

別刷

計測自動制御学会 論文集

年 第 卷 第 号

---

(P. ~P. )

*To my adviser professor Toshio Tsuji.*

*for his direction and support*

---

*Bing Hong Xu*

*May 11, 1996*



社団法人 計測自動制御学会

# ニューラルネットを利用したモデル化誤差を含むプラントの同定と制御

徐 炳 鴻\*・辻 敏 夫\*・金 子 真\*

Identification and Control for a Class of Plant with Uncertainties Using Neural Network

Bing Hong XU\*, Toshio TSUJI\* and Makoto KANEKO\*

For a class of continuous time plant with uncertainties, a new control system that integrates plant identification and feedback control by using neural network is presented in this paper. In the proposed control system, an identification model based on a neural network (NN) is connected in parallel with a plant model. The NN can identify the plant uncertainties and can modify a control signal to the plant for overcoming effect of the uncertainties simultaneously. By the Lyapunov stability techniques, stability analysis of the proposed control system is shown and a sufficient condition of the asymptotical stability is derived in case of a linear plant. Computer simulations are performed to illustrate the effectiveness and applicability of the proposed control system to a variety of continuous time plants with linear and nonlinear uncertainties.

**Key Words:** neural network, identification model, control system design, back-propagation learning, feedback control system

## 1. ま え が き

ニューラルネットワーク(以下、NNと略記)を制御問題へ応用する試みは、コントローラのパラメータを適応的に調節し、制御性能を目標の仕様に適合させるための1つの優れた制御手法として近年ブームを引き起こし、多くの研究が報告されている<sup>1)~7)</sup>。これまでNNをフィードバック制御系へ応用する構成は、おおむねつぎの3つのタイプに分けられる<sup>1)</sup>。すなわち、1)フィードバックコントローラをNNで完全に置換する直列型<sup>2), 3)</sup>、2)フィードバックコントローラと並列にNNを配置し、NNの出力がフィードバックコントローラによって得られた操作量を補正する並列型<sup>4), 5)</sup>、3)フィードバックコントローラのパラメータをNNで調整するセルフチューニング型<sup>6), 7)</sup>である。直列型は制御系の構成が単純で、さまざまなフィードバック制御系に直接適用することができるが、NNが系の安定性に重大な影響を与えるため、そのロバスト性に疑問が残る。一方、並列型

ではフィードバックコントローラの働きによりNNの学習時にみられる不安定性をある程度、回避することができるが、NNと学習に必要な出力誤差の間に未知の制御対象が存在するため、多大な計算時間や学習時間が必要となる。また、セルフチューニング型は制御系のゲインを調節して従来のフィードバック系の制御性能を改善することができるが、直列型の場合と同様に制御系の安定性を保証することは難しい。

本論文では、上述の並列型とセルフチューニング型に基づいたNNを利用した新しい制御系を提案する。本手法では、あらかじめわかっているプラントモデルとそれに並列に配置したNNを用いて同定モデルを構成し、このNNによってプラントのモデル化誤差を同定する。同時に、プラントモデルに対してあらかじめ設計したフィードバックコントローラからの操作量をこのNNの出力に基づいて適応的に補正する。NNには階層型を使用し、同定モデルの出力とプラントの出力との同定誤差からNNの重みを修正する。これにより、モデル化誤差を含むプラントの同定と制御を同時に実現することができる。本論文では、線形システムに対しては提案した制御系の漸近安定性についての十分条件を導出できることを示すとともに、線形、非線形のモデル化誤差を含むプ

\* 広島大学工学部 東広島市鏡山1-4-1

\* Faculty of Engineering, Hiroshima University,  
Kagamiyama, Higashi-Hiroshima  
(Received September 18, 1995)  
(Revised November 8, 1995)

ラントに対してシミュレーション実験を行い、本手法の有効性を検証する。

## 2. 問題の定式化

本論文では、1入力1出力の連続時間系を取り扱う。ただし、制御対象としては乗法的なモデル化誤差  $\Delta_H(p)$  を含むプラント  $H(p)$  を考える<sup>8)</sup>。

$$y(t) = H(p)u(t) \quad (1)$$

$$H(p) = H_n(p)[1 + \Delta_H(p)] \quad (2)$$

$$H_n(p) = \frac{B(p)}{A(p)} \quad (3)$$

$$\Delta_H(p) = \frac{\Delta_B(p)}{\Delta_A(p)} \quad (4)$$

ここで、 $A(p) = a_n p^n + a_{n-1} p^{n-1} + \dots + a_1 p + a_0$ 、 $B(p) = b_m p^m + b_{m-1} p^{m-1} + \dots + b_1 p + b_0$  ( $n \geq m$ ) で、

