

物理的な人間—ロボット間インタラクションを利用した 柔軟関節ヒューマノイドロボットの運動学習

池本周平*¹ ベン・アモルヘニ*² 港隆史*³
ユングバーンハード*² 石黒浩*^{1*3}

Motor Learning for Flexible Joint Humanoid Robots using Physical Human-Robot Interaction

Shuhei Ikemoto*¹, Heni Ben Amor*², Takashi Minato*³,
Bernhard Jung*² and Hiroshi Ishiguro*^{1*3}

We propose a human-in-the-loop learning architecture which addresses the question of how learning can be achieved for tightly coupled physical interactions between the learning agent and a human partner. In recent years, the application domains of humanoid robots continue to expand, moving deeper into the realm of everyday life. Thus recent robotic developments are increasingly targeted at domestic environments and assistive tasks, in which human-robot interaction is indispensable. In order for humans and robots to engage in direct physical interaction, we employ a flexible joint humanoid robot driven by pneumatic actuators. This paper presents an example for such human in-the-loop learning scenarios and proposes a computationally efficient learning algorithm for this purpose. The efficiency of this method is evaluated in an experiment, where human care gives help an android robot to stand up.

Key Words: Motor Learning, Flexible Robot, Physical Human-robot Interaction

1. はじめに

人間と同一の環境内で動作し、人間との高い親和性が要求される作業を行うことは、ヒューマノイドロボットによる実現が期待される最も重要なタスクの一つである。そのようなタスクを考える場合、同一環境内の人間と物理的に接触した場合の安全性の確保が非常に重要な課題となる。しかし一方で、人間がロボットの運動に介入する安全性が確保されれば、人間の補助をロボットが利用できる可能性が生まれる。本研究では、ヒューマノイドロボットが人間の物理的補助を利用して運動する物理的な人間—ロボット間インタラクションに注目し、人間の補助を利用してロボットの運動を改善する運動学習手法の提案を目指す。

人間の近くで動作するロボットにおいて、安全性の確保は最も重要な課題の一つであり、従来から多くの研究が行われてきた。そのなかでも接触時の安全性を確保する手法については、台

座に固定されたマニピュレータを対象として、人間との接触を検知する手法 [1] [2] や接触時に関節の機械的インピーダンスを低くする制御手法 [3] [4]、衝突時の危険度を評価する手法 [5] [6] などが提案されている。これらの手法は、制御によりソフトウェア的に安全性を確保する手法であり、定量的・理論的に安全性を評価・保証することができる。また、安全性を確保した上で実現可能な運動の精度にも優れる。しかし、いずれの手法も制御対象の解析的なモデル化を必要とするため、複雑な機構を持つロボットなどの解析的モデル化が困難な問題に対して適用することは難しい。

一方、制御対象の解析的なモデル化の難しさに依らず安全性を向上させる方法として、機械的な柔軟性を持つ部材やアクチュエータでロボットを構成し、ハードウェア的に安全性を確保する方法が挙げられる。しかし、この方法では安全性を定量的・理論的に評価・保証することが困難であり、ロボットの運動性能と安全性を両立することも困難である。

このように、安全性を確保する方法はソフトウェア（制御）による方法とハードウェアによる方法に大別でき、それぞれに利点・欠点が存在する。現在までに歩行や走行、協調作業などの高度な運動を達成することを目的とした ASIMO [7] や HRP-2 [8] などのヒューマノイドロボットが開発されてきた。これらのロボットでは、解析的なモデルに基づいて計画された運動を精緻に実現することを目指しており、外力により変形する部材など

原稿受付 2009年12月20日

*¹大阪大学大学院

*²フライベルグ大学

*³JST ERATO 浅田共創知能システムプロジェクト

*¹Osaka University

*²Technical University Bergakademie Freiberg

*³JST, ERATO, Asada Synergistic Intelligence Project

■ 本論文は提案性で評価されました。

を用いていない。また、少ない容積で多自由度の機構を実現するため、高減速比の減速器を用いており、逆可動性の低い関節で構成されている。ここで、逆可動性とは過大な力が駆動方向と逆に加わったときに逆方向への変位を許容する性能を表す。高減速比の減速器を用いる場合、摩擦トルクの影響が強く現れることで逆可動性が失われることが知られている。逆可動性が低い場合、外力によって関節に過大なトルクが生じるため、安全性を高めるためには関節トルクを高いサンプリング周波数で計測し、関節トルクを一定の範囲内に留める高度な制御が必要になる。また、逆可動性の低さは外力が加わった際にハードウェアの故障が生じる危険を増大させるため、本研究で注目する人間の物理的補助を利用した運動学習において試行を繰り返すことが困難になると考えられる。

一方で近年、ロボットの制御特性を犠牲にして逆可動性の確保や柔軟部材の導入を行うことで、安全性の確保や滑らかで自然な動作の実現を目指した多くのヒューマノイドロボットが開発されている [9]~[12]。これらのロボットは、電気モータに減速器を組み合わせた逆可動性の低い駆動方式ではなく、柔軟な部材や高い圧縮性を有する作動流体によって駆動力を伝達する駆動方式を用いている。そのため、高度な制御に依らずに人間の物理的な接触に対する安全性やハードウェアの耐久性を確保することができる。しかし一般に、これらの駆動方式は従来の電気モータに減速器を組み合わせた駆動方式に比べて駆動系自体が有する動力学の影響が非常に大きい。そのため、動力学の解析的なモデル化に基づいて運動の計画、実現を行う高度な制御手法の適用が困難である。

このように、前述の安全性を確保する二つの方法（ソフトウェアによる方法とハードウェアによる方法）に対応して、ヒューマノイドロボットで用いる駆動系の選択も大まかに二つに分けることができ、それぞれに利点・欠点が存在する。本研究では、人間の補助を利用してロボットの運動を改善する運動学習に注目するため、人間との接触に対する安全性の確保や試行錯誤に耐えるハードウェアの実現は、研究を進める上での前提条件となる。そのため、可能な限り容易にそれらの前提条件を満たすことができるヒューマノイドロボットを用いることが好ましい。

そこで本研究では、柔軟関節を有する空気圧駆動にヒューマノイドロボットを用い、単純な制御によって物理的インタラクションを実現した上で上記の運動学習手法の提案を行う。次章に本研究で用いるヒューマノイドロボット、および注目する物理的インタラクションについて説明する。

2. 柔軟な関節を有する空気圧駆動ヒューマノイドロボット

Fig. 1 に我々の研究グループにおいて開発された空気圧駆動ヒューマノイドロボット CB² [10] を示す。CB² は身長約 130 [cm]、体重約 33 [kg] のヒューマノイドロボットであり、全身に 56 の自由度を有する。全 56 自由度のうち、51 自由度は空気圧アクチュエータによって駆動され、そのうちの指の 6 自由度を除く 45 自由度の変位はポテンシオメータによって計測される。空気圧アクチュエータを用いることにより、外力に対して柔軟に関節角を変化させる関節を実現できるため、容易に安全性を高めることができる。また、機構のすべてが柔軟なシリコンゴム製

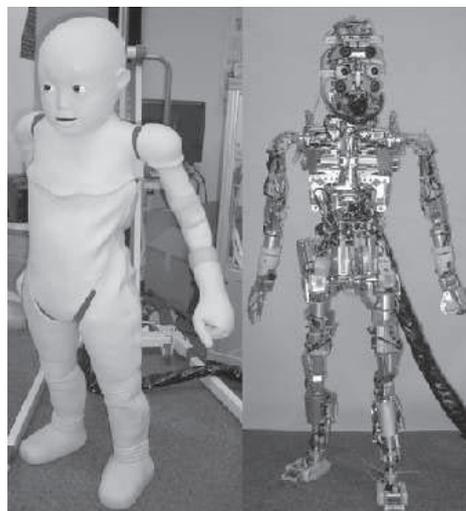


Fig. 1 A flexible joint humanoid robot: CB². All of the joints in the body are actuated by pneumatic actuators. Potentiometers are equipped in the joints without fingers

