

アトラクター状態を用いた実世界における 基本行為の学習について

高田 司郎^{†1} 新出 尚之^{†2} 濱 砂 幸 裕^{†1}
波 部 齊^{†1} 藤 田 恵^{†3}

実世界において環境との相互作用を考慮していない基本行為を実行させると、実行途中にその行為が失敗しているにも関わらず、基本行為を終了するまで実行させて失敗に至ることが多い。そこで我々は、実世界の外乱に頑健な基本行為をアトラクター（安定）状態を用いて学習する方式を提案する。すなわち、まず、基本行為のアトラクター状態をクラス分類できる学習モデルを、環境からの入力情報を用いて構築する。次に、この学習モデルと環境入力情報を用いて、基本行為がアトラクター状態への引き込み状態と分類すると、アトラクター状態に戻る動作を反射的に実行する。提案方式の基本行為を用いたカヌーレーシング事例の実験にてアトラクター状態の維持率が向上していることを示す。

Learning Atomic Actions Using Attractor States in the Real World

SHIRO TAKATA,^{†1} NAOYUKI NIDE,^{†2} YUKIHIRO HAMASUMA,^{†1}
HITOSHI HABE^{†1} and MEGUMI FUJITA^{†2}

When one carry out atomic actions without taking into account interactions with environments in the real world, the actions keep working until the end of the whole actions and prone to fail there, even if one of the actions fails before finishing all of them. We propose a learning method that uses attractor (stable) states to make atomic actions robust against dynamic variations in the real world. In our method, we first learn a model that classifies input data from the environments into some classes corresponding to attractor states. Then, with the learnt model and input data, when an atomic action is classified into a state to fall into an attractor state, an action to get back to the attractor state is performed reflexively. Experimental results, which simulate a canoe racing as a simple example of actions and interactions, show that the proposed method enables an agent to keep itself in attractor states more stably.

1. はじめに

我々は、BDIモデル⁵⁾を用いた実世界における合理的エージェントの学習と意思決定に関する研究課題に取り組んでいる。まず、実世界における強化学習から熟考フェーズに至るBDIモデルの有用性と問題点を考察し⁶⁾、次に、カヌーレーシングのように動的に変化する水流の影響を考慮するような必要がない、つまりエージェントが自ら行為を行わない限り、移動しないような平地（障害物、荷台、荷物などを設置）におけるロボット(MINDSTORMS)の移動をテストベッドとして、実世界の多様性に適応した意思決定に関する

BDIモデルの有用性と問題点を列挙した⁸⁾。特に、このロボットはカメラを持たず赤外線センサーのみを用いた環境認知能力しかなく、現在、立地している位置や向きに関する不完全な情報しか得られないため、移動に関する基本行為の成功・不成功のチェックは不完全である。また、カメラを設置したとしても、意思決定を行うには、実験環境をモデル化したグリッドワールドを仮想世界として人間が構築してロボットに与える必要がある。将来、パターン認識技術が向上し、目の前の個々のオブジェクトの形状や性質を即座に分類し、随時、目標を達成するための環境モデルを記憶から想起するか、またはその場で環境モデルを構築してプランニングできれば、実験環境をモデル化した事前のグリッドワールドは必要なくなる。しかし現時点ではそのような技術は望むべくもなく、移動などのタスクに関しては、事前に環境に関するグリッドワールドを人間が構築して与える必要がある。当実験もこの考えに基づき、「荷物を探して荷台に置く」という目的を

^{†1} 近畿大学
Kinki University

^{†2} 奈良女子大学
Nara Women's University

^{†3} 奈良女子大大学院
Graduate School of Humanities and Sciences, Nara Women's University

実現するためのグリッドワールドを与えて、その仮想世界における状況計算可能な前提条件付きの階層的プランをBDIアーキテクチャに与えることで環境変化に適応した合理的エージェントを構築した。

