柔軟構造物のフレキシビリティ制御*

(第6報, スピルオーバを考慮したニューラルネットワーク制御での 学習の漸近的収束性)

新井 史人*¹, 柴 莉 莉*², 福田 敏男*¹

Flexibility Control of Flexible Structures (6th Report, Asymptotic Convergence of Learning Process in Neural Network Controller Considering Spillover)

Fumihito ARAI, Li-li RONG and Toshio FUKUDA

This paper deals with trajectory control of a flexible plate handling system using the neural network learning method. The conditions for the asymptotic convergence of the feedback error learning method for each trial are obtained. The influence of vibration modes not modeled on the conditions for the asymptotic convergence is discussed. Based on the result, obtained here, we present a fast learning method for trajectory control of a flexible plate handling system. The control system consists of a low-pass filter and two neural networks. The learning method is to change the learning rate according to the convergence conditions. A one-joint robot handling flexible plate is simulated, and the simulation results show the effectiveness of the proposed conditions and learning method.

Key Words: Robotics, Response, Trajectory Control, Spillover, Feedback Error Learning, Flexibility, Neural Network, Asymptotic Convergence, Learning Speed Improvement

1. は じ め に

近年, フレキシブルアームと柔軟材の制御に関する研究が盛んに行われている^{(1)~(4)}. 剛体システムと違って, このような柔軟な構造をもつシステムには, 振動モードが無限個存在するため, 正確な制御モデルを得ることが困難であり, 通常は有限個モードまで考慮する方法が使われている⁽⁵⁾. このため, モデル化できない高次モードが計測装置により制御システムに入って, いわゆるスピルオーバ現象が起こる⁽⁶⁾. この現象に対して, スピルオーバがあっても, フィードバック制御だけで, システムの安定性を考慮した制御アルゴリズムが提案されている⁽⁷⁾.

一方, 最近, ニューラルネットワークはいろいろな分野で応用され, フレキシブルアームの軌道制御や, 柔軟材ハンドリングシステムの軌道制御などへの応用例が報告されてきた⁽⁸⁾⁽⁹⁾. ニューラルネットワーク制御は未知の線形システムはもとより, 未知の非線形システムにもよく適応し, 適応制御と比較した時の優位

性が示されている⁽¹³⁾.

文献(8)の中で, われわれはフィードバック誤差学習法を柔軟材ハンドリングシステムの軌道制御に応用した. フィードバック誤差学習法はフィードバックトルクを零にするように学習する方法である⁽¹⁰⁾. 柔軟材のハンドリング方法を学習している最中では, フィードバック制御入力が大きく増加することは材料をきずつける恐れがあるため好ましくない. そこで, まず, 剛体アームの軌道制御に対し, フィードバック誤差学習の漸近的収束性, つまり毎回の試行によって, フィードバックトルクが全体的に減少するための条件をわれわれは数学的に導いた⁽¹¹⁾. しかし, 柔軟材ハンドリングシステムでは, 剛体運動と振動が存在し, スピルオーバ現象もある. このようなシステムに対して, 学習の収束性はどうなるのか, また, スピルオーバ現象は学習の収束性へどのような影響を与えるのかという問題は従来より明らかでない. これらがわかれば, 精度が高く, 収束速度が速い柔軟材の軌道制御ができると考えられる.

本論文では, 柔軟材ハンドリングシステムの軌道制御に対して, フィードバック誤差学習が漸的に収束するための条件を導き, スピルオーバを考慮した上で, 学習速度を向上させる制御方法を提案する. 制御方法

* 原稿受付 平成4年5月20日.

*¹ 正員, 名古屋大学工学部 (〒464-01 名古屋市中種区不老町1).

*² 名古屋大学工学部.

