

ニューラルネットワークによる 水圧駆動型ソフトアクチュエータの汎化軌道追従制御

Tracking Control for Generalized Trajectories of a Soft Hydraulic Actuator with Neural Network

○杉山拓, 沓澤京, 大脇大, 林部充宏

○Taku Sugiyama, Kyo Kutsuzawa, Dai Owaki, Mitsuhiro Hayashibe

東北大学

Tohoku University

キーワード : ソフトアクチュエータ (Soft Actuator), ニューラルネットワーク (Neural Network), 軌道追従制御 (Trajectory Tracking Control), 個体差補償 (Compensation for Individual Differences)

連絡先 : 〒 980-8579 仙台市青葉区荒巻字青葉 6-6-01 東北大学 工学研究科 機械・知能系共同棟 503 杉山拓, Tel.: (022)795-6970, Fax.: (022)795-6970, E-mail: taku.sugiyama.t5@dc.tohoku.ac.jp

1. 緒言

2016年時点で全世界には約8010万人の脳卒中患者がいる¹⁾。そして、その生存患者の多くが後遺症として運動機能障害を抱えている²⁾。運動機能の回復にはリハビリテーション(リハビリ)が有効であるが、それには多くの人手と手間がかかってしまう。そこで、この問題の解決のために様々なリハビリ用ロボットシステムが開発されてきた^{3),4),5),6)}。

特に近年では、ソフトアクチュエータを使用したウェアラブルなリハビリシステム^{5),6)}が広く研究されている。これらのシステムは安全性やコストの面で従来の「硬い」システムよりも優れているため、在宅リハビリの実現に大きく貢献できると目されている⁷⁾。しかしながら、システムに用いられているソフトアクチュエータには高い非線形性やヒステリシス、応答遅れ

といった特性があり、制御が難しい⁷⁾。さらに、現在ソフトアクチュエータは手作業で製作されることが多く、その場合変形特性の個体差は非常に大きくなる⁸⁾。この個体差によって正確なモデルの導出は困難になり、モデルフリー型の制御手法を使用する際も手間のかかるパラメータチューニングが必要となる。

これらの問題を解決するため、筆者らは先行研究⁹⁾において反復学習制御手法(Iterative Learning Control: ILC)¹⁰⁾を基にしたソフトアクチュエータの制御手法を提案した。そして、ソフトアクチュエータ間の個体差を補償した上で、非線形性等の問題を克服した精度の良い軌道追従制御の実現に成功した。この提案手法では、目的の動作(軌道)を繰り返し行わせることで各ソフトアクチュエータの変形特性をILCが学習し、制御を行う。そのため、異なる形状の目標軌道を実現させるには、再度反復学習を行わせる必

要がある。ここで、実際のリハビリシステムにソフトアクチュエータを用いる際、実現しなければならない軌道の種類は極めて多様になると考えられる。よって、各軌道に対して逐一反復学習を行う必要があるこの手法を実際のリハビリシステムに適用することは現実的ではない。

そこで、本研究ではフィードフォワードニューラルネットワーク (Feed-forward Neural Network: FNN) を用いて、変形特性を考慮したソフトアクチュエータの逆モデルを効率的に学習する手法を提案する。なお、本研究において逆モデルとは、目的の動作 (出力) を入力するとそれを実現するための制御入力を出力するモデルのことを指す。学習した逆モデルを用いることにより、ILCによる反復学習を行っていない、一般的な軌道の追従制御をフィードフォワードに行うことができる。訓練データとしては、上述の先行研究で提案した手法を用いて単純な軌道を追従させた時の結果を使用する。先行研究の手法では、ILCがソフトアクチュエータの変形特性を反復的に学習しつつ目的の軌道を実現する。そのため制御結果には、ILCが学習した、ソフトアクチュエータの変形特性に対してどのような制御入力をすれば目的の動作が実現できるかという情報が含まれている。したがって、この制御結果を訓練データとして用いることで、FNNは各ソフトアクチュエータによって異なる変形特性を効率的に学習することができる。また、FNNへの入力を時系列データとすることで、ソフトアクチュエータが持つ応答遅れの特性も含めて逆モデルを学習できる。リハビリシステムへの応用例があるソフトアクチュエータ (Fiber-Reinforced Soft Bending Actuator: FRSBA)⁵⁾ を水圧で駆動させて制御を行い、提案手法の有効性を検証した。




