

別刷

計測自動制御学会 論文集

年 第 卷 第 号

(P. ~ P.)



社団 法人 計測自動制御学会

ニューラルネットに基づく適応制御を用いた フレキシブルビームのトルク制御[†]

徐炳鴻*・辻敏夫*・金子真*

Torque Control of a Flexible Beam Using Neuro-Based Adaptive Control

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

This paper presents a Neuro-Based Adaptive Control (NBAC) for torque control of a flexible beam with structural uncertainties. In the NBAC scheme, a neural network is connected in parallel with a linearized plant model, so that the neural network can be expected to identify the uncertainties included in the controlled plant. At the same time, the neural network works as an adaptive controller that can compensate effects of the unknown part of the plant. In this paper, the NBAC is applied to a torque control of a flexible beam that includes linear and nonlinear structural uncertainties caused by a contact force, a frictional force, shape and material of the beam, and so on. The comparison of the experimental results under the NBAC and other control methods illustrates the effectiveness and applicability of the NBAC.

Key Words: neural network, adaptive control, torque control of a flexible beam, stability analysis, linear and nonlinear uncertainties.

1. まえがき

最近、非線形変換、学習および並列処理などの能力を有するニューラルネットワーク（以下、NNと略記）を適応制御系へ応用する研究が活発に行われ、多くの研究報告がなされるようになってきた^{1)~9)}。例えば、Yabuta and Yamada¹⁾はフィードバック制御器をNNに置き換えたダイレクト適応制御を提案している。この方法は制御系の構成が単純であり、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という利点を有するが、NNが制御系の安定性に重大な影響を与えるので、実際のプラントに対する適用可能性に問題が残る。

一方、Akhyar and Omatsu²⁾はNNを用いてフィードバックPID制御器のゲインを適切な値にチューニングする方法を提案している。また、Carelliら³⁾はフィードバック誤差学習⁴⁾に基づいてNNをフィードフォワード制御器として用い、通常のフィードバック制御器から得られた操作量を修正することによって適応制御を実現しようという方法を提案している。Kraftら⁵⁾は従来のフィードバック制御器と並列に配置されるNNを利用して、フィードバック制御器から得られた

操作量を補償する適応制御系を提案している。これらの方法は、フィードバック制御器の働きによりNNの学習時に系全体をある程度、安定に保つことができる。しかしながら、学習が終了してプラントの逆モデルがNNとして表現されたとしても、プラントに含まれるモデル化誤差を陽に表現することはできず、プラントの順モデルが必要な場合には再度同定をやり直す必要を生じる。

Narendra and Parthasarathy⁶⁾, Iguchi and Sakai⁷⁾, Ku and Lee⁸⁾は制御対象に含まれる未知の部分を一つのNNで同定することにより順モデルを構成し、これを利用してもう一つのNNを用いた逆モデルによって制御を行うという方法を提案している。しかしながら、実際のプラントに適用するためには二つのNNを学習する必要があり、他の方法と同様、安定性や学習時間が大きな問題となる場合が多い。

これに対して、著者らは先にNNを利用したモデル化誤差を含む連続時間プラントに対する適応制御法を提案した（Neuro-Based Adaptive Control；以下、NBACと呼ぶ）⁹⁾。この手法はプラントの乗法的なモデル化誤差の同定と操作量の補正をただ一つのNNで実現でき、線形NNを用いた場合には制御系の漸近安定性を保証することができる。

本論文では、まずこのNBACを加法的なモデル化誤差を有する離散時間プラントに拡張するとともに、非線形NNの重みの最適値の近傍において漸近安定性に関する十分条件を導出する。そして次に、この方法をフレキシブルビームのトルク制御問題に応用する。

フレキシブルビームのトルク制御とは、Fig.1に示すよう

† (社)日本機械学会ロボティクス・メカトロニクス講演会'96で
発表(1996.6)

* 広島大学工学部 東広島市鏡山1-4-1

* Faculty of Engineering, Hiroshima University, Higashi-Hiroshima

(Received April 12, 1996)

(Revised October 2, 1996)