$$\Delta_A(p) = 1 + \sum_{j=1}^h \alpha_j p^j \quad (5)$$

$$\Delta_B(p) = \sum_{i=0}^l \beta_i p^i \quad (h \geq l) \quad (6)$$

とする。 $p$  は微分オペレータ  $p = d/dt$ 、 $H_n(p)$  はプラントモデル (ただし、 $H_n^2(p) \in RH_\infty$  はプロパーで安定な有理関数<sup>9)</sup>とする)、 $u(t)$  と  $y(t)$  はそれぞれ制御対象の入力と出力である。また、多項式  $A(p)$ 、 $B(p)$  は既知、プラントモデル  $H_n(p)$  はフィードバックコントローラ  $G_n(p)$  によって可制御で、モデル化誤差に対応する多項式  $\Delta_A(p)$ 、 $\Delta_B(p)$  の係数  $\alpha_j$  ( $j = 1, \dots, h$ )、 $\beta_i$  ( $i = 0, \dots, l$ ) および次数  $l$  ( $l \leq n$ )、 $h$  ( $h \leq m$ ) は未知である。

Fig. 1 に一般的なフィードバック制御系の構成を示す。 $r(t)$  は目標値、 $e(t) = r(t) - y(t)$  は目標値とプラントの出力との偏差である。プラントモデル  $H_n(p)$  とコントローラ  $G_n(p)$  を用いた閉ループ連続時間伝達関数<sup>10)</sup>  $F_n(p)$  は

$$F_n(p) = \frac{y(t)}{r(t)} = \frac{G_n(p)H_n(p)}{1 + G_n(p)H_n(p)} \quad (7)$$

となる。コントローラ  $G_n(p)$  はプラントモデル  $H_n(p)$  に対して望ましい制御応答が得られるように設計される<sup>11)</sup>。




Fig. 1 Block diagram of feedback control system

ここで、モデル化誤差を含むプラント  $H(p)$  に対するコントローラ  $G(p)$  をつぎのように定義する。

$$G(p) = G_n(p)[1 + \Delta_G(p)] \quad (8)$$

ただし、 $\Delta_G(p)$  はコントローラ  $G(p)$  の修正量である。このとき、プラント  $H(p)$  とコントローラ  $G(p)$  を用いた閉ループ連続時間伝達関数  $F(p)$  は

$$F(p) = \frac{G(p)H(p)}{1 + G(p)H(p)} \quad (9)$$

になる。したがって、(9) 式と (7) 式を等価にすることができれば、コントローラ  $G(p)$  によるプラント  $H(p)$  の応答を望ましい制御系の応答に一致させることができる。(9) 式と (7) 式を等しく置くと、

$$G_n(p)H_n(p) = G_n(p)[1 + \Delta_G(p)]H_n(p)[1 + \Delta_H(p)] \quad (10)$$

となり、上式からつぎの関係式が得られる。

$$\Delta_G(p) = -\frac{\Delta_H(p)}{1 + \Delta_H(p)} \quad (11)$$

しかしながら、モデル化誤差  $\Delta_H(p)$  は未知なので、コントローラ  $G_n(p)$  の制御対象に対する許容誤差範囲を超えれば、制御系の制御性能が悪化したり、定常偏差を生じたり、あるいは制御系が不安定になったりする恐れがある。次節では、この問題を解決するために、NN をプラントのモデル化誤差に対する同定器およびコントローラ  $G(p)$  の補償器として利用した新しい制御系を提案する。

## 3. 提案する制御系の構成

Fig. 2 は本論文で提案する制御系の構成を示したものである。Fig. 2 では、NN がプラントモデル  $H_n(p)$  と並列に配置され、NN の出力  $y_{NN}(t)$  が  $H_n(p)$  を通じた推定出力  $y_{ID}(t)$  とプラントモデルの出力  $y_n(t)$  との和が同定モデルの出力  $\hat{y}(t)$  となる。NN の学習は同定モデルの出力  $\hat{y}(t)$  とプラントの出力  $y(t)$  との同定誤差  $\epsilon(t)$