そこでの移動に関する基本行為の実装は、たとえば、1つのグリッドの中心から正面にあるグリッドの中心まで移動するには、左右のモーターを同時にある一定の時間だけ回転させると事前に決めておく。右への回転も同様に、左のモーターだけある一定の時間だけ回転させると決めておく。つまり基本行為の1サイクルは固定された動作列から構成されている。このようにグリッドワールドを用いた理想的な仮想環境で実行するよう基本行為を実装したが、平地の摩擦係数は一定ではない、電池の電圧変動によるモーター回転数は一定ではないなどの外乱に起因して、これら基本行為が常に成功裏に終了するとは限らないという問題点が浮き彫りとなった。特に、基本行為の成功・不成功は1サイクルが完了した時点でないとチェックできなく、途中の動作中に失敗していてもその失敗は認知されることなく1サイクルが終了するまで基本行為は継続される。

一方、身体を持った我々人間の行為、たとえば「歩行」という行為は、両足・両腕をある一定のパターンで動作させて、それら動作の環境からの反作用として、歩行に伴う「映像」、「音声」、および「風」などを発生させて、それぞれ、「目」、「耳」、および「皮膚」にてセンサすることで、「歩行」という行為の安定状態、つまりアトラクター状態^{*1}を構築している。しかし、爪先が地面の穴に嵌るなど歩行時の外乱が大きすぎると、別のアトラクター状態「倒れる」に移り、爪先で踏ん張ることができる程度の外乱であれば、元のアトラクター状態、つまり歩行に戻ることができる。このような元のアトラクター状態へ戻ることができる状態の領域を「引き込み領域」と呼ぶ。人間の歩行のポイントは、外乱が入った後、元の歩行状態に戻ったり、新しい状態へ引き込まれたりするのは、人間の歩行に関係する形態と環境との相互作用から自然と発現していることである³⁾。

そこで、我々は次のステップとしてカヌーレーシングにテストベッドを戻し、身体性を持つロボットが、実世界の持つ様々な問題点（詳細は2章を参照）を考慮しながら3.1節にて述べる基本行為をアトラクター状態として構築するための基本的なフレームワーク、

*1 力学系において、過渡状態を経た後で定期的に観察される状態を「アトラクター」と呼ぶ。

特に環境の外乱に頑健な基本行為の実装を機械学習を用いて実装する方式を提案する。ポイントとしては、まず、環境の外乱に対するアトラクター状態の維持状態、元のアトラクター状態への引き込み状態、およびアトラクター状態からの離脱状態などの状態に関するクラス分類を行うための学習モデルを、基本行為の動作と環境との相互作用で生じた環境からの入力情報を用いて構築する。次に、この学習モデルと環境入力情報を用いて状態に関するクラス分類を行いながら基本行為を実行する実験と、学習結果を用いない基本行為の実行を行う実験を行う。実験では、学習モデルを用いてクラス分類を行い引き込み状態と認知すると元のアトラクター状態に引き込むような動作を即時に行うことができるため、離脱状態への遷移が減少して基本行為のアトラクター状態の維持率が向上することを示す。

2. 実世界にて生じる問題

本章では、実世界にて生じるさまざまな問題について述べる。

2.1 仮想世界とは異なる問題

心理学者戸田正直が提案した「キノコ食い」のような完全エージェント⁴⁾が身体性を有して、実世界で長い期間生き延びて機能するためには、仮想世界とは異なる以下のような問題が生じる³⁾。

