

複数解像度連続状態空間による高速フィードフォワード制御

Fast Feed Forward Control using Continuous State Space with Multi-Resolution

川野 洋*¹
Hiroshi Kawano

*¹ 日本電信電話株式会社 NTT コミュニケーション科学基礎研究所
*¹NTT Corporation, NTT Communication Science Laboratories

This paper discusses an effect of the use of multi-layered state space, of which each layer has different resolution, on an application of online machine learning for acquisition of a dynamics model for feed forward control. By introducing the proposed method, the online acquisition of a dynamics model of the controlled plant can be dramatically accelerated without decreasing the accuracy of the obtained model. The proposed structure is designed to make the most of the accuracy of the dynamics model constructed by the state space with high resolution and the high learning speed of that constructed by the state space with low resolution. The performance of the proposed method is examined by experiments using feed forward control of multi-DOF ultrasonic motor.

1. はじめに

自動制御手法は、大きく分けてフィードバック制御とフィードフォワード制御からなる。フィードバック制御は、制御対象の状態の目標状態からの誤差を利用して、その誤差を減らすように制御入力値を自動的に調整する手法であり、簡単に実装することができるので広く利用されている。しかし、目標追従性能については限界があり、追従時間差等に関する要求が厳しい場合に十分に要求を満足できないという欠点がある。これに対して、フィードフォワード制御は、制御対象の入出力関係を記述した逆モデルを利用して、制御対象が目標状態に到達するための適切な制御入力値を計算する手法であり、高追従性と高精度を実現しやすい。その一方で、制御アルゴリズムの実装のためには、正確な逆モデルが必要であり、そのような逆モデルの獲得にかかるコストが高いという問題点がある。特に、その特性を数学的な方程式で記述しにくい制御対象を扱う場合は、その問題は顕著なものとなる。

これらの問題を解決するためには、機械学習の手法を応用した逆モデルの自動獲得が有効である。そのような手法の代表的なものとして、川人らによって提案されたフィードバック誤差学習がある[川人 1996 年]。フィードバック誤差学習は、制御対象の目標状態からの誤差を教師信号として利用し、逆モデルの入出力関係の自動調整を行うものである。具体的には、誤差の値が正の場合には、逆モデルの出力値を下げ、逆に誤差の値が負の場合には、逆モデルの出力値を上げる方向に調整を行う。この場合、逆モデルは、人工神経回路や、放射状基底関数を利用して構成されることが多く[Sutton 1998 年]、逆モデルの十分な精度を確保するためには、逆モデルを構成するパーセプトロンの数や放射状基底関数の中心点の数を十分多くする(解像度を高くする)ことが必要である。しかし、逆に解像度が高い場合には、それに応じて学習に要する時間が長くなるのが問題であり、実時間性を要求される自動制御問題の場合には特に深刻である。また、制御を行いながらのオンライン学習を使用する場合には、学習における状態空間の探索が、適切に行われなことが多く、逆モデルが状態空間全域で適切な値を出力でき




図1 多自由度超音波モータ
(東京工業大学上羽研究室製作)

るようになるとは限らないのも問題である。

本研究では、このような逆モデルの解像度に関する問題を解決するための手法として、低解像度の逆モデルが持つ高い学習速度と、高い解像度の逆モデルが持つ高い精度の両方を兼ね備えた、多重解像度状態空間[Moody 1989 年]に着目し、それによる逆モデル構成手法を提案する。そして、その有効性の検証を、多自由度超音波モータ(図1)を利用した実験により行う。

2. 多重解像度状態空間による逆モデル

2.1 逆モデルの構成と学習順序

図2に本研究で提案する多重解像度状態空間による逆モデル(MLIMMR: multi-layered inverse model with multi-resolution)の構成を示す。MLIMMRは、異なる解像度を持つ複数の逆モデルを階層的に配置したものである。各層の逆モデルは、与えられた入力値に対応する出力値を算出する。MLIMMRの出力値は、各層逆モデルの出力値の和である。図2では、便宜的に高解像度の逆モデルを上層に配置し、低解像度の逆モデルを下層に配置している。

連絡先: 川野 洋, 日本電信電話株式会社, 神奈川県厚木市
森の里宮 3-1, 電話:046-240-3185, FAX:046-240-4716,
E-mail:kawano@avg.brl.ntt.co.jp

