかなりの差が確認されたといつてよいだろう。両条件の平均値についてt検定を行った結果、有意差が確認された($p < 0.05$)。

表2 それぞれのクラスターにおける認識率

	A	B	C	D	E	F	G	H	I	J	平均
LL	77.5	50	82.5	100	100	57.5	50	57.5	90	75	74
LR	85	60	95	100	100	60	55	100	100	100	85.5

本章では、生体の左右大脳半球と脳梁の機能(両側性メカニズム)に倣ったニューラルネットワーク・モデルが、ロボットの物体認識においても有効であることを示すために、両側性メカニズムを持つモデルとそのようなメカニズムを持たないモデルとの比較実験を行った。その結果、両側性モデルはそうではないモデルに比較してかなりの認識率の差を示し、物体認識における両側性の効果を確認したといえるであろう。脳科学分野では脳梁の抑制性について様々な議論がなされているが、ロボットの物体認識課題において脳梁抑制効果を持つ両側モデルが一貫して優位な結果を示したことは、脳梁における抑制効果を間接的に支持していると考えられる。

5. 複数の自律エージェントによる協調作業シミュレーション

本章では、複数の自律移動ロボットを模したエージェントに、仮想環境上（コンピュータ・シミュレーション）で分散物収集課題を行わせ、より効率のよい課題達成のために各エージェントに協調的な行動を学習させることを試みる^[9]。

5.1 実験目的

本章では、複数の知能システム（エージェント）が互いに相互作用することで、動的で複雑な環境下においてもより高度な適応行動の実現を試みる。各エージェントは、互いに独立したシステム群として適応を目指すのではなく、互いに相互作用しエージェント群全体が1つのシステムとして機能することで、より複雑で柔軟な適応が可能になるものと考えられる^{[10]・[11]}。

実験では、エージェント群が情報的な相互作用を行うことによって、台数効果以上の課題達成における効率化を確認するために、各エージェントが独立に課題遂行を行った場合と、各エージェントが情報をやり取りすることで相互依存的に課題遂行を行った場合の比較を行う。後者の場合、各エージェントは情報のやり取りを行うことで、与えられた課題に対して適応するための行動パターンを学習していく。学習のための強化刺激は実験者が与えるといったようなものではなく、各エージェントは課題達成の成否を、フィードバックされた「強化刺激」として学習を行い、行動パターンを自己組織化する。このようなシステムの自己組織性は、動的で複雑な環境下においても柔軟な適応を導くと考えられる。

5.2 モデリング

本実験はコンピュータ・シミュレーションであるために、知能システム、およびその環境は実環境に即した形で適切にモデル化されなければならない。モデルの世界は、エージェント(Agent)、オブジェクト(Object)、ワールド(World)の主に3つの要素から構成されている。エージェントとは、ワールド内を規則に従いながら行動することができる主体であり、それ以外の構成要素に対して能動的に働きかけることができる。また、エージェントは環境に対して局所的にしか知覚・運動することができない。オブジェクトとは、エージェントに対して誘意性を持つ「目標物」であり、エージェントはオブジェクトを見つけるためにワールド内を探索する。ワールドは、20×20の格子状セルから構成されたエージェントの探索空間と、エージェントにとって特別な意味を持つ1点の局所的な空間（ネスト）から構成されている。

エージェントが課題達成のためにとる主な行動規則は、1) 1単位時間につき、1単位空間移動する。次時点において移動すべき空間は、各エージェントが持つ行動確率マトリクスによって選択する、2) エージェントの周囲1単位空間内にオブジェクトが存在する時は、オブジェクトを収集し、ネストへと持ち帰る、3) エージェントが1回につき持つことができるオブジェクトは1つだけである、というものである。

本実験は、コンピュータ・シミュレーションであるが、エージェントは第3章で解説した

Kheperaをモデルとしている。したがって、エージェントが有する知覚・運動系の局所性は実環境におかれた知能システムをモデル化していることに注意されたい。

5.3 学習

各エージェントは1単位時間あたり、情報のやり取りによって基準点からの「方向」と「移動距離」から、その他のエージェントの存在する「距離（1～10）」と「方向（1～8）」を測定することができ（図8）、それをもとに互いの「位置関係」と「課題達成度」の関係を学習する。