は、高次モードの影響をなくすように、センサ出力にローパスフィルタをかけて、収束条件を監視しながら、学習の係数を変える方法である。この制御システムに対して、ニューラルネットワークは二つ使い、剛体運動と振動を別々に学習する。最後に、1関節をもつロボットが柔軟材を軌道制御する場合について、導いた条件式の妥当性と提案する学習方法の有効性をシミュレーションによって確かめる。

2. 問題の記述

ニューラルネットワークを使って、柔軟材をハンドリング制御するブロック図を図1に示す。図1はフィードバック誤差学習の等価ブロック線図で、この中で、 G は安定なフィードバックグループを含んだ閉ループシステムの入出力関係を表する伝達関数⁽¹¹⁾、 y はプラントの出力、 y_d は目標軌道を表す。ここで、制御には1次振動モードのみ考慮すると仮定する。 FB はフィードバックコントローラ、 T_{fb} はフィードバックトルクを表す。フィードバック誤差学習則は次の式で示される。

$$\frac{dw}{dt} = c \frac{\partial T_n}{\partial w} T_{fb} \quad \dots\dots\dots (1)$$

ここで、 w と T_n はニューラルネットワークの重みと出力、 c は学習係数である。また、

$$T_{fbr} = k_p(\theta_d - \theta) + k_v(\dot{\theta}_d - \dot{\theta}) \quad \dots\dots\dots (2)$$

$$T_{fbf} = k_{qp}(q_{1d} - q_1) + k_{qv}(\dot{q}_{1d} - \dot{q}_1) \quad \dots\dots\dots (3)$$

$$T_{fb} = T_{fbr} + T_{fbf} \quad \dots\dots\dots (4)$$

である。 θ 、 q_1 は角度と1次振動モードの時間関数を表す。また、 k_p 、 k_v 、 k_{qp} 、 k_{qv} はフィードバックトルクゲインで、システムの安定性を保証することを仮定する。

プラントの出力をある目標軌道に追従させることを目的とし、その評価関数を次式のように定義する。

$$J(n) = \frac{1}{2} \sum_{k=1}^N T_{fb}(k, n)^2 \quad \dots\dots\dots (5)$$

この中で、 N は試行1回における学習のサンプリング

総数、 n は試行回数、 k はサンプリング時刻、 $T_{fb}(k, n)$ は n 回目試行するときの k サンプリング時刻のフィードバックトルクを表す。学習が漸近的に収束するためには、次の式が成立する必要がある。

$$\begin{aligned} \Delta J &= J(n+1) - J(n) \\ &= \frac{1}{2} \sum_{k=1}^N T_{fb}(k, n+1)^2 - \frac{1}{2} \sum_{k=1}^N T_{fb}(k, n)^2 < 0 \end{aligned} \quad \dots\dots\dots (6)$$

3. フィードバック誤差学習の漸近収束性

まず、 ΔJ を計算する。

$$\begin{aligned} T_{fb}(k, n+1) &= k_p[\theta_d(k) - \theta(k, n+1)] \\ &\quad + k_v[\dot{\theta}_d(k) - \dot{\theta}(k, n+1)] \\ &\quad + k_{qp}[q_{1d}(k) - q_1(k, n+1)] \\ &\quad + k_{qv}[\dot{q}_{1d}(k) - \dot{q}_1(k, n+1)] \\ &= T_{fb}(k, n) \\ &\quad + k_p[\theta(k, n) - \theta(k, n+1)] \\ &\quad + k_v[\dot{\theta}(k, n) - \dot{\theta}(k, n+1)] \\ &\quad + k_{qp}[q_1(k, n) - q_1(k, n+1)] \\ &\quad + k_{qv}[\dot{q}_1(k, n) - \dot{q}_1(k, n+1)] \\ &= T_{fb}(k, n) + \Delta T_{fb} \end{aligned} \quad \dots\dots\dots (7)$$

すると、 ΔJ は次のように表すことができる。

$$\Delta J = \frac{1}{2} \sum_{k=1}^N (2T_{fb}(k, n) + \Delta T_{fb}) \Delta T_{fb} \quad \dots\dots\dots (8)$$

次に ΔT_{fb} を計算する。図1から次式が成立する。

$$y = y(y_d, T_n) \quad \dots\dots\dots (9)$$

$$\dot{y} = \dot{y}(y_d, T_n) \quad \dots\dots\dots (10)$$

$$T_n = T_n(y_d, w) \quad \dots\dots\dots (11)$$

図2に示すように、 k 時刻に、ニューラルネットワークの理想重みを w_d 、理想出力を T_{dk} とすると、次の2式が成立する⁽¹¹⁾。

$$\begin{aligned} y(k, n) - y(k, n+1) &= \frac{\partial y}{\partial T_n} (T_n(k, n) - T_n(k, n+1)) \quad \dots\dots\dots (12) \end{aligned}$$

$$\begin{aligned} T_n(k, n) - T_n(k, n+1) &= \frac{\partial T_n}{\partial w} (w(k, n) - w(k, n+1)) \\ &= -\frac{\partial T_n}{\partial w} \sum_{j=k}^{N+k-1} \left(c \frac{\partial T_n}{\partial w} T_{fb} \right)_j \quad \dots\dots\dots (13) \end{aligned}$$