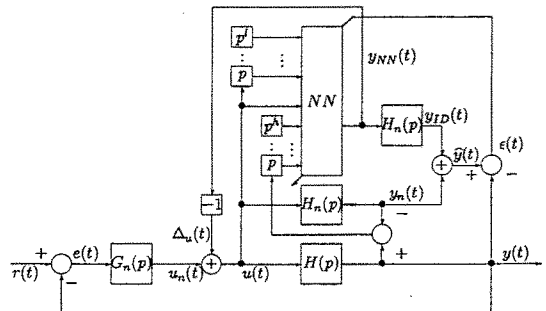


Fig. 2 Block diagram of the proposed control system using a neural network

を用いて行う。このとき、NNの出力  $y_{NN}(t)$  は操作量  $u_n(t)$  を補正する操作補正量  $\Delta_u(t)$  として用いられる。

$$\Delta_u(t) = -y_{NN}(t) \quad (12)$$

つぎに、この制御系の動作について説明する。Fig. 1と(8)式よりプラントの入力  $u(t)$  は

$$u(t) = G(p)e(t) = u_n(t) + \Delta_u(t) \quad (13)$$

となる。ただし、

$$u_n(t) = G_n(p)e(t) \quad (14)$$

$$\Delta_u(t) = \Delta_G(p)u_n(t) \quad (15)$$

である。また、(1)、(2)式からプラントの出力  $y(t)$  は

$$y(t) = y_n(t) + H_n(p)\Delta_y(t) \quad (16)$$

と与えられる。ただし、

$$y_n(t) = H_n(p)u(t) \quad (17)$$

$$\Delta_y(t) = \Delta_H(p)u(t) \quad (18)$$

である。ここで、 $\Delta_y(t)$  はモデル化誤差  $\Delta_H(p)$  に起因するプラントの出力である。また、(13)、(15)、(18)式から  $\Delta_y(t)$  は

$$\Delta_y(t) = \Delta_H(p)[1 + \Delta_G(p)]u_n(t) \quad (19)$$

と書くことができる。(15)、(19)式から  $\Delta_u(t)$  は

$$\Delta_u(t) = \frac{\Delta_G(p)}{\Delta_H(p)[1 + \Delta_G(p)]} \Delta_y(t) \quad (20)$$

となり、上式に(11)式を代入すると、

$$\Delta_u(t) = -\Delta_y(t) \quad (21)$$

を得る。

一方、Fig. 2と(16)式から同定誤差  $\epsilon(t)$  は

$$\epsilon(t) = H_n(p)[y_{NN}(t) - \Delta_y(t)] \quad (22)$$

となる。したがって、この同定誤差を最小にするようにNNを学習させ、 $\epsilon(t) = 0$  が成立したとすると、

$$y_{NN}(t) = \Delta_y(t) \quad (23)$$

を得る。このとき、(21)式が(12)式に一致することがわかる。

以上より、本論文で提案する制御系を用いれば、モデル化誤差を含む制御対象に対して望ましい制御応答を得られることが明らかになった。次節では(23)式を実現するNNについて述べる。

#### 4. ニューラルネットワークの構成

本節では、時刻  $t$  におけるNNの構成および学習アルゴリズムについて説明する。Fig. 3に、三層の階層型NNの構成を示す。入力層と中間層のユニット数はそ

れぞれ  $N$  個と  $M$  個、出力層のユニット数は1個とする。同図において、 $w_{ij}$  は入力層の  $j$  番目のユニットと中間層の  $i$  番目のユニットとを結ぶ重み、 $v_i$  は中間層の  $i$  番目のユニットと出力層のユニットとを結ぶ重みである。中間層の重みマトリクスと出力層の重みベクトルはそれぞれ  $W(t) \in R^{M \times N}$  と  $V(t) \in R^{M \times 1}$  と書くことにする。Fig. 2より、NNの入力ベクトルは  $U_{IN}(t) \in R^{1 \times N}$  は

$$U_{IN}^T(t) = [(u(t), \frac{du(t)}{dt}, \dots, \frac{d^l u(t)}{dt^l}, \frac{d\Delta_y(t)}{dt}, \dots, \frac{d^h \Delta_y(t)}{dt^h})] \\ = [u_1(t), u_2(t), \dots, u_N(t)] \quad (24)$$

で定義される。ただし、 $N = l + h + 1$  である。

入力層の  $j$  番目のユニットの出力  $I_j$  は  $I_j = u_j(t)$  ( $j = 1, \dots, N$ ) とする。一方、中間層の  $i$  番目のユニットの出力  $H_i$  は  $H_i = \sigma(s_i)$ 、 $s_i = \sum_{j=1}^N w_{ij} I_j$  で与えられる。ただし、 $\sigma(\cdot)$  はシグモイド関数である。本論文では、シグモイド関数  $\sigma(\cdot)$  として

$$\sigma(x) \equiv \frac{X_g [1 - \exp(-4x/X_g)]}{2[1 + \exp(-4x/X_g)]} \quad (25)$$

を用いることにする。 $X_g \geq 20$  の場合、 $\sigma(x)$  は線形関数に近づくことが文献3)により示されている。

同様に、出力層のユニットの出力  $O_t$  は  $O_t = \sigma(\kappa)$ 、 $\kappa = \sum_{i=1}^M v_i H_i$  となる。ここで、出力  $O_t$  はNNの出力  $y_{NN}(t)$  となる。