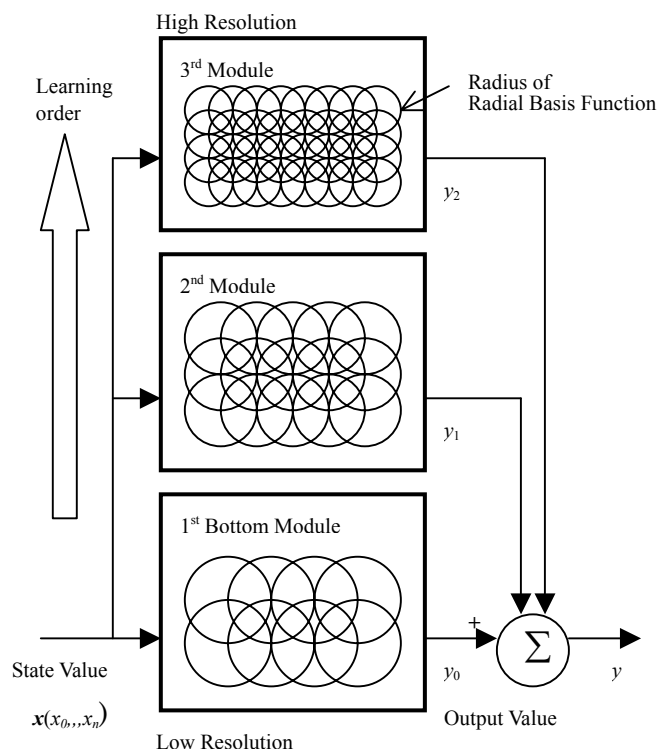


図2 多重解像度状態空間による逆モデルの構成

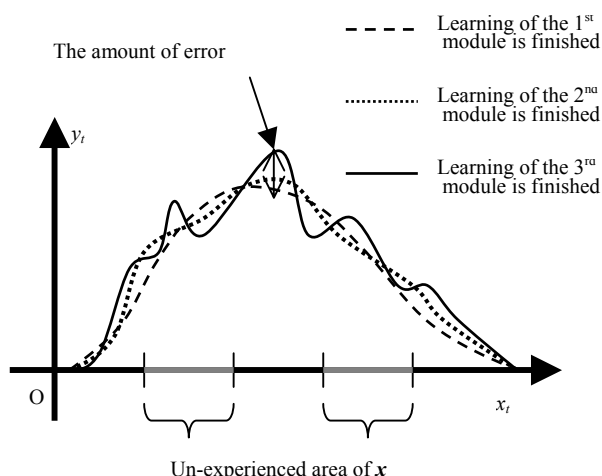


図3 学習による多重解像度状態空間による逆モデルの出力値の変化

学習前には、各逆モデルは常に 0 を出力する。学習は、低解像度の逆モデルから開始される。同時に学習を行う逆モデルは一つであり、ある解像度の逆モデルの学習が終了したら、その一つ上の解像度の逆モデルの学習を開始する。各逆モデルの学習は、学習が一定時間経過したら終了される。

2.2 学習プロセスのイメージ

図 3 に、学習中の MLIMMR の出力値が変化していく様子のイメージ図を示す。図 3 の破線は、最下層の最低解像度の逆モデルの学習が終了した時点での MLIMMR の出力値を示す。この時点では、最下層の逆モデル以外は、0 を出力している。この時点で、逆モデルの状態空間の全体が探索されているわけではないが、最下層逆モデルの解像度の低さにより、状態空間中の探索が済んでない箇所においても、探索済みの箇所の学

習結果を利用した補間が行われている。これにより、精度は低いものの逆モデルの入出力関係の全体像は、状態空間内の広い範囲でほぼ再現されている状態になっている。続いて、第 2 層の学習が行われる。第 2 層の学習中は、最下層は学習済みの値を出力するため、第 2 層は、最下層と理想的な出力値の間の誤差を埋める学習を行う。以後、第 2 層の学習が終了したら第 3 層、第 4 層の学習が順次行われる。最上層の学習が開始されたら、以後は、最上層は学習を停止せずに継続しつづける。

