

空気圧アクチュエータの特性を考慮したアンドロイドの運動学習

Motor Learning for an Android by Compensating the Characteristic of Pneumatic Actuator

池本 周平[†]

Shuhei Ikemoto

港 隆史[‡]

Takashi Minato

石黒 浩^{†‡}

Hiroshi Ishiguro

[†] 大阪大学 (Osaka Univ.), [‡] JST ERATO

1 はじめに

近年、ロボットの機能としてコミュニケーション能力に注目したコミュニケーションロボットの研究が盛んに行われている。その中でもアンドロイドサイエンス¹⁾では、人間に酷似した外見を有するロボット「アンドロイド」を用いて、ロボットの外見と動作の関係等、ロボットにおいて自然なコミュニケーションを実現するために必要な性能、それを実現するための要素を明らかにし、コミュニケーションロボットの設計論を構築することを目的に研究を行っている。

Fig.1に開発されたアンドロイドを示す。このアンドロイドは全身に42の自由度を有する超多自由度ロボットであり、柔軟な素材を用いた皮膚によって人間に酷似した外見を実現している。また、アクチュエータとして空気圧シリンダ、及び空気圧モータを用いることで、

- 作動流体の高い圧縮性による安全性の確保
- 高い出力/重量比によるコンパクトな機構

を実現している。しかし、一般に空気圧駆動システムは非線形性を有しており、制御が困難である。加えて、アンドロイドの人間らしい外見を実現するために、小さいアクチュエータ、および圧縮空気を供給するために細く長い管路を用いていることから、その非線形性は非常に強くなり、むだ時間を含む大きな応答の遅れとなって表れる。そのため、このアンドロイドにおいてある動作を実現するには、一般の多自由度ロボットにおいて問題となる逆運動学の特異点、冗長性の問題に加え、各関節におけるサーボの設計も大きな問題となる。よって、目標の動作を実現することは非常に困難な制御問題を含んでいる。

逆運動学の問題については多くの研究がなされており、既に複数の有力な手法が提案されている。特にロボットの運動学習と呼ばれるアプローチにおいては、ロボットの未知のダイナミクスを学習する過程で、逆運動学の冗長性を解決し、フィードフォワードによる軌道追従を実現する手法が提案されている。その代表的な手法として、フィードバック誤差学習²⁾が挙げられる。この手法を空気圧駆動のマニピュレータに用いた研究³⁾では、高精度な軌道追従を実現していることから、むだ時間を含む応答の遅れを有する制御対象に対しても、この手法が有効であると言える。しか

しこのアンドロイドでは、細く長い管路を用いるために、通常の空気圧駆動システムよりも大きいむだ時間を含む応答の遅れが存在する。その様な大きいむだ時間が存在する場合、通常のフィードバック制御による安定化が非常に困難であると報告⁴⁾されており、アンドロイドにおいてフィードバック誤差学習を適用する上での問題になると考えられる。

そこで本研究では、開発されたアンドロイドにおける高精度な軌道制御の実現を目的とし、大きなむだ時間を含む応答の遅れを有するロボットに対して有効なロボットの運動学習手法を提案する。多自由度に伴うダイナミクスの複雑化を避けるため、本研究では、1自由度の空気圧マニピュレータを用いて、特性の測定、および提案手法の評価を行う。

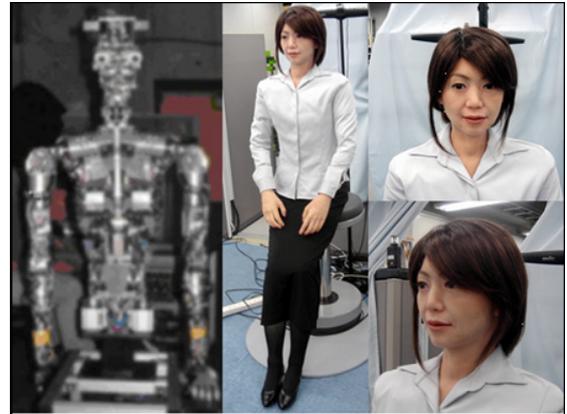


Fig.1 The developed android

2 空気圧駆動システムの特性

アンドロイドは多自由度の機構と空気圧駆動システムの特性の2つの要因によって、非常に強い非線形性を有することから、各関節における目標関節角軌道の実現が困難である。特に後者は、非常に大きな応答の遅れを作り出し、追従制御を行う上で大きな問題となる。そこで本研究では後者の要因に注目する。まず、それによって生じる応答の遅れの特性を調べるために、Fig.2に示す1自由度空気圧マニピュレータ(開発されたアンドロイドに使われているものと同等のもの)を用いて、以下の2点について測定を行った。