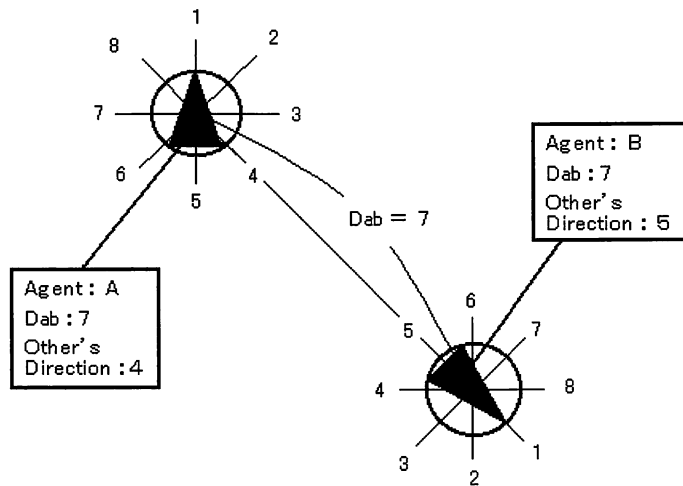


図8 エージェント間の位置関係

換言すれば、各エージェントは効率的な課題達成を行うために、互いに近づきあった方がよいのか、遠ざかった方がよいのかを学習する。各エージェントがある時点において選択した移動行動は、他のエージェントに対する「距離」と「方向」それぞれに分解した形で2次元マトリクス上に記録している（行動記録マトリクス）。

各エージェントは課題達成終了時に、その課題達成の成否をもとに、行動記録マトリクスから得られた前回の行動パターンが良いものであったのか悪いものであったのか判定し、次回の課題達成度に対する行動パターン修正のために、行動記録マトリクスに基づいた強化学習を行う。その結果、各エージェントは方向選択に対する行動確率マトリクスの修正を行う（図9）。

5.4 実験および結果

2台の自律エージェントに分散物（オブジェクト）の収集課題を行わせる。オブジェクトは環境（ワールド）内に2つ、ランダムに配置される。各エージェントはワールド内を彷徨しながらオブジェクトを探索し、発見するとネストへと持ち帰る。2つのオブジェクトをすべて持ち帰っ

た時点で1タスク終了とし、1タスクごとの課題達成時間の長さによってエージェントのパフォーマンス評価を行う。学習条件の場合、学習の機会は1タスクごとに与えられるため、100タスク行うことで学習の効果を確認する。100タスクを1試行として、学習条件、非学習条件ともに20試行ずつ行い、各条件の比較を行った。

課題達成における学習の効果をより詳細に検討するために、ある1試行を例として、各条件(学習・非学習)の課題達成時間の推移グラフと近似曲線(10区間移動平均)を示す(図10)。




図9 強化刺激によって修正された行動確率




図10 学習・非学習条件における課題達成時間の推移

推移グラフから両条件の違いは読み取りにくいですが、近似曲線が示すように非学習条件に比べ、

学習条件は課題遂行に対してよりよいパフォーマンスを示している。またこの例では、平均課題達成時間はそれぞれ122.37単位時間（非学習）、87.63単位時間（学習）であった。

次に各条件における平均課題遂行時間の平均値を求めた結果、非学習条件は113.43単位時間であり、学習条件は97.13単位時間であった。また、分散についてはそれぞれ36.38、49.08という値であった（図11）。各条件における平均値にt検定（両側分布）を行った結果、有意な差が確認された（ $p < 0.01$ ）。これは所与の条件下における課題遂行に対し、学習によるパフォーマンスの向上が得られたことを意味している。




図11 各条件の平均課題達成時間

5.5 実験の結論

本章では、複数のエージェントに互いの情報をやり取りさせることで、各エージェントが環境に対して、より柔軟な適応行動が現れることを示した。実験では、2台のエージェントをそれぞれ独立に機能させた場合と、各エージェントに互いの「位置関係」と「課題達成度」の相関を学習させた場合との比較検討を行った。その結果、学習条件は非学習条件に比べ、遂行すべき課題に対してパフォーマンスの向上が見られ、課題達成時間は平均で約15単位時間短縮され、統計的にも有意な差が見られた。