つぎに、(22)式の同定誤差  $\epsilon(t)$  を用いて、NNの学習のための評価関数  $J(t)$  を次式のように定義する。

$$J(t) = \frac{1}{2} \epsilon^2(t) \\ = \frac{1}{2} \{H_n(p)[y_{NN} - \Delta_H(p)u(t)]\}^2 \quad (26)$$

NNの学習は、この評価関数を重み  $w_{ij}$  および  $v_i$  に関して最小化(極小化)するように行う。誤差逆伝播学習法<sup>12)</sup>による重みの更新則は

$$V(t + \Delta t) = V(t) - \eta H_n(p) \epsilon(t) \frac{\partial y_{NN}(t)}{\partial V(t)} \quad (27)$$




Fig. 3 Neural network used in the proposed control system

$$\mathbf{W}(t+\Delta t) = \mathbf{W}(t) - \eta H_n(p)\epsilon(t) \frac{\partial y_{NN}(t)}{\partial \mathbf{W}(t)} \quad (28)$$

で与えられる。ここで、 $\Delta t$  は微小なサンプリング時間の間隔、 $\eta > 0$  は学習係数である。

### 5. 提案する制御系の安定性

本節では、プラント  $H(p)$  は線形部が支配的であり、かつ NN を三層線形 ( $X_g \geq 20$ ) として提案する制御系の漸近安定性の証明を行う。NN のユニットがすべて線形の場合、 $y_{NN}(t)$  は

$$y_{NN}(t) = \mathbf{V}^T(t)\mathbf{W}(t)U_{IN}(t) \quad (29)$$

となる。このとき、重み  $\mathbf{V}(t)$  の更新則 (27) 式は

$$\mathbf{V}(t+\Delta t) = \mathbf{V}(t) - \eta H_n(p)\epsilon(t)\mathbf{W}(t)U_{IN}(t) \quad (30)$$

で計算される。同様に、重み  $\mathbf{W}(t)$  の更新則 (28) 式は

$$\mathbf{W}(t+\Delta t) = \mathbf{W}(t) - \eta H_n(p)\epsilon(t)\mathbf{V}(t)U_{IN}^T(t) \quad (31)$$

となる。

一方、(4)、(5)、(6) 式より、(18) 式の  $\Delta y(t)$  は

$$\begin{aligned} \Delta y(t) &= \left[ \sum_{i=0}^l \beta_i p^i \right] u(t) - \left[ \sum_{j=1}^h \alpha_j p^j \right] \Delta y(t) \\ &= \boldsymbol{\theta}^T U_{IN}(t) \end{aligned} \quad (32)$$

となる。ただし、 $\boldsymbol{\theta} \in R^{N \times 1}$  は

$$\boldsymbol{\theta}^T = [\beta_0, \beta_1, \dots, \beta_l, -\alpha_1, \dots, -\alpha_h] \quad (33)$$

である。(22) 式に (29) 式と (32) 式を代入すると、

$$\begin{aligned} \epsilon(t) &= H_n(p)[\mathbf{V}^T(t)\mathbf{W}(t) - \boldsymbol{\theta}^T]U_{IN}(t) \\ &= H_n(p)\boldsymbol{\varphi}^T(t)U_{IN}(t) \end{aligned} \quad (34)$$

$$\boldsymbol{\varphi}^T(t) = \mathbf{V}^T(t)\mathbf{W}(t) - \boldsymbol{\theta}^T \in R^{1 \times N} \quad (35)$$

を得る。ここで、 $\boldsymbol{\varphi}(t)$  はパラメータ誤差を表す。

このとき、NN の学習が十分行われ、 $\epsilon^2(t) \approx 0$  が成り立つとすると、重みの更新則 (30)、(31) 式より、

$$\begin{aligned} \mathbf{V}^T(t+\Delta t)\mathbf{W}(t+\Delta t) &\approx \mathbf{V}^T(t)\mathbf{W}(t) - \eta H_n(p)\epsilon(t)[U_{IN}^T(t)\mathbf{W}^T(t)\mathbf{W}(t) \\ &\quad + \mathbf{V}^T(t)\mathbf{V}(t)U_{IN}^T(t)] \end{aligned} \quad (36)$$