の皮膚によって被われており、空気圧駆動による柔軟な関節とともに高い安全性を得る上での重要な要素になっている。しかし一方、空気圧駆動系が有する強い非線形性や関節駆動時のシリコンゴム製の皮膚の抵抗など、解析的にモデル化することが非常に困難な要素の影響を強く受ける。そのため、解析的モデルに基づいて CB² の各関節を精緻に制御することは非常に困難である。

関節の制御が精緻に行えないロボットを用いる場合、各時刻で実現すべき関節角などで詳細に運動を記述する運動表現を用いる利点に乏しい。よって、CB² ではある状態を精緻に実現することを前提としない運動表現を用いることが望ましいと考えられる。そこで本稿では、CB² の運動を表現する方法として柿谷らによって提案された仮想目標切り替えパターン [13] を拡張した仮想目標切り替えルール [14] を用いる。仮想目標切り替えパターンとは、フィードバック制御器に対して与える目標値とその目標値を維持する時間で運動を表現する方法であり、仮想目標切り替えルールは仮想目標切り替えパターンにおける目標値の維持時間をロボットの状態の関数とした運動表現の方法である。我々の研究グループではすでに、人間が CB² を引き起こす物理的インタラクションを仮想目標切り替えルールによって実現している。また、人間とロボット双方の運動を解析することで、目標値の維持時間が運動の成否に重要な役割を果たすことを示した [14]。

この研究で得られた結果を利用できることから、本研究でも引き続き人間が CB² を引き起こす物理的インタラクション「引き起こしインタラクション」に注目し、運動学習によってロボットの運動を改善する問題を扱う。試行錯誤によって得られた経験的な知識に基づいて物理的インタラクションを実現し、学習における利用方法に注目する本研究に対し、解析的な動力学のモデル化とそれに基づく制御系の構築を行う研究もある。小菅らは、上肢を有する車輪移動型ロボットを用い、人間から加わる力に対してロボットが移動の軌跡を適応的に変化させる手法

によって人間—ロボット間の社交ダンスを実現した [15]. この研究のアプローチは制御工学に基づいており、物理的インタラクションを解析的に扱う上で非常に重要であると考えられる. しかし, CB^2 のような多自由度ヒューマノイドロボットの動力学的解析的なモデル化は非常に困難であり, 人間の力が加わった際にロボットの関節が各時刻で採るべき状態をあらかじめ決定することも困難になる. 本研究では, 理論的に制御系を構築することよりもむしろ, 物理的インタラクションが実現されたあとに可能となる運動学習の枠組みに注目しているため, 経験的知識によって物理的インタラクションを実現することが容易と考えられる CB^2 を用いて研究を行う.

人間がヒューマノイドロボットに触れて姿勢を変化させることでロボットの運動学習を容易にする試みは, 以前から注目されている学習手法である [16] [17]. しかし, これらの提案手法では, 外力に対して完全に受動的に振る舞うロボットの関節を人間が動かすという単純なやり取りを前提としており, 本研究で注目する物理的インタラクションを利用する (人間の補助を利用する) 運動学習とは大きく異なる. そのため, 本研究における「物理的インタラクションを利用する運動学習」という着目点には新規性があると考えられる. そこで本研究では, 人間がロボットの運動を上手く補助するという環境を利用してロボットの運動学習を行う枠組みを Human-in-the-Loop Learning と呼ぶ.

本稿では, 人間と同一の環境でタスクを行うヒューマノイドロボットにおいて可能になると考えられる運動学習として Human-in-the-Loop Learning を提案する, そして, 人間が CB^2 を引き起こすインタラクションに Human-in-the-Loop Learning を用いることでロボットの運動を改善できることを示す.

3. 仮想目標切り替えルールによる物理的インタラクションの実現

前述のとおり, CB^2 (Fig. 1) は空気圧駆動系が強い非線形性を有する点およびシリコンゴム製の皮膚が関節駆動時の抵抗になる点によって精緻に制御することが非常に困難である. そのため, CB^2 は ASIMO や HRP-2 などのヒューマノイドロボットで確立されてきた目標とする運動の計画とその精緻な実現によるモデル規範型の運動制御アプローチに適さない. すなわち, 精緻に実現することを前提とする運動の表現方法を用いることが困難である点が CB^2 の運動制御における問題点と言える.

柿谷らは, ロボットの運動を表現する方法として仮想目標切り替えパターンを提案し, サーボモータで駆動されるロボットを用いて脚の振りを利用して動的に起き上がる Roll-and-Rise 動作を学習させた [13]. 仮想目標切り替えパターンとは, ロボットの運動を各関節角の時系列データとして表現するのではなく, 目標姿勢に向けて制御する制御器に対する N 個の目標姿勢 \mathbf{x}_n^* と, 制御器に各目標姿勢を与えてからその目標姿勢を維持する時間 T_n によって運動を記述する方法である. この運動表現で最も特徴的な点は, 状態が目標姿勢に収束する前に次の目標姿勢に切り替えることを許す点である. 前述の通り, CB^2 は電気モータに減速器を組み合わせて駆動されるロボットに比べて精緻な制御を行うことが難しく, 外力によって関節角度が変化するため, 実現すべきロボットの運動をあらかじめ設計すること

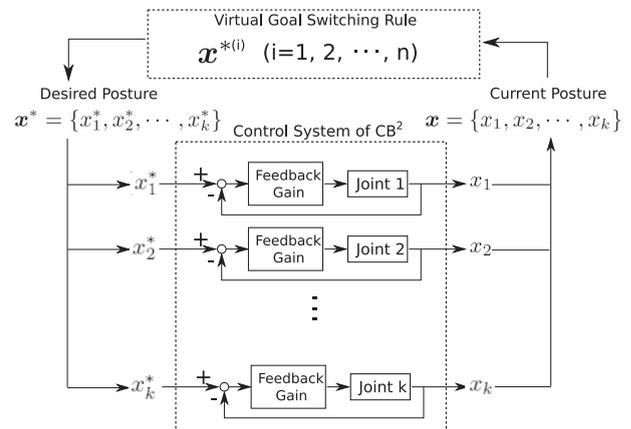


Fig. 2 The control architecture of the CB^2 robot. Where k and n indicate the number of DOFs and desired postures respectively. The desired posture is encoded as a vector \mathbf{x}^* of angular values. Using a PID-controller drive torques are generated in order to attain the posture \mathbf{x} . A virtual goal switching rule changes between a set of different desired postures in order to achieve whole body motions of the robot

が非常に困難である. よって, 仮想目標切り替えパターンは, 各目標姿勢を精緻に実現することを前提としない点において CB^2 に適した運動表現であると考えられる. 仮想目標切り替えパターンを用いて CB^2 で物理的インタラクションを実現する場合, 関節の柔軟性によって各時刻での姿勢 $\mathbf{x}(t)$ は目標姿勢 \mathbf{x}_n^* と外力の影響を受けて決定される. しかし, 各目標姿勢 \mathbf{x}_n^* を維持する時間 T_n は人間が行う物理的な補助に依らず一定である. そこで本研究では, 各目標姿勢を維持する時間 T_n を人間の力の加え方によって変化させるため, 現在の姿勢 $\mathbf{x}(t)$ を用いて次の目標姿勢 \mathbf{x}_{n+1}^* への切り替えを判断する仮想目標切り替えルールによって運動を表現する.

Fig. 2 に CB^2 の制御システムの概略図を示す. **Fig. 2** において, ロボットの各関節角は PD 制御によって制御するものとし, \mathbf{x}^* および \mathbf{x} はそれぞれ現在の目標姿勢および実現している姿勢を表すベクトルである. CB^2 の 51 自由度の空気圧駆動関節のうち, ポテンシオメータによる角度の観測が可能な関節は 45 自由度であるため, \mathbf{x}^* と \mathbf{x} は 45 次元ベクトルとなる. 仮想目標切り替えルールは, 時刻 t において次の目標姿勢 \mathbf{x}_{n+1}^* への切り替えを行うか否かを時刻 t における姿勢 $\mathbf{x}(t)$ を用いて判断する機構である.

