

フレキシブルアームのニューラルネットワーク制御

2019SC028 倉野優希

指導教員：陳幹

1 はじめに

本研究では、一自由度のバネとダンパを使った単純モデル [1] に対して構築する 2 自由度制御系をできるだけ簡単に作成することを目標とする。フィードフォワードコントローラに剛体モデルを用いてシステム同定をしないことによる悪影響をニューラルネットワークによって解決する。

2 モデリング

2.1 フレキシブルアーム

図 1 にフレキシブルアームの単純化モデルを示す。このモデルは、トルクがモータとつながっている Hub(ハブ)の部分のみに働き、先端部分は根元との間に繋がれたバネの力のみによって運動する。トルクを加えるとハブは θ だけ回転し、先端部分はそれより更に α だけ回転する。よって、先端部分の絶対的な角度は $\theta + \alpha$ となる。[1]




図 1 フレキシブルアームの概念図

単純化を行ったモデルに対してオイラー・ラグランジュの運動方程式を用いて、 $\ddot{\theta}, \ddot{\alpha}$ について解くことでシステムの運動方程式を得る。[1]

$$\ddot{\theta} = \frac{K_{stiff}}{J_{hub}} \alpha - \frac{B_{eq}}{J_{hub}} \dot{\theta} + \frac{1}{J_{hub}} \tau \quad (1)$$

$$\ddot{\alpha} = -\frac{K_{stiff}(J_{load} + J_{hub})}{J_{load}J_{hub}} \alpha + \frac{B_{eq}}{J_{hub}} \dot{\theta} - \frac{1}{J_{hub}} \tau \quad (2)$$

モータの仕様書と論文 [1] より入力電圧 V と負荷出力トルク τ の関係式は次のようになる。[1]

$$\tau = \frac{\eta_g \eta_m K_t K_g (V - K_m K_g \dot{\theta})}{R_m} \quad (3)$$

2.2 剛体アーム

図 2 に 2.1 章のフレキシブルアームと同様の状況における剛体アームを示す。

剛体モデルに対してフレキシブルアームと同様にモデルに対してオイラー・ラグランジュの運動方程式を用いて、 $\ddot{\theta}$ について解くことでシステムの運動方程式を得る。

$$\ddot{\theta} = -\frac{B_{eq}}{J_{Hub}} \dot{\theta} + \frac{\tau}{J_{Hub}} \quad (4)$$




図 2 剛体アームの概念図

3 2 自由度制御系

今回作成する 2 自由度制御系はフィードフォワードコントローラ内の $P_m(s)$ に対して弾性モデルを用いるものと剛体モデルを用いるものの 2 つある。 $P_m(s)$ に弾性モデルを用いた場合、システム同定を正確に行えるのでフィードフォワードコントローラだけでも良い制御性能を出すことができるが、システム同定に時間がかかる。 $P_m(s)$ に剛体モデルを用いた場合、システム同定を正確に行っていないのでフィードフォワードコントローラだけで良い制御性能を出すことはできないが、システム同定にかかる時間を減らすことができる。今回作成した 2 自由度制御系のブロック線図を図 3 に示す。




図 3 制御システムのブロック図

4 ニューラルネットワーク

ニューラルネットワークに関しては [2] のものをそのまま利用しており、今回の論文で用いる変数を用いて概要を示す。ニューラルネットワークは図 4 のような 1 入力 1 出力、中間層に 8 個のユニットを持つ 3 層のものを 2 つ作成した。剛体運動成分 θ と振動成分 α のそれぞれの目標値とシステムの出力との差分によるフィードバック誤差を学習信号とするフィードバック誤差学習をニューラルネットワークに行った。

ここで、学習信号は図 3 における fb_θ, fb_α であり、それぞれ式 (5)、式 (6) で求められる。また、ニューラルネットワークの全てのユニットの応答関数に式 (7) を用いた。ここで、 c_1 を学習率、 $T_{NN_\theta}, T_{NN_\alpha}$ をそれぞれ θ, α に関するニューラルネットワークの出力、 $H_{j_\theta}, H_{j_\alpha}$ ($j = 1, 2, 3, \dots, 8$) をそれぞれ θ, α に関するニューラルネットワークの中間




図4 ニューラルネットワークの概念図

層の j 番目ユニットの出力, $W_{\theta 1j}, W_{\alpha 1j} (j = 1, 2, 3, \dots, 8)$ をそれぞれ θ, α に関するニューラルネットワークの入力層のユニットから中間層の j 番目のユニットへの重み, $W_{\theta 2j}, W_{\alpha 2j} (j = 1, 2, 3, \dots, 8, k = 1)$ をそれぞれ θ, α に関するニューラルネットワークの中間層の j 番目のユニットから出力層ユニットへの重み, とすると $W_{\theta 1j}, W_{\alpha 1j}, W_{\theta 2j}, W_{\alpha 2j} (j = 1, 2, 3, \dots, 8)$ はそれぞれ式 (8), 式 (9), 式 (10), 式 (11) で更新される [2].