が得られる。上式に (34) 式を代入すると、

$$\mathbf{V}^T(t+\Delta t)\mathbf{W}(t+\Delta t) \approx \mathbf{V}^T(t)\mathbf{W}(t) - \eta H_n^2(p) \cdot \boldsymbol{\varphi}^T(t)\mathbf{Q}(t) \quad (37)$$

$$\begin{aligned} \mathbf{Q}(t) &= U_{IN}(t)[U_{IN}^T(t)\mathbf{W}^T(t)\mathbf{W}(t) \\ &\quad + \mathbf{V}^T(t)\mathbf{V}(t)U_{IN}^T(t)] \in R^{N \times N} \end{aligned} \quad (38)$$

となる。マトリクス  $\mathbf{Q}(t)$  は非負定行列と仮定する。

Fig. 2 の制御系では、同定誤差  $\epsilon(t)$  を安定化できれば、提案する制御系の安定性を保証することができる。(34) 式より  $H_n(p)$  が可制御、 $U_{IN}(t)$  は有界な入力とする場合、同定誤差  $\epsilon(t)$  の安定性を保証するためには、パラメータ誤差  $\boldsymbol{\varphi}(t)$  が安定であることを示せばよい。

そこで、リアプノフ関数の候補としてつぎのスカラー関数  $\Phi(t)$  を考える。

$$\Phi(t) = \boldsymbol{\varphi}^T(t)\boldsymbol{\varphi}(t) \quad (39)$$

このとき、(35)、(37) 式より、

$$\begin{aligned} \boldsymbol{\varphi}^T(t+\Delta t) &= \mathbf{V}^T(t+\Delta t)\mathbf{W}(t+\Delta t) - \boldsymbol{\theta}^T \\ &= \boldsymbol{\varphi}^T(t) - \eta H_n^2(p)\boldsymbol{\varphi}^T(t)\mathbf{Q}(t) \\ &= \boldsymbol{\varphi}^T(t)[\mathbf{I} - \eta H_n^2(p)\mathbf{Q}(t)] \end{aligned} \quad (40)$$

を得る。ここで、 $\mathbf{I} \in R^{N \times N}$  は単位マトリクスである。(39)、(40) 式より、

$$\begin{aligned} \Delta \Phi &= \Phi(t+\Delta t) - \Phi(t) \\ &= \boldsymbol{\varphi}^T[\mathbf{I} - \eta H_n^2(p)\mathbf{Q}(t)] \\ &\quad \cdot [\mathbf{I} - \eta H_n^2(p)\mathbf{Q}^T(t)]\boldsymbol{\varphi}(t) - \boldsymbol{\varphi}^T(t)\boldsymbol{\varphi}(t) \\ &= -\eta H_n^2(p)\boldsymbol{\varphi}^T(t)[\mathbf{Q}(t) + \mathbf{Q}^T(t) \\ &\quad - \eta H_n^2(p)\mathbf{Q}(t)\mathbf{Q}^T(t)]\boldsymbol{\varphi}(t) \end{aligned} \quad (41)$$

である。したがって、

$$\mathbf{Q}(t) + \mathbf{Q}^T(t) - \eta H_n^2(p)\mathbf{Q}(t)\mathbf{Q}^T(t) > 0 \quad (42)$$

を満足するような学習係数  $\eta$  を選べば、 $\Delta \Phi < 0$  となり、リアプノフの定理によって提案する制御系のパラメータ誤差  $\boldsymbol{\varphi}(t)$  の局所的漸近安定性が保証できる。

そこで、つぎに (42) 式を満足する学習係数  $\eta$  の条件を導出しよう。マトリクスのノルムを用いると、(42) 式は

$$\|\mathbf{Q}(t) + \mathbf{Q}^T(t)\|_\infty \geq \eta \|H_n^2(p)\mathbf{Q}(t)\mathbf{Q}^T(t)\|_\infty \quad (43)$$

となる。 $\mathbf{Q}(t)$  は非負定行列であるから、

$$\|\mathbf{Q}(t) + \mathbf{Q}^T(t)\|_\infty = 2\|\mathbf{Q}(t)\|_\infty \quad (44)$$

が成立し<sup>13)</sup>、(43) 式は

$$\begin{aligned} 2\|\mathbf{Q}(t)\|_\infty &\geq \eta \gamma \{\|\mathbf{Q}(t)\|_\infty\}^2 \\ \frac{2}{\gamma\|\mathbf{Q}(t)\|_\infty} &\geq \eta > 0 \end{aligned} \quad (45)$$

となる。ただし、 $\gamma = \sup_{0 \leq \omega \leq \infty} |H_n^2(j\omega)|$ 、 $\|\mathbf{Q}(t)\|_\infty = \sup_{0 \leq t \leq t_f} \bar{\sigma}\{\mathbf{Q}(t)\}$  である。ここで、 $[0, t_f]$  は学習時間、 $\bar{\sigma}$  は  $\mathbf{Q}(t)$  の最大特異値とする<sup>14)</sup>。