Fig. 1 FRSBA, 灰色の球体がマーカである

2. FRSBA とその個体差の補償

2.1 FRSBA

FRSBAはFluidic Elastomer Actuator (FEA) と呼ばれるソフトアクチュエータ⁷⁾の一種であり、リハビリシステムへの応用例⁵⁾がある。FEAは水圧または空圧で駆動させることができる。ここで、水は非圧縮性流体であるため水圧駆動は空圧駆動と比べてより大きな力を発生させることができる¹¹⁾。そのため、水圧駆動型のFRSBAは携行性が求められる在宅リハビリシステムに適しているといえる。よって、本研究ではリハビリシステムへの応用を念頭に水圧でFRSBAを駆動させた。

制御対象はFRSBAの根本と先端がなす角度 θ [rad]とした (Fig. 1)。FRSBAへの加圧量はポンプとの間に接続された3ポートソレノイドバルブの開度をPWM制御することで調整される。そのため、制御入力はバルブのPWMデューティ比 [%]とした。

2.2 先行研究⁹⁾の概要

ここでは、先行研究で提案した制御手法と実験結果について概説する。この手法はILCを基にしている。ILCとは制御対象に目的の動作を繰り返し行わせることで、その動作を達成するための適切な制御入力を反復的に学習していく制御手法である。反復 i 回目における制御則全体のフローチャートをFig. 2に示す。




Fig. 2 先行研究で提案した制御手法

この制御則では、まず ILC(PD 型 ILC¹⁰) が前回反復と目標軌道 $\theta_d(t)$ の情報を基に i 回目の入力量 $u_i(t)$ を算出する。ここで、制御入力 PWM デューティ比であるため、このタイミングで $u_i(t)$ が 100 以上である場合は 100 に、0 以下である場合は 0 に制限する。その後、制御入力変換関数 $f(x)$ を用いて $u_i(t)$ を変換する。そして、FRSBA の制御には変換後の入力量 $f(u_i(t))$ が使用される。なお、制御入力変換関数とは u と FRSBA が出力する角度の関係性を線形に近づけさせる関数であり、FRSBA ごとに設計される。この関数を使用することで FRSBA の非線形性を軽減し、制御性能を向上させることができる。FRSBA の出力 $\theta_i(t)$ と $u_i(t)$ は記録され、次反復における制御入力量の決定に使用される。

先行研究では 4 本の FRSBA に対して実験を行った。Fig. 3 に PWM デューティ比 100% のステップ入力に対する各 FRSBA の応答を示す。この図から、最終的な角度と過渡応答に大きな個体差があることが確認できる。Fig. 4 に上で説明した手法を用いて FRSBA の制御を行った結果 (反復 15 回目) を示す。この結果から、ILC を基にした制御手法を用いることで、個体差を補償した上で精度の良い軌道追従制御を行えることがわかる。なお、目標軌道の振幅は FRSBA ごとに異なった値となっているが、これは FRSBA が到達できる最大角度 (Fig. 3) を超えないようにその値を選択したためである。




Fig. 3 FRSBA のステップ応答




Fig. 4 先行研究における制御結果。左上の数字は対応する FRSBA 番号である。また、図中の実線は 5 回の試行の平均値を、点線は目標軌道を、薄い帯は標準偏差を表している。

3. FNN を用いた逆モデルの学習

本研究では、中間層を 1 層だけ持つシンプルな FNN を教師あり学習させ、FRSBA の逆モデルを獲得する。この逆モデルで Fig. 2 中の ILC と $f(x)$ を置き換えることで、Fig. 5A に示すように様々な種類の軌道に対して ILC による反復学習無しで追従制御を行うことができる。訓練データには、2.2 節で説明した手法を用いて FRSBA に単純な軌道を追従させた時の結果 ($f(u(t))$ と $\theta(t)$) を使用する。そのため、FNN は各ソフトウェアによって異なる変形特性を訓練データから効率的に学習することができる。