引き起こしインタラクションを実現するため, 本研究ではまず下記の手順でフィードバックゲインと各目標姿勢 \mathbf{x}_n^* , 仮想目標切り替えルールを手動で設定した. ここで, 仮想目標切り替えルールは現在の姿勢 $\mathbf{x}(t)$ のうち, 特定の関節 $x_{k(t)}$ がある角度 $x_{k(t)}^*$ を越えたときに切り替える決定論的なルールとして記述することとした. また引き起こしインタラクションを実現するための目標姿勢の数を $N = 3$ 個と決定し, 三つの目標姿勢の切り替えで運動を記述することとした.

- (1) 初期の目標姿勢 \mathbf{x}_1^* の設定
- (2) 外乱のない状態で立位を維持できる最終目標姿勢 \mathbf{x}_3^* とフィードバックゲインの設定

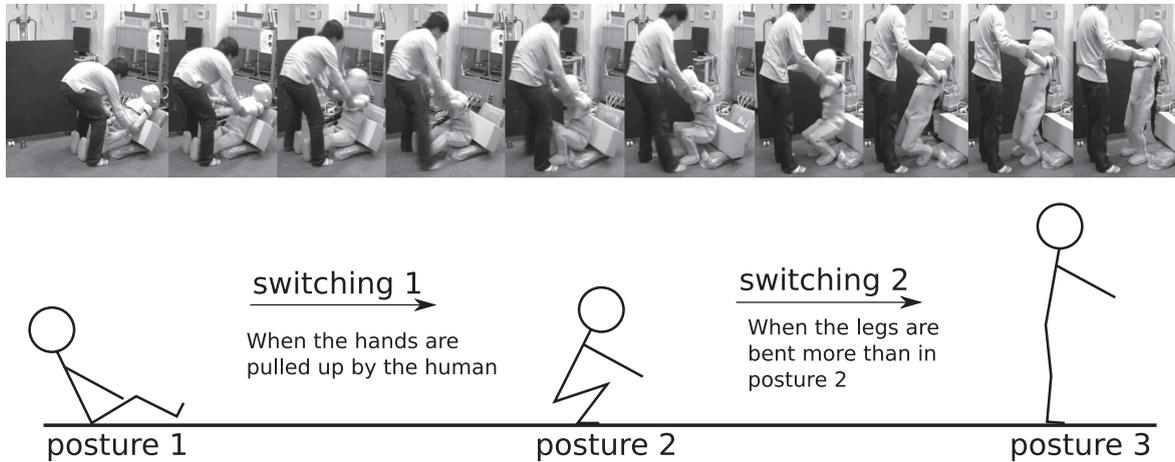


Fig. 3 Sequential snapshots of the rising-up interaction and the three desired postures and the virtual goal switching rule used in the rising-up behavior of the robot. Although the desired posture was drastically switched, the motion of the robot was smoothen by the characteristics of pneumatic actuators

- (3) 初期姿勢から最終姿勢に到達するまでの中間目標姿勢 \boldsymbol{x}_2^* の設定
- (4) 各目標姿勢を適切に切り替えることが可能な仮想目標切り替えルールを設定

Fig. 3 に実現した引き起こしインタラクションの連続写真と手で設定した CB^2 の各目標姿勢 \boldsymbol{x}_n^* と仮想目標切り替えルールの模式図を示す。この図において posture 1, posture 2, posture 3 は、それぞれ初期目標姿勢 \boldsymbol{x}_1^* , 中間目標姿勢 \boldsymbol{x}_2^* , 最終目標姿勢 \boldsymbol{x}_3^* を表す。目標姿勢の切り替えにより離散的に大きく目標姿勢が変化するが、柔軟な関節の応答特性によって滑らかな動作となるため、安全に物理的補助を行うことができる。Fig. 3 に示すとおり、2 度の目標姿勢を切り替える非常に単純な制御のみで CB^2 の引き起こしインタラクションを実現することができた。これは、物理的インタラクションを実現するために柔軟関節ヒューマノイドロボットの利用が非常に有用であることを示す結果と考えられる。

フィードバックゲインと Fig. 3 に示した各目標姿勢、仮想目標切り替えルールを設定するため、本研究では実際に人間が物理的補助を行う環境で CB^2 を動作させて試行錯誤を行った。各時刻で柔軟関節ヒューマノイドロボットが取り得る姿勢は、物理的インタラクション中にロボットに働く様々な外力によって決定される。よって、物理的インタラクションにおけるロボットの運動をあらかじめ計画するためにはロボットに加わる外力のモデル化が必要になる。しかし、人間がロボットに加える補助力をモデル化することは非常に困難であると考えられる。よって、人間-ロボット間の物理的インタラクションにおける柔軟関節ヒューマノイドロボットの運動の生成や改善を行うためには、実際に対象とする物理的インタラクションを通じて行う必要があると考えられる。

我々の研究グループではすでに、この引き起こしインタラクション中の人間とロボット双方の運動を解析することで、仮想目標切り替えルールの改善が引き起こしインタラクションの改善に繋がると考えられることを示した [14]。そこで次章では、引

き起こしインタラクションを通じて仮想目標切り替えルールを改善する運動学習システムの提案を行う。

4. 物理的インタラクションを利用した運動学習システム

Fig. 3 の引き起こしインタラクションの重要な特徴は、人間とロボットの双方が能動的に動作し、それぞれの動作が他方から加わる力によって変化する点にある。この点から仮想目標切り替えルールを変化させた場合の効果を考える場合、仮想目標切り替えルールの変化は目標姿勢の切り替えが生じる時間を変化させ、その際に各関節の角度制御に生じる誤差が変化し、ロボットの関節の駆動トルクが変化する。そして、関節の駆動トルクの変化はロボットの動作を変化させ、それを補助する人間の力の加え方も変化すると考えられる。すなわち、仮想目標切り替えルールの変化は物理的インタラクション全体を変化させることを意味すると考えられる。このことから、仮想目標切り替えルールのみでの改善により物理的インタラクション全体の改善が見込める一方、人間とロボット双方の動作の変化を独立に扱うことができないため、物理的インタラクションの評価やその評価を改善する仮想目標切り替えルールの学習は人間とロボット双方の動作データを用いて行う必要があると考えられる。しかし、人間の動作の計測をロボットが有するセンサを用いて行うことは困難であり、通常はモーションキャプチャシステムなどの大型の機材を必要とする。

本研究では、このように人間とロボット双方の動作データが運動学習に必要と考えられる点に対し、物理的補助を行っている人間の主観的な評価を用いることで解決を試みる。柔軟な関節で構成されるヒューマノイドロボットの物理的インタラクション中の動作は、仮想目標切り替えルールの変更に加えて補助を行う人間の動作の影響を受ける。よって、物理的補助を行っている人間のロボットの動作に対する主観的な評価は、間接的に物理的インタラクション中の自身の動作に対する評価になると考えられる。この評価をもとに運動学習を行うためには、人間が

ロボットのタスク達成に適した補助を行うことを前提とする必要がある。本研究では、このような人間とロボットの双方の行動が互いに他方の行動に影響を与える人間—ロボット間インタラクションにおいて、人間がヒューマノイドロボットのタスク達成のために適した補助を行うことを利用する学習の枠組みを Human-in-the-Loop Learning と呼ぶ。特に、柔軟関節ヒューマノイドロボットと人間の物理的インタラクションでは上記の特徴が強く存在すると考えられるため、Human-in-the-Loop Learning を用いる効果が現れやすいと考えられる。

人間の主観的な評価を利用した最適化は、以前から Interactive Evolutionary Computation [18] と呼ばれる手法などで注目されてきた。これらの手法と本研究との差は、評価対象（物理的インタラクション）において評価者である人間がインタラクションを成立させるための要素として存在しており、インタラクション相手に対して人間が適した補助を行うことを利用する点にある。また、Interactive Evolutionary Computation では乱数などを用いて積極的に解の探索を行うのに対し、Human-in-the-Loop Learning ではロボットの行動の変更に伴って人間の補助力の与え方が変化することを利用して解の探索が行われる点を特徴としている。

次の 4.1 節において、Human-in-the-Loop Learning によって Fig. 3 に示した引き起こしインタラクションを改善するための具体的な運動学習システムについて説明する。