式(13)を(12)に代入すると、

$$\begin{aligned} y(k, n) - y(k, n+1) &= -c \frac{\partial y}{\partial w} \sum_{j=k}^{N+k-1} \left(\frac{\partial T_n}{\partial w} T_{fb} \right)_j \quad \dots\dots\dots (14) \end{aligned}$$

が求まり、同じように、

$$\begin{aligned} \dot{y}(k, n) - \dot{y}(k, n+1) &= -c \frac{\partial \dot{y}}{\partial w} \sum_{j=k}^{N+k-1} \left(\frac{\partial T_n}{\partial w} T_{fb} \right)_j \quad \dots\dots\dots (15) \end{aligned}$$

図1 フィードバック誤差学習の等価ブロック線図

が求められる。

上の二つの式を式(8)に代入して整理すると、 ΔJ は次のように求められる。

$$\begin{aligned} \Delta J = & c \sum_{k=1}^N \left[\left(T_{fb} \frac{\partial T_{fb}}{\partial w} \right)_k \sum_{j=k}^{N+k-1} \left(\frac{\partial T_n}{\partial w} T_{fb} \right)_j \right] \\ & + \frac{1}{2} c^2 \sum_{k=1}^N \left[\frac{\partial T_{fb}}{\partial w} \sum_{j=k}^{N+k-1} \left(\frac{\partial T_n}{\partial w} T_{fb} \right)_j \right]^2 \end{aligned} \quad (16)$$

学習が漸近的に収束するための条件は次のようになる。

$$\Delta J < 0 \quad (17)$$

式(16)を整理すると、学習が漸近的に収束するための条件は次のように書ける。

$$c^2 < - \frac{2 \sum_{k=1}^N \left[\left(T_{fb} \frac{\partial T_{fb}}{\partial w} \right)_k \sum_{j=k}^{N+k-1} \left(\frac{\partial T_n}{\partial w} T_{fb} \right)_j \right]}{\sum_{k=1}^N \left[\frac{\partial T_{fb}}{\partial w} \sum_{j=k}^{N+k-1} \left(\frac{\partial T_n}{\partial w} T_{fb} \right)_j \right]^2} c \quad (18)$$

ここで、

$$\alpha = - \frac{2 \sum_{k=1}^N \left[\left(T_{fb} \frac{\partial T_{fb}}{\partial w} \right)_k \sum_{j=k}^{N+k-1} \left(\frac{\partial T_n}{\partial w} T_{fb} \right)_j \right]}{\sum_{k=1}^N \left[\frac{\partial T_{fb}}{\partial w} \sum_{j=k}^{N+k-1} \left(\frac{\partial T_n}{\partial w} T_{fb} \right)_j \right]^2} \quad (19)$$

と定義すると、式(18)は次のように書ける。

$$c^2 < \alpha c \quad (20)$$

この式は学習の漸近的収束性を保証するものである。 r を1より小さい正数として、次の式を満足するように c を選べば、学習は漸近的に収束する。

$$c = r\alpha \quad (21)$$

4. スピルオーバーの影響

フィードバック誤差学習はフィードバックトルクを零にするように学習する方法である。上の式(20)を使って、フィードバックトルク T_{fb} を学習すると評価関数 J を漸近的に減少することができる。つまり、 α が正のとき J が減少し、 α が負になると、 c を式(21)に応じて変えて、学習を続けていく。このとき、フィード

図2 学習の概念図

バックトルク T_{fb} の中には角度の運動に関する部分 T_{fbr} と振動に関する部分 T_{fbf} があるが、 T_{fbf} 中の1次振動モード成分が正確に得られないため、近似的に q_1 を得ることになる。位置 x_s に張ったセンサの出力 $y(x_s, t)$ から q_1 は近似的に次のように得られる。

$$\begin{aligned} q_{1s} &= y(x_s, t) / \phi_1(x_s) \\ &= q_1 + \sum_{i=2}^m \frac{\phi_i(x_s)}{\phi_1(x_s)} q_i \end{aligned} \quad (22)$$