- (1) 情報獲得に時間がかかる。たとえば、隣の部屋にプリンタがあるのかどうか知りたければ、行ってみるか、だれかに聞かか、あるいは、ネットワーク構成図をみなければならない。
 - (2) 極めて限られた情報しか得られない。たとえば、サッカーゲームにおいては自分の視界の範囲の情報しか得られない。
 - (3) 物理デバイスは外乱や故障から逃れられない。
 - (4) 実世界を離散的には記述できない。
 - (5) 実世界のエージェントは常に複数のことを並に行う必要がある。たとえば看護ロボットは、患者の話し相手をしながら、飲み物を運んだり、ベッドに寝かせたり、体温や脈をはかりながら主治医へ連絡するなど、患者に状況や要求に適応して、複数の目的を並行して行う必要がある。
 - (6) 実世界は固有のダイナミクスで常に変化している。
 - (7) 実世界は極めて複雑なダイナミカルシステムであり、その非線形特性と初期値に対する鋭敏性ゆえに、本質的に予測不可能である。
- まとめると、身体性を持ったエージェント、つまり

ロボットは実世界から情報を取り出すためには時間を要し、結果的に得られたものも部分的に観測されたものに過ぎず、また誤差が必ず含まれている。都合よく離散化することはできないし、エージェントは同時に複数のことを行わなければならない。そして実世界はエージェントの行動に反応するだけでなく、それ自身の動特性でもって変化し続ける。

次に、実世界のさまざまな問題を考慮した場合のカヌーレーシング事例の問題点を述べる。ただし、BDIモデルを用いれば、複数のことを並行して行えることを8)にて提示したので、上記の(5)については割愛する。

2.2 情報獲得に時間がかかる

カヌーレーシングを実世界で実行することを考えると、エージェントが環境を観測するには認識時間を要する。

たとえば人間の刺激を受けて反応するまでの実験結果⁷⁾を平均した、視覚刺激反応平均時間と聴覚刺激反応平均時間は、それぞれ194.25msと148.5msである。この観測時間を考慮すると、カヌーが10Km/hのスピードで走っている場合、人間が環境の視覚刺激を受けて漕ぐという行動をするまでには約0.2秒必要となる。この間カヌーは約0.56m進む。実世界におけるエージェントは人間以上に認識時間を必要とすると考えられるが、人間と同じ観測時間で認識可能とすると、グリッド幅を0.5mとした場合、視覚刺激の観測を開始したグリッドの地点とその反応としての反射的行為を開始するグリッドの地点は異なる場合がある。このように観測時間を考慮すると、このカヌーレーシング事例のように環境の物理法則に従って移動しつづけるタスクの場合は、行動を開始する時点の位置情報を正確に得ることができないことが生じる。このため、強化学習にて学習した方策を学習時と異なるグリッドにて実行する可能性が生じる。

さらに、実行環境の外乱やデバイスのデータ誤差までも加味すると、立地する位置情報や向き情報を正確に得ることは難しく、基本行為の実行開始や実行終了のタイミングを計算することは難しい。よって、この誤差を吸収できるような粒度の大きいグリッドを使用することが求められる。ただし強化学習はグリッドからグリッドへの状態遷移を基本行為の単位としてきたので、基本行為の粒度も考慮する必要がある。たとえば、前進中という前進の繰り返しなどとする基本行為も考えられる。

2.3 部分情報しか得られない

カヌーレーシング事例における「流れが速い」「流れ

が遅い」といった情報をどのように得るかを問題とすると、単純に「記号接地問題」にぶつかる。そもそも流れが速いというのは、どうやって判断しているのだろうか。人間だと水流の速度は、波しぶきの高さや音を聞いて判断しているように思われるが、エージェントにそのような判断をさせるのは至難の技であろう。現時点では、どのような測定機器をエージェントに接地すれば良いのかから検討を要す問題である。

2.4 物理デバイスの外乱や故障

物理デバイスのデータ誤差などへの対応は、バイズ推定などの統計的手法が考えられる。ただし実世界の外乱が正規分布などに必ずしも属していると考えて良いものは疑問が残る。ただし本論文の実験では、外乱や故障は、正規分布に属していると仮定している。

2.5 実世界は離散的には記述できない

カヌーレーシング事例では、グリッドモデルを用いて、時間的場所的に離散データとして扱ってきた。つまり時間と場所情報が離散的に完全情報として与えられることを仮定したMDPタスクと捉えてきた。しかし実際には、確率値のみでなく、時間も場所情報も連続実数である。