4.1 提案学習手法

Fig. 4 に本研究で提案する学習システムの概略図を示す。この学習システムにおいて、インタラクション相手となる人間は、ロボットとの物理的インタラクションを行う役割に加え、直前のインタラクションにおけるロボットの動作を「良い」、「悪い」の 2 値で評価する役割を持つ。ロボットは、「良い」と評価された n 回のインタラクションのデータを基に、仮想目標切り替えルールを現在のロボットの姿勢を確率変数とする確率モデルによってモデル化する。そして、次回からその更新された確率的な仮想目標切り替えルールを用いて試行を行う。このとき、人間により「良い」と評価された動作データのみから仮想目標切り替えルールを学習することで、新たな仮想目標切り替えルールは以前の仮想目標切り替えルールとは違うものになると考えられる。ロボットの動作の変化に対する人間の動作も適応的に変化すると考えられるため、この方法による仮想目標切り替えルールの更新は物理的インタラクション全体を変化させると考えられる。Fig. 4 の提案手法では、この行程を繰り返すことで物理的インタラクションにおけるロボットの運動を改善する。

本研究では Gaussian Mixture Model (GMM) と EM アルゴリズムを用いて確率モデルの生成を行う。しかし、一般に多次元の確率変数に対して GMM と EM アルゴリズムを用いることは困難である。CB² はポテンショメータを有する 45 自由度の空気圧駆動関節を有するため、各関節角で姿勢を表現するためには 45 次元のベクトルを必要とする。よって、姿勢ベクトルを直接確率変数に用いて GMM と EM アルゴリズムを適用することは非常に困難であると考えられる。そこで、本研究では学習の前に姿勢ベクトルを低次元空間に写像することで確率変数の次元を減少させる。

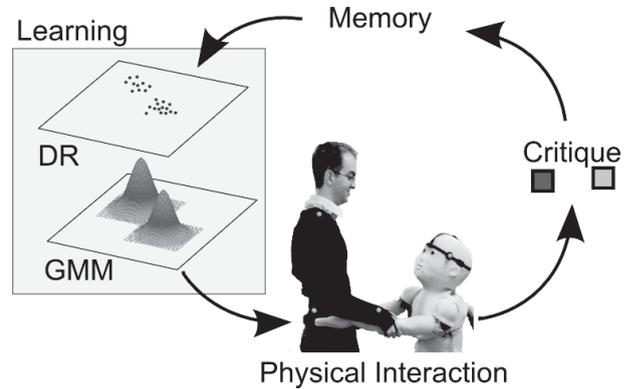


Fig. 4 Overview of the human-in-the loop learning system in physical interaction used in this paper: after physical interaction the human judges whether the interaction was successful or not. This information is stored in the memory and later used for learning

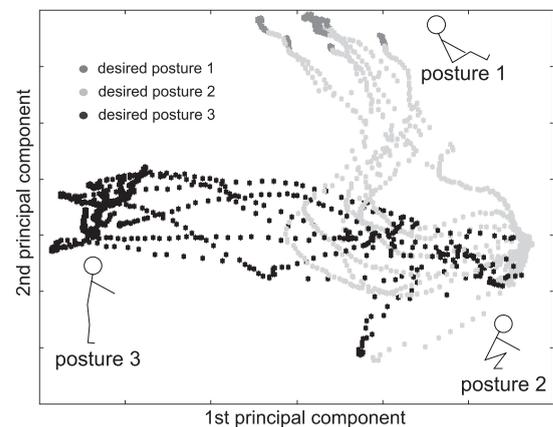


Fig. 5 Interaction data for the standing up task projected into a low-dimensional posture space. Each point corresponds to one posture of the robot

現在までに多くの次元削減手法が提案されているが、本研究ではそのなかで最も良く知られている主成分分析を用いる。「良い」と評価された n 回のインタラクションにおける姿勢の時系列データの分散共分散行列を M とし、 M に対して特異値分解を適用した場合、以下のように三つの行列に分解される。

$$M = UWV^T \quad (1)$$

ここで、 V の各列は行列 M の固有ベクトルを表し、主成分分析における主成分はこのなかから選ばれる。行列 W は対角要素にのみ値（特異値）を有する行列となり、各値は主成分分析における各主成分の寄与率を表す。主成分分析は寄与率の高い数個の固有ベクトルを主成分として選択し、それらを基底とする低次元空間に写像することで高次元のデータの低次元化を行う。

Fig. 5 に Fig. 3 の引き起こしインタラクションを数回行った際に得られたロボットの動作データに対して主成分分析を適用した結果（45 次元の姿勢空間を二次元で表現した結果）を示す。この図において、各点はインタラクション中のロボットの姿勢を表す。また、各点の色はその姿勢における目標姿勢を表す。

本研究では、低次元化された各時刻の姿勢データに対して以

下のラベルを付加し、各ラベルごとに異なる GMM を用いてモデル化する。

- i 番目の目標姿勢切り替えが生じた際にロボットがとっていた姿勢とその近傍の姿勢 (Fig. 5 においてデータ点の色が変化した姿勢の近傍)
- それ以外の姿勢

Fig. 3 に示した引き起こしインタラクションにおいて、ロボットの動作を 2 回の目標姿勢切り替えによって生成したため、GMM によって 1 番目の目標姿勢切り替えが生じる確率 $p_1(x)$ 、2 番目の目標姿勢切り替えが生じる確率 $p_2(x)$ 、目標姿勢切り替えが生じない確率 $p_3(x)$ という三つの確率密度関数をモデル化することになる。

GMM は K 個のガウス関数の重み付き総和によって確率密度関数を近似する。

$$p(x) = \sum_{k=1}^K \pi_k \mathcal{N}(x|\mu_k, \Sigma_k) \quad (2)$$

ここで、 π_k は k 番目のガウス関数の重みを表し、 $\mathcal{N}(x|\mu_k, \Sigma_k)$ は平均 μ_k 、分散 Σ_k のガウス分布を表す。一般に、GMM のパラメータ $\{\mu_k, \Sigma_k, \pi_k\}$ を推定するためには、 k 番目のガウス関数の重み π_k を潜在変数と考えて EM アルゴリズムを適用することで行われる。具体的には、下記の手順によってパラメータ $\{\mu_k, \Sigma_k, \pi_k\}$ の最尤推定値を得る。

- (1) 平均 μ_k 、分散 Σ_k 、混合係数 π_k を初期化する。これらのパラメータは k-means [19] などの単純なクラスタリング手法を用いて初期化されることが多い。
- (2) E ステップ: 現在のパラメータ値を用いて負担率 $\gamma(z_{nk})$ を計算する。

$$\gamma(z_{nk}) = \frac{\pi_k \mathcal{N}(x_n|\mu_k, \Sigma_k)}{\sum_{j=1}^K \pi_j \mathcal{N}(x_n|\mu_j, \Sigma_j)} \quad (3)$$

- (3) M ステップ: 現在の負担率 $\gamma(z_{nk})$ を用いて、パラメータ値を再計算する。

$$\mu_k^{new} = \frac{1}{\alpha_k} \sum_{n=1}^N \gamma(z_{nk}) x_n \quad (4)$$

$$\Sigma_k^{new} = \frac{1}{\alpha_k} \sum_{n=1}^N \gamma(z_{nk}) (x_n - \mu_k^{new})(x_n - \mu_k^{new})^T \quad (5)$$

$$\pi_k^{new} = \frac{\alpha_k}{N} \quad (6)$$

ただし、

$$\alpha_k = \sum_{n=1}^N \gamma(z_{nk}) \quad (7)$$

- (4) パラメータ値と対数尤度の変化から収束を確認する。収束していない場合は手順 2 に戻り、パラメータ更新を継続する。対数尤度は下式によって計算できる。

$$\ln p(X|\mu, \Sigma, \pi) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k \mathcal{N}(x|\mu_k, \Sigma_k) \right\} \quad (8)$$