ここで、 p_{1s} は q_1 の近似値、 ϕ はモード関数、 m は考慮した振動モードの次数である。 $\dot{q}_{1s}$ は近似的に次の式で表現できるとする。

$$\begin{aligned} \dot{q}_{1s} &= \dot{q}_1 + \sum_{i=2}^m \frac{\phi_i(x_s)}{\phi_1(x_s)} \dot{q}_i \\ &= \frac{q_{1s}(t+dt) - q_{1s}(t)}{dt} \end{aligned} \quad (23)$$

すると、式(3)と(4)は次のようになる。

$$T_{fbfs} = k_{qp}(q_{1d} - q_{1s}) + k_{qv}(\dot{q}_{1d} - \dot{q}_{1s}) \quad (24)$$

$$T_{fbs} = T_{fbr} + T_{fbfs} \quad (25)$$

ここで、 T_{fbfs} と T_{fbs} は T_{fbf} と T_{fb} の近似値を表す。

q_{1s} と $\dot{q}_{1s}$ を使うと、 T_{fbs} は次のように書ける。

$$\begin{aligned} T_{fbs} &= T_{fbr} + k_{qp} \left(q_{1d} - q_1 - \sum_{i=2}^m \frac{\phi_i(x_s)}{\phi_1(x_s)} q_i \right) \\ &\quad + k_{qv} \left(\dot{q}_{1d} - \dot{q}_1 - \sum_{i=2}^m \frac{\phi_i(x_s)}{\phi_1(x_s)} \dot{q}_i \right) \\ &= T_{fbr} + T_{fbfs} + \Delta T_{fbs} \\ &= T_{fb} + \Delta T_{fbs} \end{aligned} \quad (26)$$

ここで、

$$\Delta T_{fbs} = -k_{qp} \sum_{i=2}^m \frac{\phi_i(x_s)}{\phi_1(x_s)} q_i - k_{qv} \sum_{i=2}^m \frac{\phi_i(x_s)}{\phi_1(x_s)} \dot{q}_i \quad (27)$$

である。 T_{fbs} を用いて学習を行うと、式(19)は次のようになる。

$$\alpha(T_{fbs}) = \alpha(T_{fb}) + \alpha(\Delta T_{fbs}) \quad (28)$$

この中で、 $\alpha(\Delta T_{fbs})$ は2次以上の高次モードの影響による項である。すると、式(20)は次のようになる。

$$c^2 < c(\alpha(T_{fb}) + \alpha(\Delta T_{fbs})) \quad (29)$$

式(29)は T_{fbs} が漸近的に減少することを保証するが、 $\alpha(\Delta T_{fbs})$ が存在するため、 T_{fb} が漸近的に減少する保証がない。言い換えると、式(29)にしたがって c を変えると、 T_{fbs} は減少していくが、 T_{fb} は必ず減るとは限らない。この原因で、軌道制御の追従誤差は学習するのに逆に悪くなる場合もある。柔軟材ハンドリングシステムの軌道制御では、剛体運動と振動の両方ともうまく制御する、つまり振動を押えながら目標軌道にうまく追従することが目的である。この目的を実現するためには、 T_{fb} を漸近的に減らすように学習するこ

とが望ましい。

5. スピルオーバを考慮する軌道制御

5.1 制御システムの構成 高次モードの影響を除くには、センサの出力から高次モードを除くとよい。われわれはLPF(ローパスフィルタ)を使う方法を採用した。センサの出力にLPFをかけて、 q_{1s} の中の高次モードの項を除くのである。よく知られているように、柔軟構造物をもつシステムの中に、剛体運動と振動が同時に存在する。この中で、同じ入力に対して q_1 の動きは θ と逆である。LPFをかける前では、 q_1 と $\dot{q}_1$ の近似値 q_{1s} と $\dot{q}_{1s}$ の中に2次以上のモードが入っているため、 T_{fbr} と T_{fbfs} は正反対の波形にならない[図3(a)]。こういう場合、一つのニューラルネットワークを使っても学習がうまくいく⁽¹²⁾。しかし、LPFをかけることにより、高次モードの影響がなくなり、 T_{fbr} と T_{fbfs} はほとんど正反対になった[図3(b)]。この場合、一つのニューラルネットワークで学習を行うと、学習信号 T_{fbfs} は少ない学習回数で極めて小さくなっても、 T_{fbr} と T_{fbfs} はほとんど減らない。これに対して、われわれは二つのニューラルネットワークで学習する方法を使用した。二つのニューラルネットワークは別々に T_{fbr} と T_{fbfs} を学習信号として学習し、そして、学習の係数は T_{fbr} について正、 T_{fbfs} について負とする。制御システムのブロック図を図4に示す。ここで、 T_r 、 T_f はNN1、NN2の出力である。