以上のプロセスにおいて、第 1 層の出力値と理想出力値の間の誤差は、出力値そのものの大きさに比べて小さいと考えられるので、第 2 層以降のそれぞれの層の逆モデルの学習に要する時間は、それぞれの層の逆モデルが単独で使用された場合の学習に要する時間に比べて大幅に短い。そのため、全層の学習に要する時間はさほど長くない。例えば、第 1、2、3 層の解像度比が 1:2:4 で次元数が 2 の場合、学習所要時間比は、ほぼ 1:4:16 であるが、上記の効果によって、第 2 層以降の逆モデルの学習時間は、第 1 層の学習時間と同じ時間にしても問題ないと考えれば、全層の学習に要する時間はたかだか $1+1+1=3$ である。これは、単独で、第 3 層を利用した場合に比べてはるかに短い。

3. 実験のための実装

3.1 多自由度超音波モータ

本研究では、制御対象として、図1に示す多自由度超音波モータを仮定する。多自由度超音波モータは、球状の回転子を持ち、1 台で 3 方向への回転を行うことができ、高トルク性能に優れている。しかし、その動特性が摩擦力によって支配されているため、逆モデルを簡単な方程式で記述することは難しく、また、運転中に動特性が変化するという問題がある。また、モータ動作は極めて俊敏であり、速度のステップ応答時間は 10ms と非常に短いため、通常のフィードバック制御手法を使用すると深刻なギザギザ動作を起こしやすい。これらの問題を考慮すると、フィードバック誤差学習によるフィードフォワード制御の適用例として、多自由度超音波モータは適切であると言える[川野 2003 年]。

3.2 逆モデル

本研究では、放射状基底関数 (RBF: Radial Basis Function) を利用して、MLIMMR を実装する。RBF の定義は、

$$f_{jk}(x_0, x_1, \dots, x_n) = \exp\left(-\frac{\sum_i \|x_i - c_{ijk}\|^2}{r_k^2}\right) \quad \dots(1)$$

である。 x_0, \dots, x_n は入力ベクトルの各要素変数であり、 c_{ijk} は、RBF の中心点座標、 r_k は、RBF の基準半径である。 i は入力ベクトルの要素番号、 j は RBF の中心点の番号、 k は逆モデルの層番号である。入力変数軸によって構成される状態空間内に格子状に RBF の中心点を配置して、各層の逆モデルを構成する。すなわち各層の出力値 y_k は、

$$y_k(x_0, x_1, \dots, x_n) = \sum_j w_{jk} f_{jk}(x_0, x_1, \dots, x_n) \quad \dots(2)$$

である。 w_{jk} は重み変数である。学習によって、重み変数の値を調整する。(2)より MLIMMR の出力値 y は、

$$y = \sum_k y_k(x_0, x_1, \dots, x_n) \quad \dots(3)$$

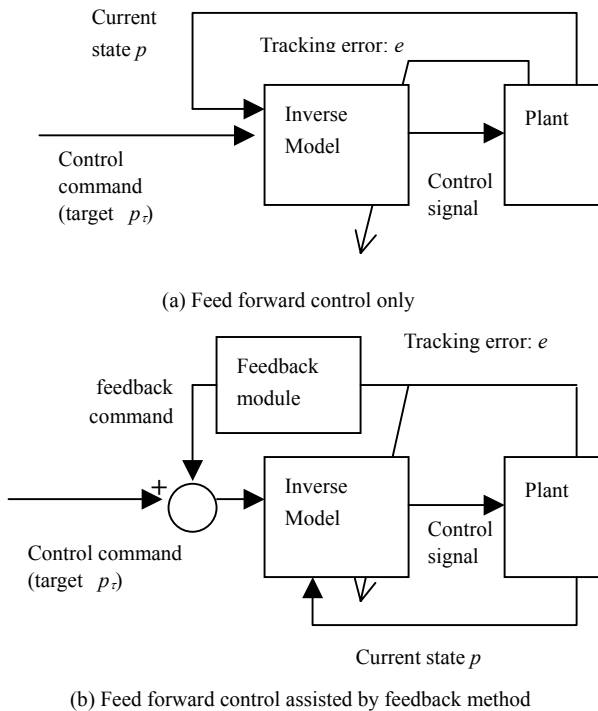


図4 実験で使用した制御アルゴリズム

表1 実験における MLIMMR の各定数の値

Parameter	1st module	2nd module	3rd module
解像度 (RBF の中心点数)	9	36	144
回転角度位置範囲	± 10 deg		
制御目標速度範囲	± 30 deg/sec		
学習時間	5 sec	no limit	
学習率 α	0.01		