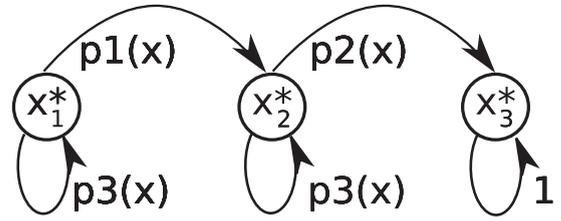


Fig. 6 The virtual goal (desired posture) transition in rising up interaction. x_1^* , x_2^* and x_3^* indicates sitting posture, crouching posture and standing posture respectively

また、用いるガウシアン個数 K について、本研究ではベイズ情報量規準を用いて決定する。ベイズ情報量規準とは、一般的に下式で書け、近似の結果得られる尤度に対して独立変数が多くなりすぎることによる罰則を課して適した独立変数の数を決定する際に用いられる。

$$\text{BIC} = -2 \ln(L) + k \ln(n) \quad (9)$$

ここで、 L は尤度関数、 n は観測データ数、 k は独立変数の数である。

学習のあと、その姿勢切り替えタイミングの確率モデルをロボットの制御に用いる場合には、各時刻で得られる姿勢データに対してリアルタイムで低次元空間への写像を行うことで、学習されたモデルを参照し、目標姿勢の切り替えを行うかどうかを判断する。Fig. 6 に引き起こしインタラクションにおけるロボットの目標姿勢の遷移図を示す。本研究では $p_i(x) (i = 1 \sim 3)$ をそれぞれ別の GMM を用いて表現している。よって、実際にロボットを駆動する際には、 x_1^* から x_2^* への切り替えは $p_1(x)$ と $p_3(x)$ の間での尤度の比較、 x_2^* から x_3^* への切り替えは $p_2(x)$ と $p_3(x)$ の間での尤度の比較を必要とする。具体的には、 $p_1(x)$ 、 $p_2(x)$ 、 $p_3(x)$ を用いて仮想目標切り替えルールを下記の手続きにより定める。

- (1) 現在の目標姿勢が x_1^* であるとき、 $p_1(x) > p_3(x)$ ならば $p_1(x)$ に基づいて x_2^* への遷移を行う。
- (2) 現在の目標姿勢が x_2^* であるとき、 $p_2(x) > p_3(x)$ ならば $p_2(x)$ に基づいて x_3^* への遷移を行う。
- (3) x_1^* において $p_1(x) < p_3(x)$ である場合、あるいは x_2^* において $p_2(x) < p_3(x)$ である場合は、現在の目標姿勢を維持する。
- (4) x_1^* において $p_1(x) > p_3(x)$ が満たされたあとに $p_1(x) < p_3(x)$ となる場合、あるいは x_2^* において $p_2(x) > p_3(x)$ が満たされたあとに $p_2(x) < p_3(x)$ となる場合は、それぞれ x_1^* から x_2^* への遷移、 x_2^* から x_3^* への遷移を直ちにを行う。

本研究では、インタラクション中の転倒の危険を減少させるため、姿勢の切り替えは対応する $p_1(x)$ 、 $p_2(x)$ が $p_3(x)$ よりも大きい場合にのみ、確率的に目標姿勢の切り替えを行う。 $p_3(x)$ が最も大きい場合は、モデルの出力する確率に関係なく現在の目標姿勢の維持を行う。また、 $p_1(x)$ あるいは $p_2(x)$ が選択されたあとに目標姿勢の切り替えを行うことなく $p_3(x)$ が選択された場合は、 $p_1(x)$ あるいは $p_2(x)$ が表す目標姿勢の切り替えをその時点で行う。これは引き起こしインタラクションが動的な

運動であるため、目標姿勢切り替えが生じなかった場合に転倒する可能性があり、この危険を避けるために設けた機能である。

5. 実験および解析結果

Human-in-the-Loop Learning に基づく提案手法の有効性を確認するために、本研究では Fig. 3 に示した引き起こしインタラクションに注目した実験を行った。人間—ロボット間の物理的インタラクションにおいては、人間側の技能の習熟によってもインタラクションの改善が生じると考えられる。そこで本研究では、

●学習あり実験：

- (1) Fig. 3 に示した仮想目標切り替えルールによって、人間に「良い」と評価される n 回のインタラクションのデータが得られるまで試行を繰り返し、そのデータを元に提案手法を適用する。
- (2) 更新された仮想目標切り替えルールによってインタラクションを行い、再び n 回の「良い」と評価されたインタラクションのデータを元に仮想目標切り替えルールを更新する。
- (3) 最終的に得られた仮想目標切り替えルールを評価するため、「良い」と評価される n 回のインタラクションのデータを得るまで試行を繰り返す。

●学習なし実験：

- (1) Fig. 3 に示した仮想目標切り替えルールによって、人間に「良い」と評価される n 回のインタラクションのデータが得られるまで試行を繰り返す。
- (2) 上の手順を計 3 回繰り返す。

の 2 種類の実験を行った。ここでインタラクションのデータとは、CB² の各時刻における姿勢 $\mathbf{x}(t)$ を表す 45 次元ベクトルの時系列データである。双方の実験で得られるデータ数はともに $3n$ 回の「良い」と評価されたインタラクションのデータとなる。被験者はこの引き起こしインタラクションを事前に経験したことのある 5 名の男性被験者とした。

PCA を用いた際の各主成分の貢献率、および GMM を用いたモデル化の際に要するガウシアン個数 K は、各被験者が行う引き起こしインタラクションに強く依存する。本実験では PCA を適用した結果、第 2 主成分までで平均約 55~70% 程度の貢献率が得られ、第 3 主成分の貢献率は 10% 未満であった。そのため、ここでは PCA を用いて CB² の姿勢を二次元ベクトルで表現し、GMM によって目標姿勢切り替えルールの確率モデルを生成した。要したガウシアン個数 K については、 K の最小値を 3 とした結果、 $p_1(x)$ では $K = 3$ 、 $p_2(x)$ では $K = 3$ 、 $p_3(x)$ では $4 \leq K \leq 7$ であった。本稿では、初期の制御プログラム、1 度目の学習によって得られたモデル、2 度目の学習によって得られたモデルのおのおのを使った場合におけるロボットの動作を比較することで提案手法の有効性を示す。

Fig. 7 に学習あり実験における 2 名の被験者による初期のインタラクションと 2 度の学習を終えたあとのインタラクションの連続写真を示す。この図の 1.0 秒および 1.5 秒の写真から、学習後は学習前に比べて早い時間からロボットの腰の高さが増加していることが分かる。また、この図の 1.5 秒の写真から、

学習後は学習前に比べてロボットの膝の曲がり方が浅いことが分かる。学習による目標姿勢の変更は行っていないため、この結果は仮想目標切り替えルールを変更することでロボットの目標姿勢切り替えが生じる時間が変化し、次いで人間からロボット、およびロボットから人間に加わる力が変化したために生じたと考えられる。

2 章で説明したとおり、CB² は身長約 130 [cm]、体重約 33 [kg] のヒューマノイドロボットであり、完全に脱力した状態のロボットを Fig. 7 のように引き起こすことは困難である。また、柔軟な関節で構成される多自由度の機構を有するため、腕のみを引くことで全身のそれぞれの自由度の変位を適切に導くことはできない。そのため、引き起こし中のロボットの運動の変化は、補助者である人間の運動の変化のみではなく、学習によってロボットの仮想目標切り替えルールが変化したために生じたと考えられる。すなわち、前述の腰の高さがより早い時間から増加し、膝の曲がり方が浅く変化したことも同様に、仮想目標切り替えルールの変化が人間の評価に基づく学習によって変更されたために生じたと考えられる。

次に、Fig. 8 に 2 名の物理的インタラクションにおける主成分分析で低次元化された空間上での運動軌跡の例を示す。それぞれの被験者の学習前、学習後の姿勢の時系列データは、それぞれ別に主成分分析を行うことで低次元化を行った。すなわち、Fig. 8 に含まれる四つの図のそれぞれは、一つの図に含まれる 5 回のインタラクションのデータを主成分分析によって低次元で表現した図である。また、それぞれの図において、インタラクション開始時および終了時のロボットの姿勢は、それぞれ軌道の左端、右端で表される状態にある。これらの図から、学習前と比べ学習後のほうが姿勢変化の軌跡が滑らかになっており、学習前に比べて各軌跡のばらつきが少ないことが定性的に分かる。これは、Fig. 7 で示した腰の高さのスムーズな増加や、膝の曲がり方の変化を示すものと考えられる。