5.2 スピルオーバを考慮した学習アルゴリズム

ニューラルネットワークを二つ使うことによって、評価関数は次のように定義する。

(a) LPF をかける前

(b) LPF をかけた後

図3 LPFをかけた前後の T_{fbr} と T_{fbfs}

$$J_r(n) = \frac{1}{2} \sum_{k=1}^N T_{fbr}(k, n)^2 \quad (30)$$

$$J_f(n) = \frac{1}{2} \sum_{k=1}^N T_{fbf}(k, n)^2 \quad (31)$$

$$J_s(n) = J_r(n) + J_f(n) \quad (32)$$

すると、 ΔJ_s は次のようになる。

$$\begin{aligned} \Delta J_s &= \Delta J_r + \Delta J_f \\ &= \frac{1}{2} \sum_{k=1}^N (2T_{fbr}(k, n) + \Delta T_{fbr}) \Delta T_{fbr} \\ &\quad + \frac{1}{2} \sum_{k=1}^N (2T_{fbf}(k, n) + \Delta T_{fbf}) \Delta T_{fbf} \end{aligned} \quad (33)$$

また、式(12)は次のように書ける。

$$y_n - y_{n+1} = \frac{\partial y}{\partial T} (T_m - T_{r(n+1)} + T_{fn} - T_{f(n+1)}) \quad (34)$$

$$T = T_m + T_{fn} \quad (35)$$

$$T_m - T_{r(n+1)} = c_r \beta_r \quad (36)$$

$$T_{fn} - T_{f(n+1)} = c_f \beta_f \quad (37)$$

ここで、 c_r 、 c_f はNN1、NN2の学習係数、

$$\beta_r = -\frac{\partial T_r}{\partial w} \sum_{j=k}^{N+k-1} \left(\frac{\partial T_r}{\partial w} T_{fbr} \right)_j \quad (38)$$

$$\beta_f = -\frac{\partial T_f}{\partial w} \sum_{j=k}^{N+k-1} \left(\frac{\partial T_f}{\partial w} T_{fbf} \right)_j \quad (39)$$

である。すると、式(34)は次のようになる。

$$y_n - y_{n+1} = \frac{\partial y}{\partial T} (c_r \beta_r + c_f \beta_f) \quad (40)$$

上の式と式(7)を使うことにより、 ΔT_{fbr} と ΔT_{fbf} は次のように求められる。

$$\Delta T_{fbr} = -\frac{\partial T_{fbr}}{\partial T} (c_r \beta_r + c_f \beta_f) \quad (41)$$

$$\Delta T_{fbf} = -\frac{\partial T_{fbf}}{\partial T} (c_r \beta_r + c_f \beta_f) \quad (42)$$

上の二つの式と式(33)を使うと、 ΔJ_r 、 ΔJ_f と ΔJ_s が漸近的に減少する条件式は次のように求められる。

$$c_r^2 < a_1 c_r, \quad a_1 = 2P_1/Q_1 \quad (43)$$

$$c_f^2 < a_2 c_f, \quad a_2 = 2P_2/Q_2 \quad (44)$$

$$c_r^2 < a_0 c_r, \quad a_0 = 2(P_1 + P_2)/(Q_1 + Q_2) \quad (45)$$

図4 制御システムのブロック図

この中で,

$$P_1 = \sum_{k=1}^N \left(T_{fbr} \frac{\partial T_{fbr}}{\partial T} \right) (\beta_r + r_c \beta_f) \dots\dots\dots (46)$$

$$Q_1 = \sum_{k=1}^N \left[\frac{\partial T_{fbr}}{\partial T} (\beta_r + r_c \beta_f) \right]^2 \dots\dots\dots (47)$$

$$P_2 = \sum_{k=1}^N \left(T_{fbf} \frac{\partial T_{fbf}}{\partial T} \right) (\beta_r + r_c \beta_f) \dots\dots\dots (48)$$

$$Q_2 = \sum_{k=1}^N \left[\frac{\partial T_{fbf}}{\partial T} (\beta_r + r_c \beta_f) \right]^2 \dots\dots\dots (49)$$