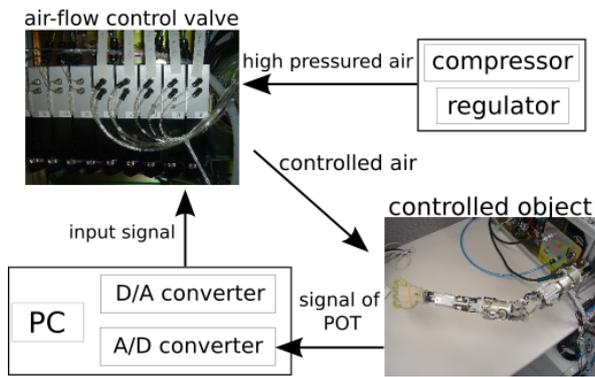


Fig.2 Experimental setup

2.1 入力履歴の影響

Fig.2の実験装置において、制御入力空気流量制御弁への信号であり、出力はマニピュレータの関節のポテンショメータの信号である。よって、この実験装置において、制御弁や空気等のダイナミクスは隠れ変数によって表現される。このダイナミクスにより、現在の出力は数時刻前から現在までの入力、及び出力の影響を受ける。応答の特性はステップ応答によって測定する。しかし、前述したように初期状態の影響を受けるため、ここでは以下の手順によって、過去の入出力の影響の大きさを調べる。

1. 開始時刻 t_0 から時刻 t_n まで、マニピュレータを曲げた状態で運動を拘束し、その状態で曲げる方向に最大のトルクを与える。
2. 時刻 t_{n+1} から拘束を解除し、伸ばす方向に最大トルクを与える。
3. 時刻 t_{n+1} から関節角に変化が表れるまでの時間 t_d (不感となる時間) を測定する。

以上を繰り返し、 n の変化に対して t_d がどのように変化するかを調べた。測定結果を Fig.3 に示す。この図より、 t_n が約 1000msec となったとき、 t_d が一定となるため、隠れ変数を定常状態にするために少なくとも 1000msec 以上の一定入力が必要であることが分かる。

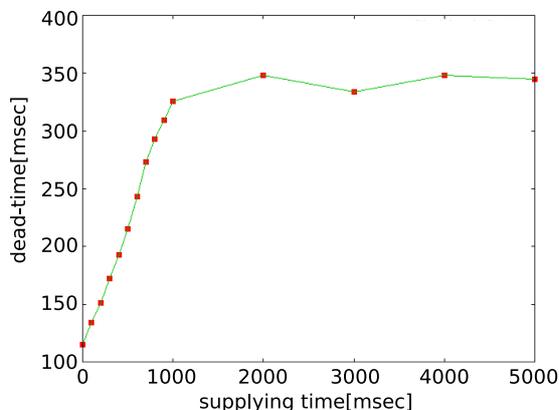


Fig.3 Influence of the input history

2.2 初期状態の影響

前節の結果より、定常状態を得るために 1000msec 以上の一定入力が必要であることが分かったため、以下の手順で弁開度が応答の遅れに与える影響を測定する。

1. 開始から 1000msec 以上、マニピュレータを曲げた状態で運動を拘束した上で曲げる方向にトルクを生じさせる空気流量制御弁への一定入力 V を行う。
2. 肘を伸ばす方向に最大トルクを生じさせる一定入力 V_{max} を行う。
3. V_{max} を印加してから関節各に変化が表れるまでの時間 t_d (不感となる時間) を測定する。

以上を繰り返し、 V の変化に対して t_d がどのように変化するかを調べた。測定結果を Fig.4 に示す。この図から、 $V \geq 6$ であれば t_d は非常に大きく、ほぼ一定の t_d となることが分かる。 $V \geq 6$ は弁を完全に閉じる入力であるが、空気流量制御弁のヒステリシスにより、入力信号 V に対して弁開度が一意に決まらない。しかし、 $V = 5$ と $V \geq 6$ の間には明確な変化が表れていると言える。 $V < 5$ となる範囲は肘関節を伸ばす方向の入力であるため、運動を拘束できず、測定する事はできなかったが、 t_d はより小さくなると考えられる。