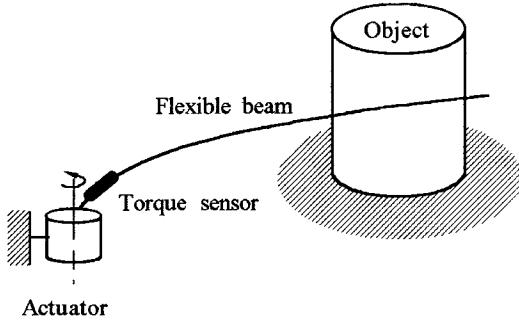


Fig. 1 Flexible beam in contact with a fixed object

に、ビームが固定対象物に接触しているとき、その対象物に対して目標とする大きさの関節トルクを加えることである。接触点の位置は関節部の能動動作によって検出することができる^{10), 11)}、関節トルクを制御することができれば対象物に加える力を制御することが可能となる。しかしながら、ビームの伝達特性は材質、形状、断面形状などによって非線形的に変化する。また、関節部から接触点までの距離により関節部で感じるビームの剛性は大きく変化するので^{10), 11)}、このフレキシブルビームの正確な動特性モデルを得ることは困難である。また、物体にビームが接触した状態でもアクチュエータはある程度回転可能であるため、減速機構の摩擦特性やビームの動特性が関節トルクに大きな影響を与える。そのため通常の適応制御では精密なトルク制御を行うことは難しい。

剛体リンクからなるロボットアームに関しては、福田らが対象物の特性を考慮した適応力制御の構成法¹²⁾を示している。また、彼らはニューラルサーボコントローラを用いたロボットマニピュレータの力制御¹³⁾を提案し、その有効性を示した。一方、フレキシブルビームに関しては、福田らは分布定数系のモデルを用いた振動抑制制御¹⁴⁾を提案している。さらに、最近ではビームの動特性を線形モデルとする仮定のもとで、モデルマッチング法、 H_∞ 制御法を活用したロバスト制御の研究が活発に行なわれている^{15)~17)}。本論文では、フレキシブルビームのトルク制御問題に対してNBACを適用し、ただ一つのNNを用いてビームの動特性を同定しながら適応的にトルク制御を実現できることを明らかにする。

2. ニューラルネットを用いた適応制御系

2.1 プラントモデル

本論文では、1入力1出力の非線形離散時間プラントを対象とし、制御対象は線形部 $H_L(z^{-1})u(k)$ と非線形部 $f(u(k))$ からなるものとする。

$$y(k) = H_L(z^{-1})u(k) + f(u(k)) \quad (1)$$

ここで、 $u(k)$ 、 $y(k)$ はそれぞれプラントの入力、出力、 $f(\cdot)$ は非線形の関数である。また、線形部は概略値モデル $H_{La}(z^{-1})$ を用いて次式のように表現する。

$$H_L(z^{-1}) = H_{La}(z^{-1}) + \Delta_{La}(z^{-1}) \quad (2)$$

ただし、 $\Delta_{La}(z^{-1})$ は $H_L(z^{-1})$ のモデル化誤差、 z^{-1} は遅れオペレータである。

さらに、(1)式で与えられた制御対象の非線形部 $f(u(k))$ を

$$f(u(k)) \approx H^*(z^{-1})u(k) \quad (3)$$

のように局所的に線形近似すると、(1)、(2)式より

$$\begin{aligned} y(k) &\approx H_{La}(z^{-1})u(k) + \Delta_{La}(z^{-1})u(k) \\ &+ H^*(z^{-1})u(k) \\ &= H(z^{-1})u(k) \end{aligned} \quad (4)$$