であり, また, $r_c = c_f/c_r$ であり, T_{fbf} は LPF をかけた後の T_{fbfs} を使う。 α_0 は T_{fbr} と T_{fbf} の二乗和, α_1 は T_{fbr} の二乗和, α_2 は T_{fbf} の二乗和の変化に関連する。これに応じて, 次の二つの学習アルゴリズムが考えられる。

(1) 毎回の試行に対して, α_0 を計算して, α_0 が負になると式(45)を満足するように c_r を変える。

(2) 毎回の試行に対して, α_1 と α_2 を計算して, 一つでも負になると式(43)あるいは式(44)を満足するように c_r を変える。

今回はわれわれは剛体運動と振動を目標軌道に同時にできるだけ沿わせることを目的としたため, (2)の方法を使用した。

6. シミュレーション方法と結果

6・1 シミュレーションモデル シミュレーションモデルを図5に示す。簡単のため重力は考慮しない。柔軟材の長さは0.4メートルで, 1次固有振動数は0.97 Hzである。関節は初期値の30度から目標値の60度まで目標軌道に追従するように, また, 1次振動モードも目標軌道に追従するように制御を行うとする。整定時間は1.0秒, サンプル時間は0.005秒, ニューラルネットワークは3層である⁽⁸⁾。

6・2 シミュレーション結果1: LPFをかけてない場合 図6に示すのは一つのニューラルネットワークと式(20)を使って得た結果である。評価関数は式(5)を使った。学習係数の変化は次の式のとおりである。

図5 柔軟材ハンドリングシステム

$$c(n+1) = c(n)r \dots\dots\dots (50)$$

この場合, $J(T_{fbs})$ と α の関係は式(20)のとおりであるが, $J(T_{fb})$ と α の関係はそうではない。式(50)に従って学習をすると, $J(T_{fbs})$ が漸近的に減少していくが, $J(T_{fb})$ が増える場合もある。 $r=1.0$ のとき, つまり学習係数を変化しないとき, T_{fbs} と T_{fb} は100回学習した後, ある程度小さくなった。 $r=1.20$ のとき, 100回学習したあと, T_{fbs} はもっと小さくなったが, T_{fb} が $r=1.0$ のときと比べると, 悪くなった。これが高次モードが学習過程に対して与える影響である。

6・3 シミュレーション結果2: LPFをかけた場合

図7に示す結果の学習アルゴリズムは図6のと同じで, センサの出力にカットオフ周波数2 HzのLPFをかけた。図7からわかるように, T_{fbr} と T_{fbfs} の波形はほとんど正反対になって, 30回学習した後, $J(T_{fbs})$ は約5/1000まで減ったが, $J(T_{fbr})$ と $J(T_{fbf})$ はわずか1/10減っただけであった。このため,

図6 LPFをかけてない場合の応答

評価関数が極めて小さくなくても、追従誤差が学習前と比べ、ほとんど変わらない [図7の(a)と(b)を比較するとわかる]。これはLPFをかけたあと、高次モードの影響が少なくなり、一つのニューラルネットワークで二つの逆方向に動く変数を制御しにくいからである。

6.4 シミュレーション結果3: 本論文で提案する制御アルゴリズムによる結果 図8に示すのは本論文で提案する制御アルゴリズムによる結果である。ニューラルネットワークは二つ、学習は式(43)と(44)の中の α_1 と α_2 を、また、評価関数は式(32)の中の J_s を使った。ネットワークの重みの初期値は乱数により $-0.2 \sim 0.2$ の範囲であたえ、学習係数の初期値は $c_r = 0.5$, $c_f = -0.02$ である。 α_1 か α_2 が連続4回負になると、 c_r を収束条件式(43)と(44)を満たすように次のように変える。