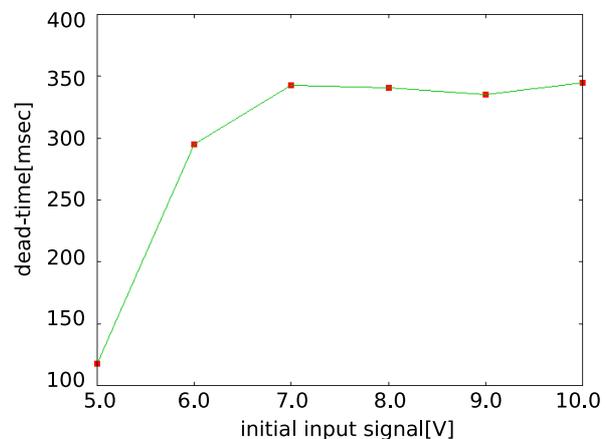


Fig.4 influence of initial valve gap

以上の測定結果から、1自由度の空気圧マニピュレータであっても、空気圧駆動システムが有するダイナミクスは複雑であり、高精度のモデル化は非常に困難となるため、学習手法の適用が有効であると考えられる。しかし、大きな応答の遅れは従来の学習手法の適用を困難にすると考えられる。そこで、その問題を説明し、その問題への対処を提案する。

3 運動学習手法の提案

多くのロボットの運動学習手法において、学習される内部モデルとは逆力学モデルを指し、その逆モデルはフィードフォワード制御による軌道制御に用いられる。Fig.5 に、それらの手法の内、最も多く用いられるフィードバック誤差学習²⁾のブロック線図を示す。

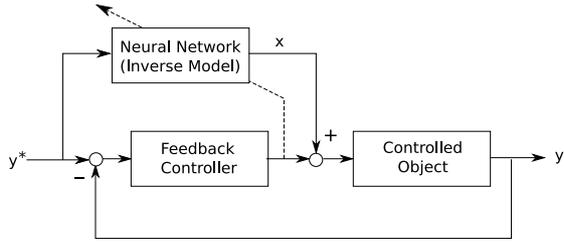


Fig.5 Feedback error learning

この手法は目標軌道を実現する逆モデルを学習する手法である。しかし、ある軌道を実現するための各時刻における入力信号 x_t^* は、制御対象の応答から直接知ることができない。そこでこの手法では、各時刻におけるニューラルネットワークの出力誤差 E_t^{NN} を以下のように近似する。

$$E_t^{NN} = (x_t^* - x_t) \approx K (y_t^* - y_t) \quad (1)$$

この式から、フィードバック誤差学習において、ニューラルネットワークの出力誤差はフィードバック制御器の信号によって近似されると言える。この近似は、ある程度のむだ時間を含む応答の遅れを有する制御対象に対しても有効であることが示されている³⁾。しかし2章で示したように、アンドロイドの応答は、強い非線形性による非常に大きなむだ時間、及び高次の遅れを有しているため、定数ゲインのフィードバック制御器による追従制御は困難である。そのため、式(1)のニューラルネットワークの出力誤差の近似が成り立たない場合が考えられる。そこで、時刻 t_c におけるニューラルネットワークの出力誤差の近似値を、

$$E_{t_c}^{NN} \approx K \frac{1}{n} \sum_{t=t_c}^{t_c+n} (y_t^* - y_t) \quad (2)$$

の様に算出することを考える。この式の右辺は未来の n 時刻間に生じる誤差に対してのフィードバック制御入力を表す。これによってニューラルネットワークは、むだ時間以降の誤差に対処できる先行入力を学習できる。ただし、このようなフィードバック制御入力を各時刻において行うことはできないため、この手法では、フィードバック制御を行わず、ニューラルネットワークの出力のみを用いて制御を行う。

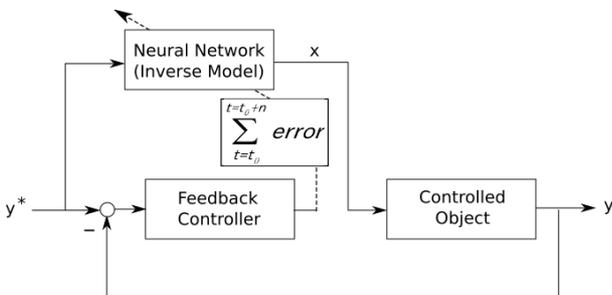


Fig.6 Proposed learning system

4 実験

提案した手法の有効性を調べるために以下の2点に注目し、学習によって軌道追従を行う実験を行った。

このとき、実験装置は Fig.2 に示されたものを用い、制御周期は 5msec とした。また、ニューラルネットワークの入力ベクトルは、 n ステップ先までの目標関節角とし、出力ベクトルは関節を制御するための空気流量制御弁への入力電圧とした。