2.6 固有のダイナミクス

カヌーレーシング事例においては、深刻な問題である。まず、カヌーはエージェントが何も行為を起こさなくても、水の流れに乗って、常に移動する。次に、カヌーを漕いだとしても、オールの向き一つで、カヌーの進む方向やスピードは一定ではない。

もっと深刻な問題として、実世界の状態は、多様な変化を、物理法則に沿って常に起こしている。つまり実世界は、二度と同じ状態とはならないことである。プランの前提条件は、このように常に変化している状態の平均値にしか過ぎない。しかも前提条件は仮想世界では、命題として取り扱っているが、実世界では実数を扱う必要が生じるであろう。

エージェントの取るべき行為も、毎回同じで良いという保証もない。しかも、グリッドモデルだと、船体の向きもゴール地点をいつも向いているとして、行為を決めてきたが、グリッドモデルの特定地点、たとえば川の中央に岩がある場合、岩の手前右側の水流は左から右に流れているのではないだろうか。その保証も神のみぞ知るわけであるが、もし左から右に流れているとすれば、船体も左から右の方向を向くことになるので、取るべき行為は、船体の向きと同じ、もしくは、やや右に切るような行為が良いように思われる。

2.7 予測不可能性

実世界の予測不可能性に関しては、現時点では、ノー

アイデアである。特に、シミュレータを作成するとしても、予測不可能な世界のシミュレータを作成することは不可能である。

3. 基本行為の学習

カヌーレーシングにおける代表的な基本行為であるフォワード・ストロークに関して、アトラクター状態、アトラクター状態のクラス分類、基本行為の実行方式について述べる。

3.1 フォワード・ストロークのアトラクター状態

人間のフォワード・ストロークは、真っ直ぐ前を向き背筋を伸ばして、肩幅と同じ間隔でシャフトを持ち、そのまま体の前に下ろした基本ポーズを取り、下記の一連の動作を繰り返すことで、アトラクター状態が実現されている。

- (1) 右のブレードは水面に直角、左のブレードは水面と平行に持つ。
- (2) そのまま右手を伸ばし、できるだけ遠くの水をキャッチする。
- (3) 右手を強く引きながら左手を強く押して、右のブレードが水から出るまで漕ぐ。
- (4) (左右逆で) 左のブレードが水面に垂直、右のブレードは水面と並行になるように、左手を引いて右手を伸ばす。
- (5) 左手を伸ばすのと同時に右手首を手前にひねり、左のブレードを水面に対して直角にする。
- (6) そのまま左手を伸ばし、できるだけ遠くの水をキャッチする。
- (7) 左を強く引きながら右手を強く押して、左のブレードが水から出るまで漕ぐ。
- (8) 再び右手首を元に戻す。

3.2 アトラクター状態のクラス分類

人間と同じ形態と可動性を持った両手のロボットを制作して、上記のフォワード・ストロークのアトラクター状態を忠実に実現することが理想ではあるが、本論文では、上記のフォワード・ストロークの動作列の具体的な実装には触れずこの基本行為のアトラクター状態が実現できたと仮定する。

まず、各基本行為のアトラクター状態は、下記の何れかの状態であると仮定する。

- (1) 維持状態：基本行為を構成する動作列が安定的に実行されている状態
- (2) 引き込み状態：基本行為を構成する動作列が何らかの外乱で正常に実行できなくなりかけているが、まだ元の安定的な状態に戻れる状態。この状態から、元のアトラクター状態へ戻る為の動作は個々

の基本行為で実装されていると仮定する。

- (3) 離脱状態：基本行為を構成する動作列が何らかの外乱で正常に実行できなくなり、もう元の安定的な状態には戻れなく、別のアトラクター状態に移ってしまった状態。

また、引き込み状態などは、複数の状態があると仮定する。たとえば、簡単な動作にてアトラクター状態に戻れるクラスや、かなり右往左往しないと戻れないクラスなどが仮定されていても良い。