$$c_r(n+1) = r c_r(n), \quad r = 1.25 \quad \dots (51)$$

図8からわかるように $J_s(T_{fb})$ と α_0 との関係も、また $J_s(T_{fbs})$ と α との関係も式(45)のとおりであり、 c_r を変えても $J_s(T_{fb})$ と $J_s(T_{fbs})$ は同じ方向に変化する。学習を続けていくと、 $J_s(T_{fb})$ は漸次的に減少していく。また、ニューラルネットワークを二つ使うことにより、LPFによる影響があっても、 J_r と J_f は学習につれて減少する。これによって、剛体運動と振動の追従誤差がともに小さくなって、精度の高い軌道制御が実現できるのである。図8からもわかるように、提案するNN制御により、フィードバック入力は学習後にほとんど零になり、逆システムに近い物がNNに生成されたと考えられる。ここで、近いと表現した理由は1次振動モード成分 q_1 が実際には正確に得られないため、フィードバック信号に q_1 の近似値である q_{1s} を用い、 q_{1s} が零になるように学習している限り、完全な逆システムは作成できない。ただし、図8を

見る限りでは誤差はほとんど零に収束し、実用上は問題ないと考えられる。さらに高速アクセス運動を考えると場合には高次モードの励振が大きくなり、高次モー

(a) LPF をかけた場合の応答(学習前)

(b) LPF をかけた場合の応答(学習後)

図7 一つのニューラルネットワークで制御した場合

図 8 提案した学習方法による応答

でも積極的に制御する必要があると考えられる。

制御も含めて検討したい。

7. 終 り に

本論文において、柔軟材ハンドリングシステムの軌道制御をスピルオーバーを考慮したニューラルネットワークの学習によって行うことについて検討した。毎回の学習を通して、フィードバックトルクを要素とした評価関数が漸的に減少するための条件を導いた。高次モードの存在によるスピルオーバー現象が学習の収束へ及ぼす影響について明らかにした。ローパスフィルタをかけて、二つのニューラルネットワークと漸近収束するための条件式を使うことにより、精度の高い軌道制御をする方法を提案した。そして、シミュレーションにより、導いた条件式の妥当性を確かめ、提案した学習方法の有効性を確認した。今後は高次モードの

文 献

- (1) 福田・荒川, フレキシブルロボットアームの制御(第2報), 機論, 53-488, C(1987), 954-961.
- (2) 吉川・村上・細田, 2本のフレキシブルリンクを有する3自由度マニピュレータのモデリングと制御, 日本ロボット学会誌, 9-1(1991), 1-10.
- (3) 新井・福田, 柔軟構造物のフレキシビリティ制御(第3報), 機論, 56-532, C(1990), 3279-3286.
- (4) 新井・福田・細田, 柔軟構造物のフレキシビリティ制御(第4報), 機論, 57-538, C(1991), 1936-1943.
- (5) 嘉納, フレキシブルアームの分布定数系モデル, 日本ロボット学会誌, 6-5(1988), 430-435.
- (6) Balas, M.J., Active Control of Flexible Systems, *J. Opt. Theory Appl.*, 25-3(1978), 415.
- (7) 嘉納, 集中と分布一近似モデリングの方法, 計測と制御, 26-11(1989), 968-976.
- (8) 新井・栄・福田, 柔軟構造物のフレキシビリティ制御(第5

- 報), 機論, 59-562, C(1993), 1757.
- (9) Cheng, W. and Wen, J. T., A Neural Controller for the Tracking Control of Flexible Arms, *IEEE Int'l conf. on Neural Networks*, 2(1993), 749-754.
- (10) 川人・宇野・鈴木, 随意運動における適応と学習 2, 日本ロボット学会誌, 6-3(1988), 222-230.
- (11) Arai, F., Rong, L. L. and Fukuda, T., Asymptotic Convergence of Feedback Error Learning Method and Improvement of Learning Speed, *IEEE/RSJ Int'l conf. on Intelligent Robots and Systems (IROS)*, 2(1993), 761-767.
- (12) Arai, F., Fukuda, T., Tanaka, T. and Shibata, T., Hierarchical Control System for Flexible Materials Handling Robots Using Neural Networks, *IEEE/RSJ Int'l conf. on Intelligent Robots and Systems (IROS)*, 1(1992), 534-541.
- (13) Saerens, M., Soquet, A., ほか2名, Some Preliminary Comparisons Between a Neural Adaptive Controller and Model Reference Adaptive Controller, *Neural Networks in Robotics* (George, A. B. and Kenneth, Y. G., ed.), (1993), 131-146, Kluwer Academic Publishers.
-