

運動イメージに基づく実ロボットの運動生成法

Method for generating Real Robot Motion based on Motor Imagery

荻野 直樹 (慶大院) 正 前野 隆司 (慶大)

Naoki OGINO, Keio University, 3-14-1, Hiyoshi, Kohoku-ku, Yokohama
Takashi MAENO, Keio University, 3-14-1, Hiyoshi, Kohoku-ku, Yokohama

A method for generating robot motion during an autonomous behavior based on motor imagery of humans proposed in our previous paper is applied for a real robot. The procedure of the method is as follows: First, a robot controller obtains input and output values by moving randomly in real environment. Then weights of a neural network representing the interaction between the robot and the real environment is learned by a supervised learning method and back propagation method. Secondly, the robot trains a motion generator for realizing a task by genetic algorithm (GA) in simulation using the model. The proposed method is applied for learning the motion of a mobile robot having a two DOF arm. As a result, the motion pattern which is able to be used in real environment is generated. It is confirmed that the proposed method is effective for generating the autonomous motion of a robot.

Key Words: Motion learning, Locomotion Robot, Neural Network, Genetic Algorithm, Motor Imagery

1. 緒言

ロボットの運動生成問題に対し、強化学習や進化的計算を用いて環境に適した運動パターンを生成する研究が多く行われている。これらの研究における運動パターンの生成方法は主に二つある。一つは、実環境における実際のロボットの試行により学習を行い、生成する方法である。もう一つは、ロボットと環境の相互作用を表すモデルを用いたシミュレーションにおける試行により学習を行い、生成する方法である。前者においては、実環境において直接適用できる運動パターンが生成される。しかし、最終的な運動パターンを生成するまでに非常に多くの試行が必要であるため、ロボットの機械的負担が大きくなる。後者においては、ロボットの機械的負担が無いことに加え、同じ回数での試行を行った場合、前者より短時間で学習が可能である。しかし、シミュレーションに用いるモデルと実環境の誤差が大きい場合、得られた運動パターンを実環境において適用することは困難である。これより、多くの研究において、最初にシミュレーションを行い、その結果を初期状態として実環境において再度学習を行う方法が採用されている⁽¹⁾。しかし、シミュレーションを用いた場合、環境が変わるごとにモデルを変更する必要性が生じる。モデルの変更には人の介入が必要であるため、ロボットによる自律的な運動パターンの生成は不可能となる。

このため、筆者らはロボットの自律的な運動パターン生成を可能とする運動生成法を提案した⁽²⁾。これは、ヒトの脳内における運動のシミュレーションと考えられる運動イメージに基づき構築された運動生成法である。前報においては自律的な運動生成に対する有効性をシミュレーションにより示した。本報においては、提案した運動生成法を実環境下のロボットに適用することにより実ロボットの運動生成に対する有効性を示す。

2. 運動イメージに基づく運動生成法

運動イメージとは、実際の運動から獲得した身体と環境の相互作用を表すモデルによる脳内における運動のシミュレーションである。この運動イメージに基づき、前報⁽²⁾において提案した運動生成法の手順を Fig. 1 に示す。

最初に、Fig. 1(a)のように、実環境における運動によりロボットと実環境の相互作用を表す力学モデルを獲得する。これをモデル獲得過程とする。

次に、Fig. 1(b)のように、獲得したモデルを用いた、運動イメージに相当するシミュレーションにより、環境に適した運動パターンを生成する運動生成器を獲得する。これを運動イメージ過程とよぶ。実環境における運動から獲得したモデルにより、シミュレーションにおいて実環境下の運動を表現することが可能である。さらに、実環境下のロボットへ直接適用することが可能な運動生成器を獲得できると考えられる。

最後に、Fig. 1(c)のように、獲得した運動生成器を実環境下のロボットに適用する。これを運動実行過程とよぶ。

3. 運動生成法の実ロボットへの適用

3.1 ロボットの形態とタスク

前報においてシミュレーションに用いた、モデル化されたロボットに基づき、Fig. 2 に示すような実ロボットを製作した。ロボットは 2 自由度のアームとそれを搭載する台車により構成されている。また、アームのいかなる動きに対しても台車を持ち上げることがないようにするため、アームの動きに対応してベースが上下に動く機構を有している。