$$fb_{\theta}(k, n) = \theta_d - \theta \quad (5)$$

$$fb_{\alpha}(k, n) = \alpha_d - \alpha \quad (6)$$

$$f(x) = \frac{1}{1 + e^{-x}} - 0.5 \quad (7)$$

$$\begin{aligned} W_{\theta 1j} &= W_{\theta 1j} + \Delta W_{\theta 1j} = W_{\theta 1j} + c_1 \frac{\partial T_{NN\theta}}{\partial W_{\theta 1j}} fb_{\theta} \\ &= W_{\theta 1j} + c_1 (0.5 + T_{NN\theta})(0.5 - T_{NN\theta}) \\ &\quad (0.5 + H_{j_{\theta}})(0.5 - H_{j_{\theta}}) W_{\theta 2j} fb_{\theta} \end{aligned} \quad (8)$$

$$\begin{aligned} W_{\theta 2j} &= W_{\theta 2j} + \Delta W_{\theta 2j} = W_{\theta 2j} + c_1 \frac{\partial T_{NN\theta}}{\partial W_{\theta 2j}} fb_{\theta} \\ &= W_{\theta 2j} + c_1 (0.5 + T_{NN\theta})(0.5 - T_{NN\theta}) T_{NN\theta} fb_{\theta} \end{aligned} \quad (9)$$

$$\begin{aligned} W_{\alpha 1j} &= W_{\alpha 1j} + \Delta W_{\alpha 1j} = W_{\alpha 1j} + c_1 \frac{\partial T_{NN\alpha}}{\partial W_{\alpha 1j}} fb_{\alpha} \\ &= W_{\alpha 1j} + c_1 (0.5 + T_{NN\alpha})(0.5 - T_{NN\alpha}) \\ &\quad (0.5 + H_{j_{\alpha}})(0.5 - H_{j_{\alpha}}) W_{\theta 2j} fb_{\alpha} \end{aligned} \quad (10)$$

$$\begin{aligned} W_{\alpha 2j} &= W_{\alpha 2j} + \Delta W_{\alpha 2j} = W_{\alpha 2j} + c_1 \frac{\partial T_{NN\alpha}}{\partial W_{\alpha 2j}} fb_{\alpha} \\ &= W_{\alpha 2j} + c_1 (0.5 + T_{NN\alpha})(0.5 - T_{NN\alpha}) T_{NN\alpha} fb_{\alpha} \end{aligned} \quad (11)$$

5 シミュレーション

今回のシミュレーションでは, 学習率 c_1 は 0.003, 初期値は $[\theta \ \alpha]^T = [0.0 \ 0.0]^T [\text{rad}]$, 目標値は $[\theta_d \ \alpha_d]^T = [\frac{\pi}{2} \ 0.0]^T [\text{rad}]$ とした. $P_m^{-1}(s)$ が弾性モデルの 2 自由度制御系, $P_m^{-1}(s)$ が剛体モデルの 2 自由度制御系, ニューラルネットワークの学習 1 回目, ニューラルネットワークの学習 10 回目のそれぞれの θ, α , 理想応答, システムの応答結果を比較したものを図 5, 6, 7, 8 にそれぞれ示す.

6 おわりに

本研究では, ニューラルネットワークを用いることで 2 自由度制御系を簡略化して構築した. その後, シミュレーションによって提案した手法の検証を行った.




図5 $\theta, \alpha, \theta + \alpha, \theta + \alpha$ に関する理想応答の応答結果 ($P_m(s)$ に弾性モデルを用いた場合)




図6 $\theta, \alpha, \theta + \alpha, \theta + \alpha$ に関する理想応答の応答結果 ($P_m(s)$ に剛体モデルを用いた場合)




図7 $\theta, \alpha, \theta + \alpha, \theta + \alpha$ に関する理想応答の応答結果 (学習 1 回目)




図8 $\theta, \alpha, \theta + \alpha, \theta + \alpha$ に関する理想応答の応答結果 (学習 10 回目)

今後の課題としては, 収束性能は同程度またはこれ以上で, オーバーシュートを抑えられるニューラルネットワークの学習則を考える必要がある.

参考文献

- [1] 水戸健詞: 最適レギュレータによるフレキシブルアームの制振制御, 南山大学数理情報学部 2010 年度卒業論文 (2010).
- [2] 新井 史人・栄 莉 莉・福田 敏男: 「柔軟構造物のフレキシビリティ制御 (第 5 報, ニューラルネットワークを用いた柔軟材の位置. 姿勢制御)」. 日本機械学会文集 (C 編) 59 巻 562 号, 1993-6, pp.155-162.