上記のクラス分類を設定した後、各基本行為を対象にして、上記の状態にクラス分類できるセンサ情報が得られると仮定して、多次元のセンサ情報を入力として、アトラクター状態のクラス分類ができる学習モデルを構築する。

3.3 基本行為の実行方式

上記で得られた学習モデルとセンサ情報を用いて、現在実行中の基本行為のアトラクター状態のクラス分類を行い、その分類によって、下記の動作を行う。

- (1) 維持状態：そのまま基本行為を構成する動作列の実行を継続する。
- (2) 引き込み状態：元のアトラクター状態へ戻る為の動作を実行する。
- (3) 離脱状態：基本行為の実行を中断して、実行が失敗したことをマークする。たとえば、BDIアーキテクチャーの実行サイクルが終わった時点で、失敗したことを認識して、熟考フェーズに移る。

これらの方法を用いて、環境の外乱に対して、頑強な基本行為が実装できることを、次章の実験で示す。

4. 実験

センサによる感覚を用いた機械学習によってアトラクタ状態を得る過程の模擬として、カヌーレーシングを意識した次のような問題設定のもとでの実験を行った。

4.1 問題設定

図1左のように、川面上を走行しているカヌーがある。ここでは、反時計回りの角度を正の度数で表す。同図は川の方向に対し、 $+20^\circ$ の方向を向いているカヌーの例である。

カヌーは、向きを図る複数のセンサ(ここでは3つとする)を積んでおり、それらは常に、おおむね川の方向を向いているが、外乱(局所的な乱流など)の影響を受け、標準偏差 10° のずれを生じる。例えばカヌーが川に対し $+20^\circ$ の方向を向いている場合、各センサのカヌーに対する角度はそれぞれ、平均 -20° 、標準偏差 10° の分布をする。ここで目指すのは、センサの

方向情報をもとに、カヌーの川に対する方向が傾きすぎて姿勢を失ってしまわないような安定状態を獲得することである。

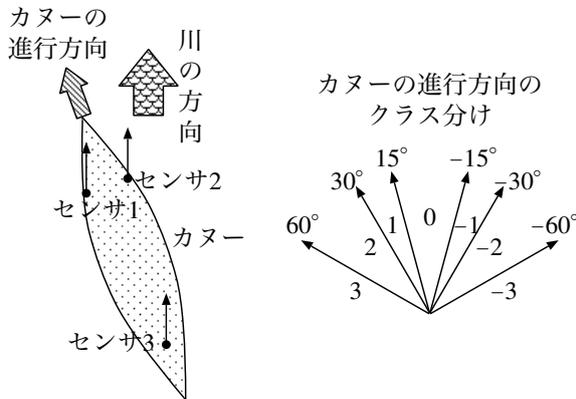


図1 川面上のカヌーの角度予測による安定状態獲得問題

4.2 データ収集と学習

まず、カヌーの川に対する実際の角度を図1右のようにクラス分けし、カヌーの向きをさまざまに変えながら、向きのクラスと3つのセンサの情報のデータを、計1万件作成した。カヌーの向きは、最初の1回は平均0°、標準偏差5°の正規分布により生成し、2回目以降は、川の流れに刻々と影響を受けて走るカヌーからデータを取るという想定のもと、前回の角度を平均として、標準偏差15°の正規分布で生成した。ただし、あまり角度が中央(0°)から外れたところに偏らないようにするため、前回の角度が-60°~60°の範囲にない場合は、前回より5°ほど中央寄りの角度を平均とした分布(標準偏差は同じ)を用いた。また、新たな角度が-90°~90°の範囲をはみ出る場合は、-90°または90°に強制した。その結果データ件数は、向きのクラスが-3から3までの順に、各1248件、1965件、1022件、1940件、922件、1810件、1093件となった。こうして生成したデータを、センサ情報の角度-90°~90°を-1~1にスケールした上で、サポートベクタマシンによる学習ツールとして知られるLIBSVM²⁾を用いて、センサ情報から向きのクラスを分類する学習を行った(パラメータやカーネル関数などの選択は全てデフォルトによった)。