ロボットに課すタスクは、平面上において、一定時間における移動距離を可能な限り大きくすることとした。ロボットが移動する方法はアームで地面を蹴ることのみであるものの、地面を蹴る運動パターンは非常に多く存在する。これらの運動パターンからタスクを実現する運動パターンを生成することにより、自律的な運動パターン生成に対する本運動生成法の有効性が確認できる。また、今回用いたロボットは、多足歩行ロボットの 1 脚を 2 自由度で搭載したロボットと考えられる。これより、一般的な多足歩行ロボットに対し、本運動生成法を適用することの可能性を示唆できる。

3.2 モデル獲得過程におけるモデルの獲得

モデル獲得過程において獲得するモデルはロボットと環境の相互作用を表す。アーム先端と地面が接触した場合、非線形性が大きいいため、数理モデルによるモデルの表現は困難である。一方、非接触時における非線形性は小さいため、実際の運動と数理モデルを用いたシミュレーションの結果がほぼ同一になると考えられる。また、ロボットの構造は既知であるとともに、不変である。これより、アームの運動のみを表す数理モデルは容易に導出できる。以上より、運動イメージ過程の非接触時のモデルは数理モデルを用いることとした。

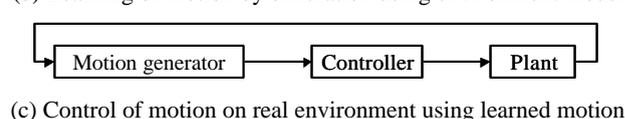
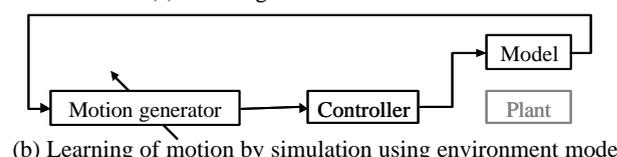
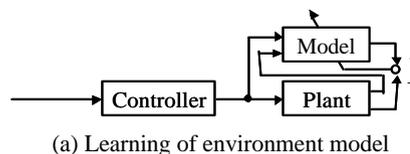


Fig. 1 Procedure of learning model and learning motion

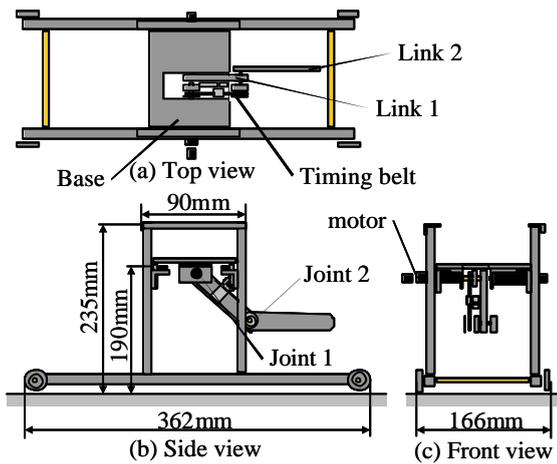


Fig. 2 Robot having two DOF arm

えで、モデル獲得過程においては接触時のモデルのみを獲得することとした。

接触時の非線形性を表現するため、ニューラルネットワーク(NN)によりモデルを表すこととした。これを状態推定 NN とよぶ。状態推定 NN の構造は階層型 NN とした。また、学習には誤差逆伝播法を用いた。入力は Joint 1・2 の角度(角度 1・2)、Joint 1・2 の角速度(角速度 1・2)、台車速度、Joint 1・2 に加えられるモータのトルク(トルク 1・2)とし、出力は Joint 1・2 の角加速度(角加速度 1・2)、台車加速度とした。これらの加速度を現在の状態に加算することにより次の状態が算出される。また、教師データは最初にランダムな運動をさせることにより取得した。

目標角度の変化に対する、学習した状態推定 NN により求められた角度 1・2 の変化と実際の角度 1・2 の変化を比較した結果、どちらも大きな誤差を生じることなく目標角度に追従していた。一方、台車位置の変化を比較した場合、誤差は比較的大きいものの、傾向は一致していた。よって、タスクに対する生成された運動パターンの評価は可能であると考えられる。これより、状態推定 NN は十分に学習されたといえる。

運動イメージ過程においては、状態推定 NN と数理モデルを切り替えるために接触・非接触の判定を必要とする。これより、接触・非接触を判定する階層型 NN をモデル獲得過程において獲得することとした。これを接触判定 NN とする。入力は角度 1・2 とし、出力は接触・非接触の状態とした。具体的には、接触状態を 1、非接触状態を 0 として出力値とした。学習には、状態推定 NN の教師データと同時に取得した教師データによる誤差逆伝播法を用いた。接触判定 NN は、実際に接触した際の関節角度を入力した場合、接触状態を示したため、十分に学習されたといえる。