これらの結果から本研究では、人間の補助がロボットの腰の高さをスムーズに増加させることや膝の曲がり方を緩和することを導くように行われ、その変化がより明確に達成された場合に「良い」という評価を与えた結果、ロボットの運動の効率が改善されたと考えられる。

そこで、学習によってロボットの運動の効率が改善されたことを定量的に評価するため、本稿では姿勢変化ノルムの総和に注目して解析を行う。

$$a(t) = \|\mathbf{x}(t) - \mathbf{x}(t-1)\|_2, \mathbf{x} \in \mathbf{X}. \quad (10)$$

$$A = \sum_t a(t), (t_{start} \geq t \geq t_{end}) \quad (11)$$

ここで、 a は姿勢変化ノルム、 \mathbf{x} は各関節角で定義される姿勢空間 \mathbf{X} における点で表される姿勢ベクトルを表す。また、 t_{start} および t_{end} はそれぞれインタラクション開始時刻 (CB² の腕を持ち上げ始めた時刻) およびインタラクション終了時刻 (膝が伸びきって立ち上がった時刻) を表す。

姿勢変化ノルムの総和は、インタラクション中のロボットの姿勢変化の量を表す。よって、姿勢変化ノルムの総和が少なく、引き起こしインタラクションが成功する場合、ロボットが少な

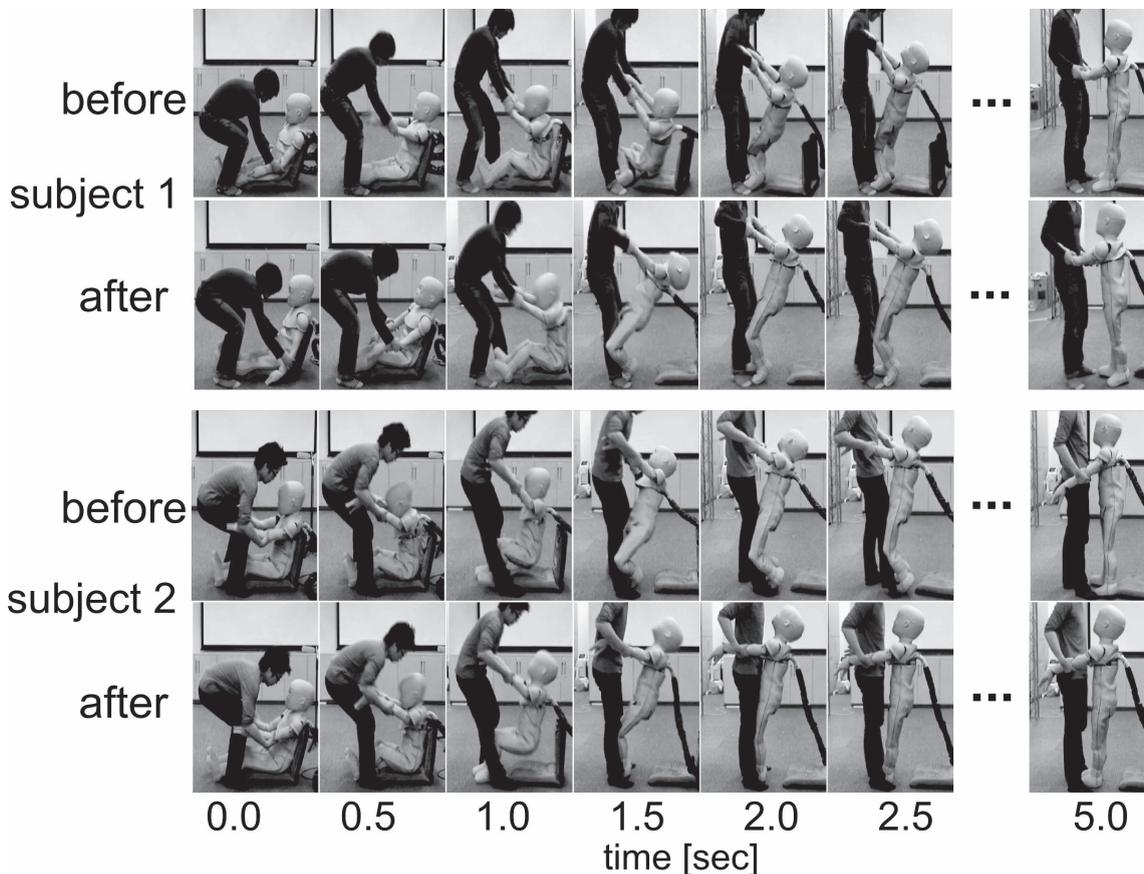


Fig. 7 Sequential snapshots of the first (top) and last (bottom) interaction of the test subjects with the robot. The white curve depicts the change in the robot's hips position

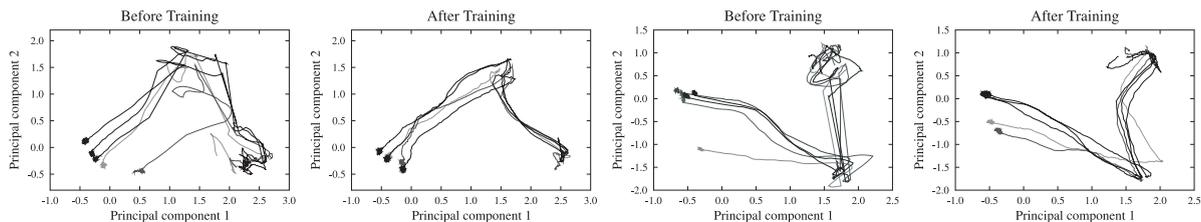


Fig. 8 Projected interactions in the low-dimensional posture space. The left two plots show the interaction trajectories for the first subject before and after learning. The right two plots show the interaction trajectories for the second subject. Each figure expresses low-dimensional interaction trajectories as a result of PCA for the five interactions data. The right endpoints and the left endpoints in each figure indicate initial postures and final postures respectively. In both cases the trajectories becomes smoother after learning and sudden jumps and knots are reduced

い動作で引き起こしが成功していることを表す。また、先に説明したとおり、柔軟な関節で構成される多自由度の機構を有し、腕のみを引くことで全身のそれぞれの自由度の変位を適切に導くことはできないため、単に補助者である人間がより多くの仕事を行うだけでは姿勢変化ノルムの総和の減少は生じない。このことから本研究では、姿勢変化ノルムの総和は引き起こしインタラクションにおけるロボットの運動を評価する指標として妥当であると考え、ここでは、学習あり実験と学習なし実験

の双方で得られた計 30 回の「良い」と評価されたインタラクションのデータを対象とし、前述の姿勢変化ノルムの総和および姿勢変化ノルムの最大値を計算、比較した。

Fig. 9に座った状態から立った状態に至るまで姿勢変化ノルムを総和した値の比較結果を示す。ここでは、「良い」と評価された 30 回のインタラクションのデータを最初の 10 回と中盤の 10 回、最後の 10 回に分けることで、人間がロボットを引き起こす技術の習熟過程と提案手法によるインタラクションの改善

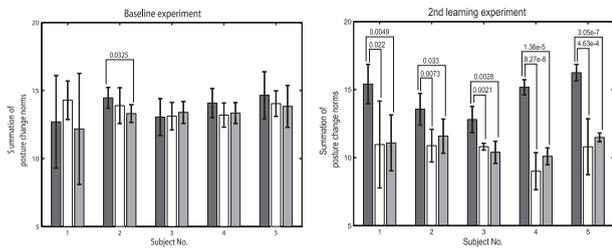


Fig. 9 The average and standard deviation of the summation of the posture change norm of test subjects in the baseline experiment (left) and training experiment (right). The dark gray, white, and light gray bars indicate the mean and standard deviation values during each of the intermediate learning steps (after every 10 trials). In the case of the baseline experiment only subject 2 has a significant improvement after all trials. After the training experiment, the interaction with the robot improved for all subjects