となる。 w_{jk} は、以下の学習側により更新される。

$$w_{jk} \rightarrow w_{jk} + \alpha e \frac{\partial}{\partial w_{jk}} y_k(x_0, x_1, \dots, x_n) \quad \dots(4)$$

ここでは、 e は制御誤差、 α は、学習率である。

3.3 制御アルゴリズム

図4に、本研究の実験で使用したフィードフォワード制御アルゴリズムのブロック図を示す。(a)は、フィードフォワード制御のみによる制御アルゴリズムであり、(b)は、フィードバック制御により補助されたフィードフォワード制御アルゴリズムである。(a)は、MLIMMRの学習性能の評価に、(b)は、MLIMMRを利用した制御アルゴリズムの総合的な性能の評価のためのものである。

モータへの制御出力は電圧値で与えられ、制御目標は、回転速度で与えられる。制御目標回転速度は、目標回転角度位置を微分して算出されるものである。実験ではモータ回転子上に負荷重量物を固定することを考慮し、逆モデルの入力をモータの回転角度位置と制御目標回転速度とする。また、出力は、制御電圧とする。

4. 実験による検証

4.1 学習速度検証結果

MLIMMRを利用した制御アルゴリズム(a)と、MLIMMRの最上層と同じ解像度を持った逆モデルを利用した制御アルゴリズム(a)とで、学習速度を比較した。学習速度の比較は、制御誤差の時間履歴を参照して行った。表1に、実験で使用した各定数の値を示す。検証に使用した目標軌道は、正弦波状の軌道とした。目標軌道の周期は、学習開始後30秒間は、4秒としたが、30秒以降は、周期を変化させた。変化後の周期の値は、2秒の場合と10秒の場合の2通りで実験を行った。

図5、6に単層の逆モデルを利用した場合の、図7、8にMLIMMRを利用した場合の実験結果を示す。総じて、学習開始直後の制御誤差値は、単層逆モデルを使用した場合が低いが、その後の目標軌道の周期変更までは、単層逆モデルとMLIMMRの両者の場合で同様の大きさの制御誤差値を示している。これは、学習開始直後のMLIMMRの最下層逆モデルの低解像度に起因するものである。一方、目標軌道の変更後では、両者の制御誤差値には、明確な差がある。一つは、図5の、単層逆モデルを利用した場合には、目標軌道変更直後に急激な制御誤差の上昇が見られるのに対して、図7のMLIMMRを利用した場合にはそれは見られない。また、図6の単層逆モデルを利用した場合と図8のMLIMMRを利用した場合とでは、MLIMMRを利用した場合のほうが制御誤差は小さい。この結果は、MLIMMRの下層モデルの補間によって、未経験の目標速度を入力された場合の出力値の誤差が小さく押さえられていることを示す。すなわち、学習開始から30秒までの間に与えられた目標軌道上でのみの学習に限っては、単層逆モデルとMLIMMRの場合とで同様の性能が出ているが、逆モデルの




図5 単層逆モデルを利用した場合の学習履歴 (学習開始後30秒で周期を短くした場合)




図6 単層逆モデルを利用した場合の学習履歴 (学習開始後30秒で周期を長くした場合)

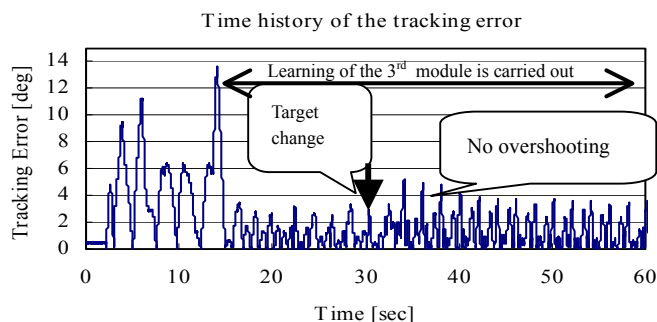


図7 多重解像度逆モデルを利用した場合の学習履歴 (学習開始後 30 秒で周期を短くした場合)