4.3 学習結果を用いた推定による安定状態の実現

次に、新たにカヌーの初期方向を平均0°、標準偏差5°の正規分布で決め、センサ情報から学習結果による分類で向きのクラスを推定した上で、その推定結果のクラスに応じて表1のように漕ぐことを、1万回続け

る実験を行った。新たなカヌーの方向は、漕ぎ方に応じて、表1に与えられる向きの変化量を元の方向に加えた角度を平均とし、標準偏差15°の正規分布で決まる(例えば、実際のカヌーの方向が25°であり、しかしクラスを2と推定していた場合、右へ強く漕ぐことによって、カヌーの新たな向きは平均5°(=25°-20°)、標準偏差15°の正規分布で決まる)。ただし、向きのクラスの推定が-3または3の場合は、「傾きすぎて姿勢の制御を失った」と判断する(これをここではtiltと呼ぶ)という設定で、向きを再び平均0°、標準偏差5°の正規分布で決まる角度にリセットした上で続行する(従って、表1にはクラス-3と3の項目はない)。そして、1万回の試行において、tiltが何回生じるかを調べた。

表1 カヌーの漕ぎ方と方向変化

カヌーの向きのクラス	漕ぎ方	向きの変化
-2	左へ強く漕ぐ	+20°
-1	左へ漕ぐ	+10°
0	漕がない	0°
1	右へ漕ぐ	-10°
2	右へ強く漕ぐ	-20°

以上の実験を10回繰り返した結果、tiltは1万回中平均16.7回であった。比較として、全く漕がずに同じことを行った結果、tiltは1万回中平均454.9回であり、学習によって安定して漕ぐ状態を獲得していると言える。ここでのクラス-3と3は3.2節で導入した「離脱状態」、クラス-2,-1,1,2は「引き込み状態」、クラス0は「維持状態」にあたる。漕ぎ手は離脱状態を「失敗」と認識し、また引き込み状態にあれば維持状態に引き込む動作を行うことで、維持状態を保とうとする働きを持つ。

ここでは前方向に安定して漕ぐ状態を獲得したが、他の基本行為のアトラクタ状態についても同様に獲得できることが期待されよう。

5. 考察

以上、実世界における合理的エージェントのアトラクタ状態を用いた基本行為の学習・実装方式を提案した。また、提案方式の基本行為を用いたカヌーレーシング事例の実験にてアトラクタ状態の維持率が向上していることを示した。そこで、本提案手法を用いれば、実世界にて生じる「環境(水流)の外乱や物理デバイスの外乱や故障」に対して、頑健な基本行為を構築できていると結論できる。ただし実験では、これら外乱やノイズがある一つの正規分布であることを条

件としている。水流などを考慮するには、少なくとも混合分布まで拡張して実験する必要がある。今後の課題である。

また、実世界の問題は実世界で解くべきではある。つまり訓練データは実世界にて実際に実行させて得るべきである。しかし、いきなり実機のロボットを用いて実験を行うには、まだまだ技術的、方法論的に敷居が高いように思われる。そこで、今後は、連続量が扱え、特に物理法則を忠実にシミュレーションできるシミュレータを構築することが、急務の課題である。また、カヤックの形態を考慮した水の流れとの相互作用、つまり流体力学までも考慮すべきがどうかもシミュレータ構築時には大きな問題である。カヤックと水流との相互作用を実現するだけでも、かなり難易度の高い問題と思われるからである。

5.1 サブサンクションアーキテクチャとの比較

センサと振る舞いモジュールの階層構造からなるロボットアーキテクチャとしては、Brooksのサブサンクションアーキテクチャ¹⁾がある。これは、複数の目標を達成するために、多数のセンサに反応し、頑健かつ漸進的に拡張可能なロボットを容易に設計できる方法論であり、以下の特徴を持つ。