Fig. 5 (A) FNN 使用時の制御の流れ, (B) FNN の入力と出力

Fig. 5B に FNN の入力と出力に関する概略図を示す。FNN は、入力としてある時間 t とその前後一定サンプルにおける角度データを受け取る。そして、 t における PWM デューティ比 (FRSBA に対する制御入力) を出力する。入力を一定間隔の時系列データとすることで、FNN は FRSBA が持つ応答遅れの特性格も含めて逆モデルを学習することができる。FNN の入力層におけるニューロン数は、使用する FRSBA のステップ応答から算出した遅れ時間を元に設定する。一方、出力層のニューロン数は常に 1 である。なお、 $t < 0, t_{\text{end}} < t$ (t_{end} は制御終了時間) における角度は 0 として入力を行う。

4. 実験

実験装置の外観を Fig. 6 に示す。ポンプによって加圧された水は 3 ポートソレノイドバルブを介して FRSBA へと送られる。PWM 信号は PC と接続したマイコンで生成し、MOS-FET スイッチ回路を介してバルブに入力される。FRSBA の角度は、その根元と先端に取り付けられたマーカ (Fig. 1) をモーションキャプチャシステムでトラッキングし、PC で処理することで計測した。なお、FRSBA の動作速度は 1-2 Hz である⁵⁾ ため、制御周波数はその値よりも十分大きい 30 Hz とした。バルブの PWM 周波数は経験的に 50 Hz に設定した。




Fig. 6 実験装置の外観




Fig. 7 訓練データ, Fig. 8 における軌道の振幅と周波数のペア

4.1 FNN の学習

本研究では FNN に Fig. 4 中の FRSBA No. 4 の逆モデルを学習させた。この FRSBA の遅れ時間は 0.57 秒であり (Fig. 3)、制御周波数 30 Hz における約 17 サンプル分の秒数と対応している。よって、3 章で説明した様に FNN の入力層のニューロン数は 35 個に設定した。また、中間層のニューロン数は過学習を避けるために 100 個に設定した。十分な量の訓練データを集めるため、FRSBA を 2.2 節で説明した手法で制御し、様々な振幅と周波数を持つ単一正弦波軌道を追従させた。Fig. 7 に追従させた軌道の振幅と周波数のペアを示す。反復は 15 回行い、全ての結果を訓練データとして使用した。なお制御入力変換関数としては、行う処理と効果は $f(u)$ と同様だが設計がより簡易な $f_{\text{square}}(x)$ ⁹⁾ を使用した。学習率は 1.0×10^{-3} に設定し、学習は 250 epoch 行った。




Fig. 8 軌道追従制御の結果
 (A) 訓練データに含まれている目標軌道
 (B) 訓練データには含まれていない目標軌道

訓練データに含まれるノイズの影響を抑えるため、損失関数としては平均絶対誤差を使用した。最適化にはAdam¹²⁾を使用した。また、FRSBAの角度データは訓練前にカットオフ周波数0.25 Hzのローパスフィルタで処理した。

4.2 実験結果

各目標軌道に対する実験は、それぞれ同じ制御入力を用いて5回ずつ行った。結果を表す図中の実線は全試行の平均値を、薄い帯は標準偏差を表している。なお、定量的な制御性能の評価には平均二乗誤差 (RMSE) を使用した。

Fig. 8Aに、訓練データと同じ形状の単一正弦波軌道に対する制御結果を示す。またFig. 8Bに訓練データには含まれていない形状の目標軌道に対する結果を示す。これらの軌道の振幅・周波数のペアはFig. 7に示されている。どちらの場合もRMSEの値は十分小さく、精度の良い軌道追従制御が行えたことがわかる。特に、訓練データに含まれていない目標軌道に対しても




Fig. 9 複雑な軌道の追従制御結果

精度の良い制御が行えたことは特筆に値する。なお、全体的に振幅が大きくなると目標振幅に追従できずRMSEの値もやや大きくなっているが、これはFRSBAの駆動速度が物理的な限界に近くなったことが原因だと考えられる。

Fig. 9に複雑な軌道に対する制御結果を示す。この図から、訓練データに含まれていない複雑な目標軌道に対しても正確な追従制御が行えたことがわかる。興味深いことに、訓練データには正弦波状の軌道に対する制御結果しか含まれていなかったにも関わらず、ランプ・ステップ状の軌道を追従することにも成功した。