また、エージェントによって学習された行動パターンを検討した結果、各エージェントは探索空間を分担することで課題構造に対する適応を行っていた。エージェントによる探索空間の分担行動は、あらかじめモデルに組み込まれたものではなく、各エージェントは課題遂行を通じて学習された行動パターンであり、各エージェント群が互いの位置関係情報をもとに自己組織化させたものである。

本実験で検討したような、自己組織性を有した知能システム・モデルは動的な環境下においても柔軟な適応を示す可能性があり、さらに複雑な環境条件下のもとで詳細な検討を行わなければならない。また、今後はコンピュータ上における理想環境のもとでのシミュレーションではなく、実際の自律ロボットを用いることで様々なノイズが混在する現実の環境下においても、その頑健

性を示すかどうか検討しなければならない。

6. まとめ

本研究では、生体の認知メカニズムを理解するにあたり、そのメカニズムを有する知能システム・モデルと環境との相互作用を重要視する新しいアプローチについて解説し、研究に際して重要な実験ツールとなる移動ロボットKheperaについても解説を行った。まず、脳科学的な立場からは、脳梁を介した大脳半球の両側性メカニズムを仮定したモデル構築を行い、知能ロボットにおける物体認識課題に適用しその有効性を示した。また、社会学的な立場からは、ロボットを模した複数の自律エージェントに、互いの位置情報のやり取りを行わせ、協調的な行動パターンを学習させることで、分散物収集課題の効率化が図られることをシミュレーションによって示した。

生体における認知メカニズムをモデル化する際に、そのモデルをロボットにインプリメントし、実環境のもとで試験してみることは、1) モデルの頑健性を示す、2) モデルの工学的な応用可能性を示す、という点において意義深いものであると考えられる。それぞれの点については研究者の見解や立場によって力点の相違があるだろうが、上記のような研究アプローチが重要視されるべきであることには変わりないであろう。

付記

本研究の4章における実験結果は、土井信也氏の修士論文[4]に基づくものです。氏の協力に心より感謝します。

謝辞

本研究は、関西大学国際交流センター「国際交流助成基金による関西大学と協定校間の共同研究助成」（研究課題：人間およびロボットの両側制御と視覚認知機構に関する研究）より助成をうけた。

参考文献

- [1] Pfeifer, R. & Scheier, C.: Understanding Intelligence, The MIT Press, Cambridge(1999).
- [2] Pfeifer, R.: Building "Fungus Eaters": Design principles of autonomous agents, Proc. SAB-96, 3-12(1996).
- [3] <http://www.k-team.com>
- [4] 土居 信也：関西大学大学院総合情報学研究科 平成12年3月期 修士論文（未公開）。
- [5] Cook, N. D. : The brain code: Mechanisms of information transfer and the role of the corpus callosum, Methuen, London(1986).
- [6] Cook, N. D. & Hayashi, T.: Activation of verbal labels on bilateral self-organized maps. Proc, ICONIP'98, vol.3, pp.1474-1477(1998).
- [7] Cook, N. D.: Simulating consciousness in a bilateral neural network: "Nuclear" and "fringe" awareness, Consciousness and Cognition, 8 (1), 62-93(1999).

- [8] Kohonen, T.: *Self-organizing Maps*, New York: Springer, New York (1995).
- [9] 藤澤 隆史 : 関西大学大学院総合情報学研究科 平成13年3月期 修士論文 (未公刊) .
- [10] Mataric, M. J.: *Using communication to reduce locality in distributed multi-agent learning*, *Journal of Experimental and Theoretical Artificial Intelligence*, special issue on Learning in DAI Systems, Gerhard Weiss, ed., 10(3), 357-369(1998).
- [11] Billard, A. & Dautenhahn, K.: *Experiments in learning by imitation - Grounding and use of communication in robotic agents*, *Adaptive Behavior Journal*, Vol. 7:3/4, 1-47 (1999).