以上の検討をまとめると、つぎの定理が存在することがわかる。

《定理1》 三層線形の NN を用いた提案する制御系の局所的漸近安定性についての十分条件は, (45) 式を満足する学習係数  $\eta$  を選ぶことである。ただし, (45) 式のマトリクス  $Q(t)$  は非負定行列とする。

つぎに, 二層線形の NN を用いた場合について, 提案した制御系の安定性を考察してみよう。二層型の NN の出力  $\tilde{y}_{NN}(t)$  は  $\tilde{y}_{NN}(t) = \tilde{V}^T(t)U_{IN}(t)$  と定義する。ただし,  $\tilde{V}(t) \in R^{N \times 1}$  は NN の重みベクトルである。このとき, つぎの定理を導くことができる。

《定理2》 二層線形の NN を用いた場合の提案した制御系の大域的漸近安定性についての十分条件は, 学習係数  $\tilde{\eta}$  がつぎの条件を満たすことである。

$$\frac{2}{\gamma \|\tilde{Q}(t)\|_{\infty}} \geq \tilde{\eta} > 0 \tag{46}$$

ここで, マトリクス  $\tilde{Q}(t) = U_{IN}(t)U_{IN}^T(t) \in R^{N \times N}$  は非負定行列とする。

(証明) この証明は定理1の証明と同様に行うことができるので, おもな式だけを説明したい。まず, 同定誤差  $\tilde{\epsilon}(t)$  を

$$\tilde{\epsilon}(t) = H_n(p)\tilde{\varphi}^T(t)U_{IN}(t) \tag{47}$$

$$\tilde{\varphi}^T(t) = \tilde{V}^T(t) - \theta^T \in R^{1 \times N} \tag{48}$$

とする。ここで,  $\tilde{\varphi}(t)$  はパラメータ誤差を表わす。(30) 式より, 重みの更新則は

$$\tilde{V}(t + \Delta t) = \tilde{V}(t) - \tilde{\eta}H_n(p)\tilde{\epsilon}(t)U_{IN}(t) \tag{49}$$

となる。リアプノフ関数の候補として,  $\tilde{\Phi}(t) = \tilde{\varphi}^T(t)\tilde{\varphi}(t)$  を用いれば, 定理1の場合と同様に漸近安定性に関する十分条件を導出することができる。

定理1では同定誤差の自乗が微小という近似式を仮定したが, 定理2ではこのような近似式は必要なく, 大域的漸近安定性を保証することができる。

### 6. シミュレーション実験

本論文で提案した手法の有効性を確認するため, 文献11)の数値例を用いて本手法を通常のフィードバック




Fig. 4 Block diagram for simulation of the proposed control system

コントローラと比較するシミュレーション実験を行った。実験に用いたプラントモデル  $H_n(p)$  は

$$H_n(p) = \frac{1}{1 + 4p + 2.4p^2 + 0.448p^3 + 0.0256p^4} \tag{50}$$

で, 部分的モデルマッチング法を用いてコントローラ  $G_n(p)$  を次式のように設計した<sup>11)</sup>。

$$G_n(p) = \frac{1.889 + 7.131p + 2.878p^2}{p} \tag{51}$$

ステップ状の目標入力, 矩形波状の目標入力を与えた場合のフィードバックコントローラ  $G_n(p)$  によるプラントモデル  $H_n(p)$  の応答波形を, それぞれ Fig. 7, Fig. 9 の実線 (図面中, DRE と略記) に示す。この応答波形がプラントモデルに対して設計された望ましい制御応答であり, 本手法の目的はプラントにモデル化誤差が含まれる場合でもこの望ましい制御応答を実現することである。

ところで, NN への入力  $U_{IN}(t)$  には微分オペレータが含まれているため ((24) 式参照), 各要素を計算することは一般にかなり難しい。そこで, 本節では  $U_{IN}(t)$  の各要素をすべて  $u(t)$  とし, NN の学習能力に期待して (24) 式に含まれる微分計算を省略した。その結果, 制御系は Fig.4 のようになる。

本手法にはいくつかのパラメータが含まれている。まず, 省略した微分計算および後述する非線形プラントへの適用を考慮して (25) 式のシグモイド関数に含まれる  $X_g$  を  $X_g = 0.85$  とし, ニューラルネットの各ユニットに十分な非線形をもたせた。また, モデル化誤差  $\Delta_H(p)$  の次数は未知なので, 可能な次数の範囲をカバーできるように最大次数を想定した。すなわち,  $h = n, l = m$  ((5), (6) 式参照) で, (24) 式より NN の入力層のユニット数は  $N = 5$  となる。中間層のユニット数は入力層と同じ  $M = 5$  とし, NN の重みの初期値には  $[-2.0, +2.0]$  の一様乱数を用いた。また, 学習係数  $\eta$  は予備実験より  $\eta = 0.06$  とした。なお, サンプリング時間は  $\Delta t = 10ms$  である。