Fig. 8,9から、FNNで学習したFRSBAの逆モデルを用いることで、訓練データに含まれていない一般的な軌道の追従制御を行えることが分かる。また、FNNへの入力を時系列データとしたことで、FRSBAの応答遅れの特性も含めて逆モデルを獲得できた。以上の結果から、本研究で提案した手法の有効性を確認できる。

5. 結言

本研究ではFNNを用いてソフトアクチュエータの逆モデルを効率的に学習する手法を提案した。そして、FRSBAを用いた実験を行うことで提案手法の有効性を検証した。実験の結果、学習した逆モデルを使用することで、訓練データに含まれていない一般的な軌道の追従制御を行

える事が示された。よって提案手法を用いることで、先行研究⁹⁾の様にILCを用いた反復学習を行わずとも、様々な軌道の追従制御をフィードフォワードに行うことができるといえる。

今後の課題としては、FRSBAとは異なる種類のソフトアクチュエータに対する提案手法の有効性の検証と、あるソフトアクチュエータの逆モデルが他のソフトアクチュエータに対してどの程度汎用的かの検証が挙げられる。

参考文献

- 1) E. J. Benjamin, P. Muntner, A. Alonso, M. S. Bittencourt, C.W. Callaway, A. P. Carson, *et al.*: Heart disease and stroke statistics—2019 update: a report from the american heart association, *Circulation*, 139-10, e56/e528 (2019)
- 2) C. D. Takahashi, L. Der-Yeghiaian, V. Le, R. R. Motiwala and S. C. Cramer: Robot-based hand motor therapy after stroke, *Brain*, 131-2, 425/437 (2008)
- 3) L. Dovat, O. Lambercy, R. Gassert, T. Maeder, T. Milner, T. C. Leong, *et al.*: HandCARE: a cable-actuated rehabilitation system to train hand function after stroke, *IEEE Trans. Neural Syst. Rehabil. Eng.*, 16-6, 582/591 (2008)
- 4) C. N. Schabowsky, S. B. Godfrey, R. J. Holley and P. S. Lum: Development and pilot testing of HEXORR: Hand EXOskeleton Rehabilitation Robot, *J. NeuroEng. Rehabil.*, 7, (2010)
- 5) P. Polygerinos, Z. Wang, K. C. Galloway, R. J. Wood and C. J. Walsh: Soft robotic glove for combined assistance and at-home rehabilitation, *Rob. Auton. Syst.*, 73, 135/143 (2015)
- 6) H. Zhao, J. Jalving, R. Huang, R. Knepper, A. Ruina and R. Shepherd: A helping hand: soft orthosis with integrated optical strain sensors and EMG control, *IEEE Rob. Autom. Mag.*, 23-3, 55/64 (2016)
- 7) P. Polygerinos, N. Correll, S. A. Morin, B. Mosadegh, C. D. Onal, K. Petersen, *et al.*: Soft robotics: review of fluid - driven intrinsically soft devices; manufacturing, sensing, control, and applications in human - robot interaction, *Adv. Eng. Mater.*, 19-12, 1700016 (2017)
- 8) Z. Wang, Y. Torigoe and S. Hirai: A pre-stressed soft gripper: design, modeling, fabrication, and tests for food handling, *IEEE Rob. Autom. Lett.*, 2-4, 1909/1916 (2017)
- 9) 杉山拓, 沓澤京, 大脇大, 林部充宏: 反復学習制御によるFiber-Reinforced Soft Actuatorの個体差補償, 第38回日本ロボット学会学術講演会, #2A2-02 (2020)
- 10) 有本卓: 新版ロボットの力学と制御, 143/158, 朝倉書店 (2002)
- 11) C. Lee, M. Kim, Y. J. Kim, N. Hong, S. Ryu, H. J. Kim, *et al.*: Soft robot review, *Int. J. Control Autom. Syst.*, 15-1, 3/15 (2017)
- 12) D. P. Kingma and J. L. Ba: Adam: a method for stochastic optimization, *Int. Conf. Learn. Repr.*, (2015)