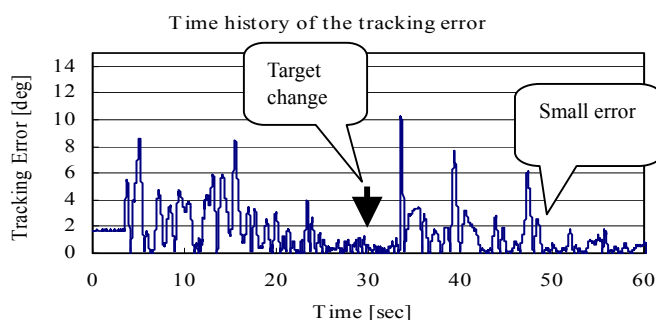


図8 多重解像度逆モデルを利用した場合の学習履歴 (学習開始後 30 秒で周期を長くした場合)




図9 フィードバック制御と多重解像度逆モデルを利用したフィードフォワード制御を併用した場合のモータ制御結果




図10 フィードバック制御と多重解像度逆モデルを利用したフィードフォワード制御を併用した場合のモータ制御誤差

状態空間内で適切な学習が行われた部分の広さには大きな差があったと言える。そして、このことが、目標軌道変更後の学習性能差に現れていると言える。つまり、MLIMMR の学習性能は学習プロセスの後半になるにつれて加速的に上がると言える。

4.2 制御性能検証結果

図 9 に、MLIMMR を逆モデルとした制御アルゴリズム(b)を使用した場合の、モータの傾斜運動制御結果を示す。図 9 のグラフにより、深刻なギザギザ動作なしで、追従時間差が 10ms 以内のモータの軌道追従制御が実現されていると言える。図 10 に制御誤差の履歴を示す。図 10 のグラフより、制御誤差も、0.5 度程度に押さえられていることが読み取れる。制御アルゴリズム (a) の場合より格段に制御誤差が小さいのは、フィードバック制御による補助のためである。

5. 結論

本研究では、機械学習を利用したフィードフォワード制御時における逆モデルの学習速度向上のために、多重解像度状態空間を利用した逆モデルの構成方法を提案し、その有効性の評価を多自由度超音波モータの軌道追従制御実験により行った。その結果として、以下の結論を得た。

- ① 多重解像度状態空間を利用した逆モデルを使用し、フィードバック誤差学習の手法により、逆モデルの学習を行わせた場合、単層逆モデルに比べて、学習速度の向上と、学習時の探索の不完全さに対する頑健性の向上が見られる。
- ② フィードバック制御とフィードフォワード制御を併用し、逆モデルとして多重解像度状態空間を利用した制御アルゴリズムにより、負荷付きの多自由度超音波モータの軌道追従制御において、追従時間差約 10ms で、ギザギザ動作なしの滑らかな動作を実現できる。

6. 今後の展開

今後は、多重解像度状態空間の持つ特性について、詳細な数理および実験的解析を行っていくとともに、逆モデルの学習時の探索状況に応じて、学習すべき逆モデルの階層を切り替えるための手法について研究し、さらなる制御性能の向上を図っていく予定である。

7. 謝辞

本研究で使用された多自由度超音波モータは、東京工業大学精密工学研究所上羽研究室にて製作されたものである。上羽貞行教授のご協力に厚く御礼を申し上げる。

参考文献

- [川人 1996 年] 川人光男, 脳の計算理論, 産業図書, 1996.
- [Sutton 1998 年] Reinforcement Learning –An Introduction–, R., S., Sutton, A., G., Barto, The MIT Press, 1998.
- [川野 2003 年] H. Kawano, T. Hirahara, “Three-DOF Angular Positioning Control using a Multi-DOF Ultrasonic Motor in the Pre-loaded Condition – Application to the Auditory Tele-Existence Robot “TeleHead” –”, Proc. of 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems, pp2247-2253, 2003.
- [Moody 1989 年] J., Moody, “Fast Learning in Multi-Resolution Hierarchies”, Proceedings of 2nd Annual Conference on Neural Information Processing Systems, pp.29-39, 1989.