まず, 線形のモデル化誤差を含むプラントに対して行ったシミュレーション結果を Fig. 5 に示す。用いたプ




Fig. 5 Responses for the plant  $H^1(p)$  by using the proposed method

ラントは

$$H^1(p) = \frac{1.1}{1.2 + 1.1p + 5.6p^2 + 0.48p^3 + 0.05p^4} \quad (52)$$

で、ステップ状の目標入力  $r(t)$  に対する応答である。

Fig. 5 から学習回数が増加するにつれて、プラントの応答波形が望ましい応答波形に収束していくようすがわかる。

このときの  $\gamma\sigma(t)$  ((45)式参照) の時間変化を Fig. 6 に示す。図は1回目のステップ入力学習時のもので、 $Q(t)$  の他の特異値はすべて非負であった。 $Q(t)$  はプラントへの入力  $u(t)$  を含んでいるため、 $u(t)$  が大きく変化する時刻で最大値  $\gamma\|Q(t)\|_\infty = 19.92$  をとる。 $\eta=0.06$  であるから、(45)式の十分条件が満足され、局所的漸近安定性を保証できることがわかる。もちろん、一般には正の小さな学習係数  $\eta$  を選べば、(45)式あるいは(46)式の安定性に関する十分条件を満足することができる。しかしながら、より高速に学習を進めるためには  $\eta$  は大きい方が望ましい。本論文で示した  $\eta$  の上限に関する条件式には、NNの重みやプラントへの入力が含まれており((38)式参照)、残念ながら学習前に安定性を評価することは難しい。今後は、学習中に  $\eta$  を適応的に調整する方法を検討する必要がある。

一方、Fig. 7 にモデル化誤差がない場合の  $G_n(p)$  による  $H_n(p)$  の応答(実線: DRE)、モデル化誤差を含むプラント  $H^1(p)$  を  $G_n(p)$  で制御した場合の応答(一点鎖線: FBC)、5回目のステップ入力学習時の本手法の制御結果(破線: NNC)を示す。本手法を用いれば、モデル化誤差を含むプラントに対しても、ほぼ設計したとおりの望ましい応答特性を実現できていることがわかる。




Fig. 6 Time history of the maximum singular value of  $Q(t)$




Fig. 7 Comparison of control results for the plant  $H^1(p)$

一般に NN を利用したフィードバック制御では、重みの初期値の設定法にシステムの制御性能が大きく依存する場合が多い。学習が十分進んでいない段階では、前節で示した局所的な漸近安定性も必ずしも保証されない。そこで、NNの重みの初期値によって系の制御性能がどのように変化するか調べた。NNの重みの初期値を与える際に用いた一様乱数の範囲  $[-a, a]$  とプラントの出力の自乗偏差の積分値 (1.0 秒間)  $E$  の関係で、いずれも 10 種類の重みの初期値による 10 回目のステップ入力学習時の平均値と標準偏差である。乱数の範囲が Fig. 8 は、大きくなるにしたがって、偏差が増加し、標準偏差も拡大するが、十分小さな初期値から学習を開始した場合には、常に偏差がほぼ 0 となっていることがわかる。

Fig. 9 にプラントの特性を

$$H^2(p) = \frac{1.45 + 0.25p + 0.05p^2}{0.75 + 3.2p + 1.92p^2 + 0.35p^3 + 0.025p^4} \quad (53)$$

とした場合の矩形波入力 (1.0 秒間) に対する制御結果を示す。 $H^2(p)$  はパラメータのモデル化誤差を含むだけでなく、分子の多項式の次数もプラントモデル  $H_n(p)$  に比べて大きくなっている。フィードバックコントローラ  $G_n(p)$  による応答波形 (図中、FBC) には振動がみられるが、本手法の制御結果 (第 5 回目の矩形波学習時) は望ましい応答波形にはほぼ一致していることがわかる。

つぎに、非線形のモデル化誤差を含むプラントについて本手法を適用し、その有効性を調べた。用いたプラントは




Fig. 8 Change of the control performance with the initial weight values of the NN




Fig. 9 Simulation results for the plant  $H^2(p)$




Fig. 10 Control results for the plant with nonlinear uncertainties

$$y(t) = H^1(p)u(t) + \{1 - \exp[\epsilon u(t)]\}. \quad (54)$$

で、線形部  $H^1(p)$  のモデル化誤差に加えて非線形項が存在しているため、線形のフィードバックコントローラ  $G_n(p)$  では、システムは不安定になってしまう。ここで、(54)式に含まれる  $\epsilon$  は非線形性の度合を示す指標であり、シミュレーションでは  $\epsilon = 0.01$  とした。