4.1 評価に用いる時間幅について

平均誤差を計算するための誤差評価のパラメータ n の値を増加させ、安定した学習が行える n について調べた。Fig.7, 及び Fig.8 に軌道追従の結果を示す。

Fig.7 は、安定した学習が行えた場合の結果である。誤差評価のためのパラメータ n は 60 であり、300msec 間の平均誤差を用いている。このとき追従誤差は減少し、一定値に収束した。よって式(2)により、ニューラルネットワークの出力誤差が近似できたとと言える。それに対し、パラメータ n が小さい場合は、学習の初期において追従誤差が減少するが、一定値に収束せず、Fig.8 に示す結果となった。このとき、この評価はニューラルネットワークの出力誤差の近似になっていないと言える。よって、大きく変化する応答の遅れが学習を不安定にする問題に対し、適当なパラメータ n を設定することで、単純な式(2)により、ニューラルネットワークの出力誤差を近似できると言える。

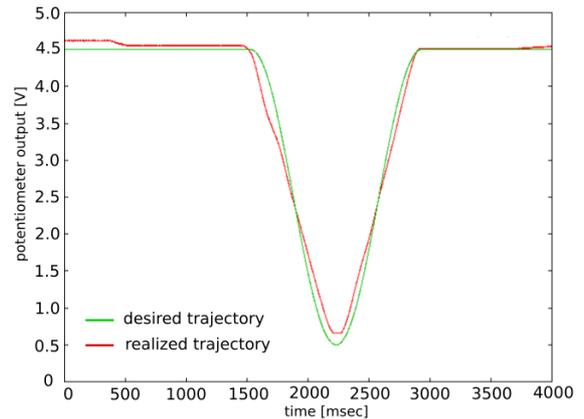


Fig.7 Result ($n=60$)

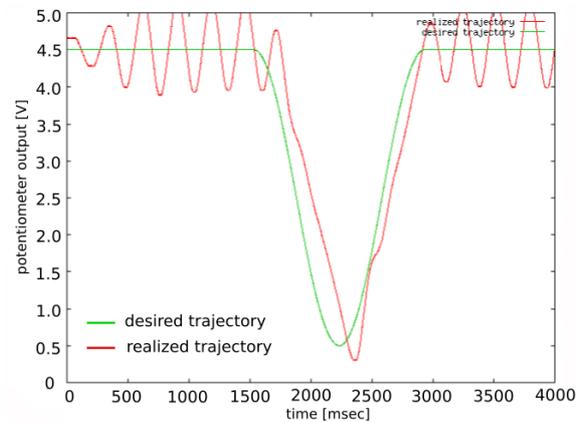


Fig.8 Result ($n=30$)

4.2 フィードバック制御器による制御について

ここでは、フィードバック制御器を除くことに関する有効性について確認する。そこで、Fig.5 に示したフィードバック誤差学習において、ニューラルネットワークの誤差評価を式 (2) と入れ換えたシステムで学習を行った。このとき n は 60 とした。

実験結果を Fig.9 に示す。Fig.8 の学習時と同様に学習初期の段階で追従誤差が減少するが、学習を続けると一定値に収束せず、発散する結果となった。これは、ニューラルネットワークの出力誤差の評価が適当であっても、その評価に基づかないフィードバック制御を行うことによって学習が不安定になることを表していると考えられる。Fig.5 に示したフィードバック誤差学習を変更せずに用いた場合においても、追従誤差がほとんど減少しない挙動が表れた。Fig.10 に Fig.7, Fig.8, Fig.9 の結果を得た際の学習過程における平均 2 乗誤差の変化を示す。パラメータ n を大きくした場合、式 (2) による近似は、追従誤差に対してローパスフィルタを適用することと同様の効果を与えるため、短い周期で生じる誤差に対しては近似できないこと、及び学習速度が低下することが考えられる。しかし Fig.10 において、提案手法では極端な学習速度の低下は見られず、学習過程で得られる軌道の追従誤差も小さいことから式 (2) による近似がむだ時間、および高次の遅れによる学習の不安定化に対して有効であると言える。