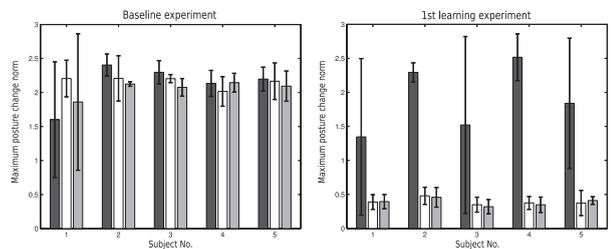


Fig. 10 The change of the maximum posture change norm in each phase during the baseline experiment and the first learning experiment. We cannot see any significant difference of the maximum posture change norm in the baseline experiment. On the other hand, there are large changes of the maximum posture change norm in the learning experiment. For all subjects the values drastically decrease after learning

過程を比較する。Fig. 9 の右図は、学習あり実験において Fig. 3 に示した初期の仮想目標切り替えルールから提案手法を2度適用することでインタラクションがどれほど改善されたかを表している。また Fig. 9 の左図は、学習なし実験で得られたデータを解析した結果であり、人間の適応能力のみで引き起こしインタラクションがどれほど改善されるかを表している。Fig. 9 から、2度目の学習後の引き起こしインタラクションにおけるロボットの姿勢変化は、初期プログラムを用いる場合に比べて少ないことが分かる。また、t検定を行った結果、すべての被験者について学習後の引き起こしインタラクションにおける姿勢変化量と、初期プログラムを用いた場合の姿勢変化量との間に有意差（有意水準 $\alpha = 5\%$ ）があることが示された。これは、初期プログラムを用いて同じ回数引き起こしインタラクションを行った際の結果と比べて運動の改善が大きいことを表しており、提案手法によって引き起こしインタラクションが改善されたことを表している。

Fig. 10 に Fig. 9 で用いたデータと同様のデータについて、姿勢変化ノルムの最大値で比較した図を示す。この図から、提案手法による引き起こしインタラクションの改善は、姿勢変化ノルムの最大値が減少することで得られたと考えられる。すな

わち、Fig. 7 について先に議論した様な膝関節の動きや、肩関節における大きな角度変化等の不必要な運動が減少したことを表すと考えられる。

以上の結果から、提案学習システムの適用によって、引き起こしインタラクションにおけるロボットの不必要な姿勢変化が減少し、全体として効率的な引き起こしインタラクションになったと考えられる。よって、本提案学習システムが柔軟関節を利用した物理的インタラクションにおいて、人間—ロボット間の物理的インタラクション全体の運動を改善する手法として有効な手法であると考えられる。

6. 考察

Fig. 8 において、両被験者による補助によって立ち上がったロボットの低次元化された姿勢軌道は、学習前、学習後を問わずいづれも大まかに V 字形の軌道を示している。これは引き起こしインタラクションにおけるロボットの運動が、初期姿勢から中間目標姿勢に向かう動作と、中間目標姿勢から最終目標姿勢に向かう動作の二つに大別できるためと考えられる。國吉らは、動的な運動においてロボットが経路すべき状態の重要性は運動開始から運動終了までで非均一に存在すること、すなわち動的な目的の運動を達成するために経路すべき数個の状態「運動のコツ」が存在することを示した [20]。この研究は環境—ロボット間インタラクション全体の動力学において現れる特性であり、新たな運動生成アプローチにおいて運動制御の簡単化を行うための重要な視点を示している。本研究では、すでに引き起こしインタラクションが成り立っている状態から学習を始めているため、学習前と学習後で軌道中の変化が少ない部分が物理的インタラクションにおける運動のコツであると考えられる。そのため、Fig. 8 に示された軌道における V 字形の特長は運動のコツに相当する可能性がある。これは、運動のコツが環境—ロボット間のインタラクションにおける全体の動力学だけの特徴ではなく、人間の動力学を含めた環境—人間—ロボット間のインタラクションにおいても現れ、人間—ロボット間の物理的インタラクションにおいても環境—ロボット間インタラクションと同様の方法 [21] [22] によって運動制御を簡単化できる可能性を示唆するものであると考えられる。これらの可能性に注目し、より定量的に人間—ロボット間の物理的インタラクションを解析することは今後の重要な課題であると考えられる。また、床反力計などの新たなセンサを導入し、より詳細に人間—ロボット間の物理的インタラクションを計測することも重要であると考えられる。

本研究では、物理的インタラクションにおいて人間の補助を利用するロボットの運動学習システムを提案した。提案学習システムの有効性を検証するために、本稿では人間がロボットを引き起こして立たせるタスクに注目し、提案学習システムの適用によって引き起こしインタラクションにおけるロボットの動作が改善されることを確認した。これは、本研究で比較に用いた姿勢変化ノルムの総和が、引き起こしインタラクションにおける人間の主観的な評価の一面を表したためと考えられる。今後、人間が補助を行う際の動作の計測や人間が加える補助力の計測を通じて人間が行う補助および評価の特性を明らかにする

ことは、学習の収束性や人間を含む系で学習を行うことの利点を明らかにする上で非常に重要な課題になると考えられる。

また、人間の補助を利用する運動学習に対して期待される結果の一つとして、最終的に人間が補助することなくロボットにその運動を達成させることが挙げられる。しかし、本研究で扱った引き起こしインタラクションにおいて学習されたロボットの動作は、人間の補助を利用することを前提としているため、最終的にロボット単体で運動が達成されることはない。この点に対し本研究では今後、人間からの補助によるロボットの動作への寄与を最小化する学習を Human-in-the-Loop Learning の枠組みに加えることで、最終的に人間が補助することなくロボットにその運動を達成させる運動学習システムを提案できると考えている。物理的インタラクションにおける寄与の最大化、最小化の視点から物理的インタラクションにおいて可能な学習を明らかにすることは、本研究における重要な課題である。

本稿では提案手法の適用に際し、各関節の角度制御のフィードバックゲインや Fig. 3 に示した各目標姿勢 x_n^* と仮想目標切り替えルールを手動で設定した。今後、初期の動作を手動で設定することなく、引き起こしインタラクションの実現自体も学習によって行えるように Human-in-the-Loop Learning の枠組みを構築することも重要な課題と言える。

7. おわりに

本稿ではまず、CB² の運動を表現する方法として柿谷らによって提案された仮想目標切り替えパターン [13] を拡張した仮想目標切り替えルールを提案した。そして、仮想目標切り替えルールを用いることで単純な制御で引き起こしインタラクションを実現できることを示した。次に、人間-ロボット間インタラクションにおける人間の高い適応力を利用する学習の枠組みとして Human-in-the-Loop Learning を提案し、引き起こしインタラクションを改善する具体的な運動学習システムを提案した。提案学習システムの有効性を検証するために、本稿では人間がロボットを引き起こして立たせるタスクに注目し、提案学習システムの適用によって、引き起こしインタラクションにおけるロボットの余分な姿勢変化が減少し、効率的な動作になることを確認した。これらの結果は、人間と同一の環境でタスクを行うヒューマノイドロボットにおける柔軟関節、および Human-in-the-Loop Learning の有用性を示唆するものであると考えられる。

謝辞 本研究は特別研究員奨励費 (A217530) の助成を受けた。また、用いたロボット CB² は JST ERATO 浅田共創知能システムプロジェクトにおいて開発されたものである。同プロジェクトの総括および大阪大学大学院工学研究科、浅田稔教授からは多くの非常に有用な助言をいただいた。ここに記して謝意を表す。