Fig. 10 にステップ状の目標入力に対する制御結果の一例を示す。学習の初期段階では大きな偏差がみられるが、15回目のステップ入力学習時の応答波形はプラントモデル  $H_n(p)$  に対して設計された望ましい応答波形 (Fig. 7 参照) にはほぼ一致している。前節では、線形のプラントに対して線形の NN を用いた場合の安定性を証明したが、非線形のモデル化誤差を含むプラントに対しても本手法がある程度有効であることがわかる。

## 7. むすび

本論文では、ニューラルネットワークを制御問題へ応用する1つの試みとして、プラントのモデル化誤差の同定と操作量の補正をただ1つの NN で実現する手法について提案し、その制御系の漸近安定性を解析した。そして、線形と非線形のモデル化誤差を含むプラントに対してシミュレーション実験を行い、本手法の有効性を確認した。本手法は、線形のモデル化誤差に対してはシステムの漸近安定性が保証できること、モデル化誤差を含むプラントの同定と制御を同時に実現できること、非線形のモデル化誤差を含むプラントに対しても非線形のニューラルネットワークを用いることにより適用可能であることなどの優れた性質を有している。今後は、より一般的なモデル化誤差に対して本手法を拡張するとともに、ニューラルネットワーク学習の高速化、多変数への拡張などの点について考察する必要があると考えている。

## 参考文献

- 1) 大松: ニューラルネットワークによる適応制御, 電学誌, 112-7, 503/506 (1992)
- 2) N.S.Narendra and K.Parthtsarathy: Identification and Control of Dynamics Systems Using Neural Networks, IEEE Transaction on Neural Networks, 1-1,

4 / 27 (1990)

- 3) T. Yabuta and T. Yamada: Neural Network Controller Characteristics with Regard to Adaptive Control, IEEE Trans. On Systems, Man, and Cybernetics, SMC-22-1, 170 / 176 (1992)
- 4) C.Ku and K.Y.Lee: Diagonal Recurrent Neural Networks for Dynamic Systems Control, IEEE Trans. on Neural Networks, 6-1, 144/156 (1995)
- 5) 山田, 藪田: ニューラルネットワークを用いた適応型フィードフォワードフィードバックコントローラ, 計測自動制御学会論文集, 30-19, 1234 / 1241 (1994)
- 6) W.T.Miloler, R.S.Sutton and P.J.Werbos: Neural Networks for Control, MIT Press (1990)
- 7) 松村, 大松, 植笠: ニューラルネットワークによる電気自動車実験装置の走行負荷トルク制御, 電学論C, 113-6, 430/439 (1993)
- 8) 木村, 藤井, 森: ロバスト制御, コロナ社 (1994)
- 9) 細江, 荒木: 制御系設計— $H_\infty$  制御とその応用, 朝倉書店 (1994)
- 10) K.J.Åström and B.Wittenmark: Adaptive Control, Addison-Wesley publishing Company (1989)
- 11) 北森: 制御系の設計, オーム社 (1991)
- 12) D.E.Rumelhart, G.E.Hinton and R.J.Williams: Learning Representations by Error Propagation, Parallel Distributed Processing, 1, MIT Press (1986)
- 13) A. Weinmann: Uncertain Models and Robust Control, Springer-Verlag Wien New York (1991)
- 14) M.Green and D.J.N.Limebeer: Linear Robust Control, Prentice Hall, Englewood Cliffs (1995)

## [著者紹介]

### 徐 炳 鴻 (学生会員)



1988年, 中国上海科学技術大学大学院修士課程修了。上海建築材料工業学院助手, 講師を経て, 現在広島大学大学院工学研究科 (博士課程後期) に在学中。情報工学, ニューラルネットなどの研究に従事。計測自動制御学会などの学生会員。

### 辻 敏 夫 (正会員)



1985年, 広島大学大学院工学研究科博士前期修了。同年同大学工学部助手。94年同大学助教授。92年イタリア国ジェノバ大学客員研究員。人間とロボットの運動制御, ニューラルネット, マン・マシンシステムなどの研究に従事。電気学会, 日本ロボット学会, IEEEなどの会員 (工学博士)

### 金子 真 (正会員)



1981年, 東京大学大学院工学系研究科博士課程修了。同年通産省工業技術院機械技術研究所入所。90年九州工業大学情報工学部機械システム工学科助教授。93年広島大学工学部第2類 (電気系) 教授。ロボティクスやセンサの研究に従事 (工学博士)