3.3 運動イメージ過程における運動生成器の獲得

運動パターンは非線形関数として表現されるため、運動生成器に NN を用いることとした。これを運動生成 NN とよぶ。運動生成 NN の構造は階層型 NN とした。また、Joint 1・2 それぞれに対し、運動生成 NN を設けた。入力は Joint 1・2 の現在の目標角度とし、出力は次の目標角度とした。つまり、出力値を制御器への指令値、かつ運動生成 NN への次の入力値として用いることとした。一定時間ごとに Joint 1・2 の目標角度を出力することにより運動パターンが生成される。

獲得した状態推定 NN と接触判定 NN によるシミュレーションである運動イメージ過程により運動生成 NN の学習を行った。運動パターンの自律的な生成を運動イメージ過程の目標とするため、運動生成 NN に対する教師データを予め取得することは不可能である。これより、結合係数を遺伝子型と

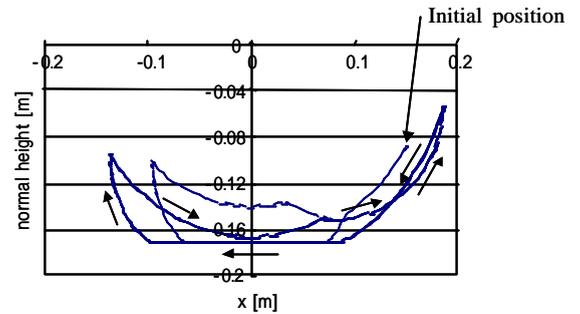


Fig. 3 Motion at the tip of arm

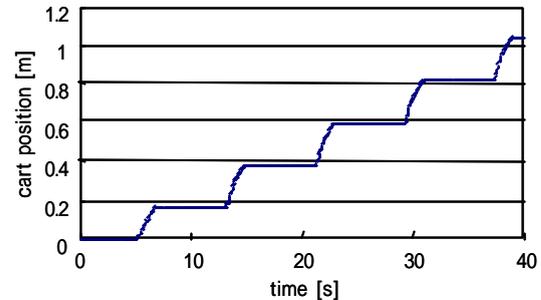


Fig. 4 Change of cart position

した遺伝的アルゴリズム(GA)により運動生成 NN の結合係数を決定した。Joint 1・2 それぞれの運動生成 NN が運動パターンを生成することにより一つの運動パターンが生成される。よって、タスクの実現に適した、全体としての運動パターンを探索できると考え、各運動生成 NN の結合係数を一つの染色体上に表現することとした。選択にはルーレット方式とエリート保存戦略を用いた。エリートは各世代において一つ保存した。交叉には実数値 GA の交叉方法である BLX- を用いることとし、交叉率を一組の親個体に対し 0.5 とした。また、突然変異には交叉をしていない個体の遺伝子に正規分布乱数を加算する方法を用いることとし、突然変異率を各遺伝子に対し 0.5 とした。適合度は 20 秒間のシミュレーションにおいて進んだ距離とした。適合度が大きいほどタスクを実現していることとなる。個体数 50、最終世代数 100 の計算において、最終世代で得られた最良個体の運動生成 NN を Fig. 2 のロボットに適用した。生成されたアーム先端の運動パターンを Fig. 3 に示す。また、台車位置の変化を Fig. 4 に示す。

Fig. 3 より、一定のサイクルをもつ運動パターンを生成したといえる。また、Fig. 4 より、アーム先端と地面の接触時には前進のみしており、後退してしまう無駄な運動パターンを生成していないことがわかる。得られた結果から、タスクを実現する、実環境に適用可能な運動生成 NN が獲得されたといえる。以上より、本運動生成法が実ロボットの自律的な運動パターン生成に対し有効である可能性を示した。

4. 結言

2 自由度のアームをもつ実ロボットに運動イメージに基づく運動生成法を適用することにより、本手法の有効性を確認した。今後は、平面以外の環境において本手法を適用することにより、本手法の汎用性を示す。また、複数のアームの運動パターンを同時に生成できるように本手法を拡張し、多足歩行ロボットの自律的な運動パターン生成を行う。

参考文献

- (1) 浅田稔, 実環境におけるロボットの学習・進化的手法の適用と課題, 計測と制御, 第 38 巻第 10 号, 650-653(1999)
- (2) 川内野明洋, 前野隆司, 運動イメージを用いた実ロボットの自律的運動学習法, ロボティクス・メカトロニクス講演会 2002 講演論文集, 1P1-A01, (2002)