参考文献

- [1] A. De Luca and R. Mattone: "Sensorless robot collision detection and hybrid force/motion control," IEEE International Conference on Robotics and Automation, pp.999-1004, 2005.
- [2] K. Suita, Y. Yamada, N. Tsuchida, K. Imai, H. Ikeda and N. Sugimoto: "A failure-to-safety "Kyozon" system with simple contactdetection and stop capabilities for safe human-
- autonomous robotcoexistence," IEEE International Conference on Robotics and Automation, vol.3, 1995.
- [3] T. Matsumoto and K. Kosuge: "Collision detection of manipulator based on adaptive control law," 2001 IEEE/ASME International Conference on Advanced Intelligent Mechatronics, vol.1, 2001.
- [4] S. Morinaga and K. Kosuge: "Collision detection system for manipulator based on adaptive impedance control law," IEEE International Conference on Robotics and Automation, vol.1, 2003.
- [5] J. Heinzmann and A. Zelinsky: "Quantitative safety guarantees for physical human-robot interaction," The International Journal of Robotics Research, vol.22, no.7-8, p.479, 2003.
- [6] K. Ikuta, H. Ishii and M. Nokata: "Safety evaluation method of design and control for human-care robots," The International Journal of Robotics Research, vol.22, no.5, p.281, 2003.
- [7] R. Hirose and T. Takenaka: "Development of the humanoid robot ASIMO," Honda R&D Technical Review, vol.13, no.1, 2001.
- [8] K. Kaneko, F. Kanehiro, S. Kajita, H. Hirukawa, T. Kawasaki, M. Hirata, K. Akachi and T. Isozumi: "Humanoid robot HRP-2," IEEE International Conference on Robotics and Automation, vol.2, pp.1083-1090, 2004.
- [9] T. Minato, M. Shimada, H. Ishiguro and S. Itakura: "Development of an android robot for studying human-robot interaction," Lecture Notes in Computer Science, pp.424-434, 2004.
- [10] T. Minato, Y. Yoshikawa, T. Noda, S. Ikemoto, H. Ishiguro and M. Asada: "Cb2: A child robot with biomimetic body for cognitive developmental robotics," Proc. of IEEE/RAS 7th Int. Conference on Humanoid Robots, pp.557-562, 2007.
- [11] I. Mizuuchi, Y. Nakanishi, Y. Sodeyama, Y. Namiki, T. Nishino, N. Muramatsu, J. Urata, K. Hongo, T. Yoshikai and M. Inaba: "An Advanced Musculoskeletal Humanoid Kojiro," Proc. 2007 IEEE-RAS Int. Conf. on Humanoid Robots, pp.101-106, 2007.
- [12] I. Mizuuchi, R. Tajima, T. Yoshikai, D. Sato, K. Nagashima, M. Inaba, Y. Kuniyoshi and H. Inoue: "The design and control of the flexible spine of a fully tendon-driven humanoid "Kenta"," IEEE/RSJ International Conference on Intelligent Robots and Systems, 2002.
- [13] 柿谷慧, 寺田耕志, 國吉康夫: "仮想目標切替パターンの探索による実ロボットの多様な動作獲得", ロボティクス・メカトロニクス講演会講演概要集, 2008:2P2-G13, 2008.
- [14] S. Ikemoto, T. Minato and H. Ishiguro: "Analysis of physical human-robot interaction for motor learning with physical help," Applied Bionics and Biomechanics (Special issue on Humanoid Robots), vol.5, pp.213-223, 2008.
- [15] K. Kosuge, T. Hayashi, Y. Hirata and R. Tobiyaama: "Dance partner robot—ms dancer—," IEEE/RSJ International Conference on Intelligent Robots and Systems, vol.3, pp.3459-3464, 2003.
- [16] E. Berger, H. Ben Amor, D. Vogt and B. Jung: "Towards a simulator for imitation learning with kinesthetic bootstrapping," Proceedings of the SIMPAR 2008 International Conference on Simulation Modeling and Programming for Autonomous Robots, Workshop on The Universe of RoboCup Simulators, Proceedings CD, 2008.
- [17] S. Calinon and A. Billard: "What is the teacher's role in robot programming by demonstration?—Toward benchmarks for improved learning," Interaction Studies, Special Issue on Psychological Benchmarks in Human-Robot Interaction, vol.8, no.3, pp.441-464, 2007.
- [18] R. Dawkins: The Blind Watchmaker. Longman, 1986.
- [19] S.P. Lloyd: "Least squares quantization in PCM," IEEE Transactions on Information Theory, vol.28, no.2, pp.129-137, 1982.
- [20] Y. Kuniyoshi, Y. Ohmura, K. Terada, A. Nagakubo, S. Eitoku and T. Yamamoto: "Embodied basis of invariant features in ex-

education and perception of whole body dynamic actions - knacks and focuses of roll-and-rise motion,” Robotics and Autonomous Systems vol.48, no.4, pp.189–201, 2004.

- [21] Y. Kuniyoshi, Y. Ohmura, K. Terada, T. Yamamoto and A. Nagakubo: “Exploiting the Global Dynamics Structure of Whole-Body Humanoid Motion—Getting the “Knack” of Roll-and-Rise

Motion,” Robotics research: the eleventh international symposium, p.385, 2005.

- [22] 寺田耕志, 國吉康夫: “力学系の有限時間到達可能性に基づく運動生成法 (制御の新理論とモーションコントロール 2, 生活を支援するロボメカ技術のメガインテグレーション)”, ロボティクス・メカトロニクス講演会講演概要集, 2005:1P1–N–052, 2005.



池本周平 (Shuhei Ikemoto)

2007年3月大阪大学大学院工学研究科知能・機能創成工学専攻博士前期課程修了。2009年4月より、日本学術振興会特別研究員 (DC2)。2010年3月大阪大学大学院工学研究科知能・機能創成工学専攻博士後期課程修了。現在、大阪大学大学院情報科学研究科マルチメディア工学専攻助教、博士 (工学)。

ロボットの運動を対象とした機械学習、生物規範型制御手法に関する研究に興味を持つ。
(日本ロボット学会正会員)



ベン・アモル ヘニ (Heni Ben Amor)

2005年ドイツ、コブレンツ大学修士課程卒業。2005年9月～2006年3月まで大阪大学大学院工学研究科知能・機能創成工学専攻知能ロボット学研究室においてロボットの運動学習に関する研究を行う。2006年4月ドイツ、フライベルグ大学博士課程入学。現在、同大学バーチャルリアリティ・マルチメディアグループ博士課程3年、修士 (工学)。

機械学習、バーチャルリアリティに興味を持つ。



港 隆史 (Takashi Minato)

2001年11月大阪大学大学院工学研究科知能・機能創成工学専攻博士後期課程単位修得退学。同年12月科学技術振興事業団研究員。2002年9月大阪大学大学院工学研究科知能・機能創成工学専攻助手。2006年6月よりJST ERATO 浅田共創知能システムプロジェクト研究員となり現在に至る。

博士 (工学)。人とロボットのコミュニケーションに関する研究に従事。
(日本ロボット学会正会員)



ユング バーンハード (Bernhard Jung)

ドイツ、シュトゥットガルト大学およびアメリカ、ミズーリ大学において計算機科学および言語学を学ぶ。知的仮想環境下における動的な知識表現に関する研究によってドイツ、ピーレフェルト大学より博士を得る。博士 (工学)。2003年よりドイツ、リューベック大学メディア情報学教授。2005年10

月よりドイツ、フライベルグ大学バーチャルリアリティ・マルチメディアグループ教授。バーチャルリアリティ、ヒューマン・コンピュータインターフェースの研究に従事。



石黒 浩 (Hiroshi Ishiguro)

1991年大阪大学大学院基礎工学研究科物理系専攻修了。同年山梨大学工学部情報工学科助手。1992年大阪大学基礎工学部システム工学科助手。1994年京都大学大学院工学研究科情報工学専攻助教授。この間、1998年より1年間カリフォルニア大学サンディエゴ校客員研究員。2000年和歌山大学システム工学部情報通信システム学科助教授。2001年より同大学教授。

2002年10月より大阪大学大学院工学研究科知能・機能創成工学専攻教授。1999年より、ATR 知能映像研究所客員研究員。現在、大阪大学大学院基礎工学研究科システム創成専攻教授。ATR 知能ロボティクス研究所コミュニケーションロボット研究室客員室長。工学博士。知能ロボット、アンドロイドロボット、センサネットワークの研究に興味を持つ。人工知能学会、電子情報通信学会、IEEE、AAAI 各会員。
(日本ロボット学会正会員)