- (1) タスクを階層的なレイヤに分け、下位のレイヤが構築されれば、それを変更することなく、上位のレイヤを構築できる。
- (2) 内部処理をほとんど必要としないような単純なセンサとモーターの結合によって、環境と実時間での相互作用ができる。
- (3) 知能は中央集権化されたものではなく、複数の緩やかに結合されたプロセスから知的振る舞いが創発されると考える。

サブサンクションアーキテクチャが実世界にて頑健であるのは、(2)のセンサとモーターの結合に基づいて実時間で環境と相互作用することに起因している。ただし、センサ入力に対する簡単な内部処理モジュールを固定的に人間が準備する必要があり、これによってセンサとモーターは直接に結合される。これに対し、我々の提案では、センサとモーター（動作）を間接的に結合している。つまり、センサ入力を用いて基本行為のアトラクター状態をクラス分類した後、分類されたクラスに用意された動作を実行する方式である。この方式の利点としては、センサから得た情報が、環境状態のラベルとして使用できる可能性がある点が挙げられる。つまり「記号接地問題」を扱える可能性があることである。たとえば、「前進中」とは、アトラクター状態の維持状態がクラス分類された場合である。

記号接地問題は、BDIにおけるプランの前提条件の判定に必要であり、実世界のセンサ情報からボトムアップ的にパターン認識を用いてラベル付けしていくことで、この問題を扱えるようになるのではないかと期待している。今後の課題である。

6. おわりに

身体性を持つ合理的エージェントが、実世界の持つ様々な問題点、特に実世界の外乱やセンサのデータ誤差に対して頑健な基本行為の実装を機械学習を用いて実装する方式を提案した。すなわち、まず環境の外乱に対するアトラクター状態の維持状態、元のアトラクター状態への引き込み状態、およびアトラクター状態からの離脱状態などの状態に関するクラス分類を行うための学習モデルを、基本行為の動作と環境との相互作用で生じた環境からの入力情報を用いて構築する。次に、この学習モデルと環境入力情報を用いて状態に関するクラス分類を行い引き込み状態と認知すると元のアトラクター状態に引き込むような動作を即時に行う方式である。当方式を用いれば、実世界における基本行為のアトラクター状態の維持率の向上、すなわち基本行為の頑健性が向上することを、カヌーレーシング事例の実験で示した。本論文が、実世界における合理的エージェント、つまり知能ロボットの議論の一助となれば幸いである。

参考文献

- 1) Brooks, R.A.: A Robust Layered Control System for a Mobile Robot, *IEEE Journal of Robotics and Automation*, Vol.RA-2, No.1, pp.14-23 (1986).
- 2) Chang, C.-C. and Lin, C.-J.: LIBSVM: A library for support vector machines, *ACM Transactions on Intelligent Systems and Technology*, Vol.2, pp.27:1-27:27 (2011).
- 3) Pfeifer, R. and Bongard, J.C.: *How the Body Shapes the Way We Think*, The MIT Press (2006).
- 4) Toda, M.: *Man, robot, and society: models and speculations*, M. Nijhoff Pub. (1982).
- 5) Wooldridge, M.: *Reasoning about Rational Agents*, The MIT Press (2000).
- 6) 高田司郎, 新出尚之: 実世界における強化学習から熟考まで, *Proc. of JAWS2011* (2011). 84takata.pdf.
- 7) 勝浦哲夫, 栃原 裕, 佐藤陽彦, 横山真太郎 (編): 人間工学基準数値式便覧, 技報堂出版 (1992).
- 8) 藤田恵, 片山寛子, 新出尚之, 高田司郎: 実世界の多様性に適応した BDI ロボットについて, *情報処理学会論文誌 数理モデル化と応用*, Vol.5, No.1, pp.50-64 (2012).