以上の結果から、提案した手法は変化する大きな応答の遅れを有するシステムの運動学習に対し、有効であると考えられる。

5 考察

実験で用いたニューラルネットワークの入力ベクトルの次元は、パラメータ n に等しいために、Fig.7 の結果を得た際に用いた入力ベクトルは 60 次元であった。そのため、多自由度のマニピュレータにおける軌道の学習を行う際には、非常に高次元の入力ベクトルが必要となり、探索空間の増大による学習速度の低下、得られる解の悪化等の悪影響が生じると考えられる。その問題に対処するためには入力ベクトルの次元の圧縮が必要である。その方法としては、関数近似、長い制御周期を用いること、および低次元空間への非線形写像

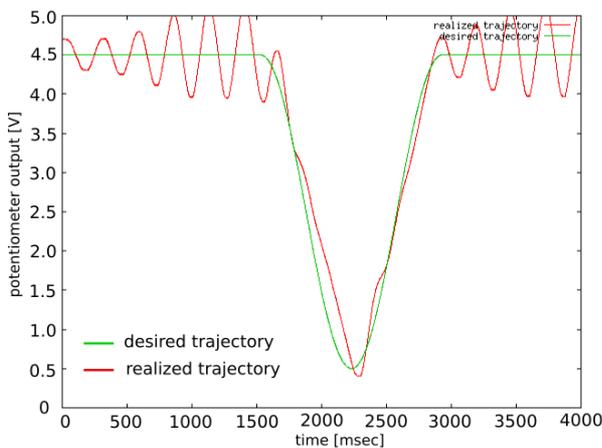


Fig.9 Result (FEL using averaged error evaluation)

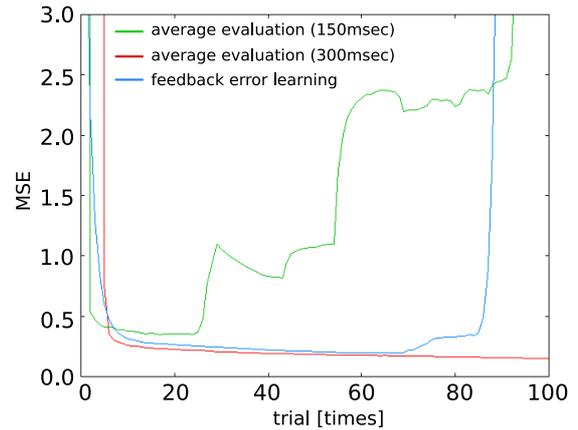


Fig.10 Learning process

等が挙げられる。加えて、これまでに行った実験により空気圧駆動システムにおけるむだ時間、高次の遅れは、空気の流れの方向の変化が生じる場合に大きく変化することが明らかになっている。そこで、平均誤差を計算する際のデータを区間を $(t_c + t_s \leq t \leq t_c + t_s + n)$ のデータとすることで、

$$E_{t_c}^{NN} \approx K \frac{1}{n} \sum_{t=t_c+t_s}^{t_c+t_s+n} (y_t^* - y_t). \quad (3)$$

によって近似し、区間の場所を決める新しいパラメータ t_s の値を流れの方向の変化に応じて変更する等の方法が考えられる、これによって $E_{t_c}^{NN}$ の近似の精度が向上することが考えられる。

6 おわりに

本論文では、非常に大きな応答の遅れを有する制御対象において、フィードバック制御による追従制御が不安定になり、フィードバック誤差学習を用いることができない問題に対処する手法を提案し、その有効性についての評価を行った。その結果、提案手法がむだ時間を含む大きな応答の遅れを有する系に対して有効であることを示した。空気圧アクチュエータが有する高い安全性、及び高い出力/重量比等の利点をロボットの駆動に利用する試みは多くなされており、空気圧アクチュエータが有する非線形性が大きな問題となるため、その問題に対処できる手法として、提案手法は広く適用可能な手法と言える。

参考文献

- 1) H. Ishiguro : Android Science -Toward a new cross-interdisciplinary framework, Proceedings of the International Symposium of Robotics Research, 2005
- 2) M. Kawato, Y. Uno, M. Inobe and R. Suzuki : Hierarchical neural network model for voluntary movement with application to robotics, IEEE Control System Magazine, 8, pp.8-16, 1988
- 3) 片山 正純, 川人 光男 : 筋肉・骨格系の運動制御を行う並列階層制御神経回路モデル, 電気情報通信学会論文誌 D-2, vol.J73-D-2, No.8, pp.1328-1335, 1990
- 4) 朝倉 俊行, 李 運生 : むだ時間を考慮した空気圧マニピュレータの軌道追従におけるカオス現象とニューラルネットワークによる安定化制御, 日本機械学会論文集 (C 編), 71 巻, 711 号, pp.3130-3137, 2005