$$H(z^{-1}) = H_n(z^{-1})[1 + \Delta_H(z^{-1})] \quad (5)$$

$$H_n(z^{-1}) = H_{La}(z^{-1}) + H^*(z^{-1}) \quad (6)$$

$$\Delta_H(z^{-1}) = \frac{\Delta_{La}(z^{-1})}{H_n(z^{-1})} \quad (7)$$

を得る。ここで、 $H_n(z^{-1})$ はプラント全体に対する既知の概略値モデル、 $\Delta_H(z^{-1})$ はモデル化誤差で、

$$H_n(z^{-1}) = \frac{B_n(z^{-1})}{A_n(z^{-1})} \quad (8)$$

$$A_n(z^{-1}) = 1 + \sum_{j=1}^n a_j z^{-j} \quad (9)$$

$$B_n(z^{-1}) = \sum_{i=0}^m b_i z^{-i} \quad (n \geq m) \quad (10)$$

$$\Delta_H(z^{-1}) = \frac{\Delta_B(z^{-1})}{\Delta_A(z^{-1})} \quad (11)$$

$$\Delta_A(z^{-1}) = 1 + \sum_{j=1}^h \alpha_j z^{-j} \quad (12)$$

$$\Delta_B(z^{-1}) = \sum_{i=0}^l \beta_i z^{-i}, \quad (h \geq l) \quad (13)$$

とする。ただし、 $H_n(z^{-1})$ は可制御、多項式 $\Delta_A(z^{-1})$ 、 $\Delta_B(z^{-1})$ の係数 $\alpha_j (j = 1, \dots, h)$ 、 $\beta_i (i = 0, \dots, l)$ および次数 $l (\leq n)$ 、 $h (\leq m)$ は未知とする。

2.2 適応制御系の構成

Fig. 2は本論文で提案する離散時間プラントに対する

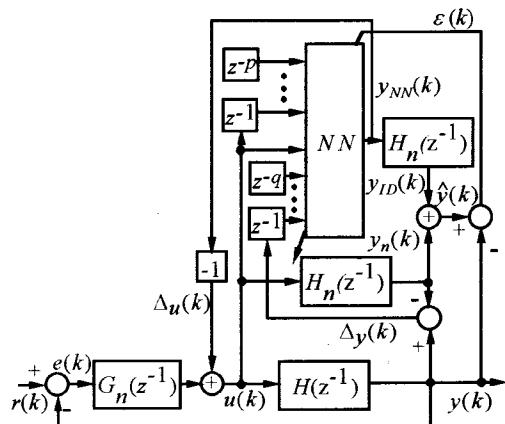


Fig. 2 Block diagram of the NBAC scheme

NBACの構成を示したものである。図中、 $r(k)$ は目標値、 $e(k) = r(k) - y(k)$ は偏差を表す。NNの出力 $y_{NN}(k)$ が $H_n(z^{-1})$ を通じた推定出力 $y_{ID}(k)$ とモデルの出力 $y_n(k)$ との和が同定モデルの出力 $\hat{y}(k)$ となる。NNの学習は同定誤差 $\epsilon(k)$ を用いて行う。このとき、入力 $u(k)$ は次式を用いて補正される。

$$\begin{aligned} u(k) &= u_n(k) + \Delta_u(k) \\ &= u_n(k) - y_{NN}(k) \end{aligned} \quad (14)$$

ただし、 $u_n(k)$ は制御器 $G_n(z^{-1})$ の出力で、 $\Delta_u(k)$ は補正入力を表す。以下、この制御系の動作について説明する。

まず、プラントにモデル化誤差が存在しない場合($\Delta_u(k) = 0$)を考えよう。モデル $H_n(z^{-1})$ に対して望ましい制御応答が得られるように設計された制御器 $G_n(z^{-1})$ を用いた直列補償系の閉ループ伝達関数 $F_n(z^{-1})$ は

$$F_n(z^{-1}) = \frac{y(k)}{r(k)} = \frac{G_n(z^{-1})H_n(z^{-1})}{1 + G_n(z^{-1})H_n(z^{-1})} \quad (15)$$

となる。一方、プラントにモデル化誤差が存在する場合($\Delta_u(k) \neq 0$)、Fig.2における制御器を

$$G(z^{-1}) = G_n(z^{-1})[1 + \Delta_G(z^{-1})] \quad (16)$$

と定義する。ただし、 $\Delta_G(z^{-1})$ は制御器の修正量を表す。このとき、プラント $H(z^{-1})$ と制御器 $G(z^{-1})$ を用いた閉ループ伝達関数 $F(z^{-1})$ は

$$F(z^{-1}) = \frac{G(z^{-1})H(z^{-1})}{1 + G(z^{-1})H(z^{-1})} \quad (17)$$

となる。(15)、(17)式を等しくすることができれば、 $G(z^{-1})$ によって $H(z^{-1})$ の出力応答を望ましい制御応答に一致させることができる⁹⁾。(15)、(17)式を等しくおくと、結局、次の関係式を得る。

$$\Delta_G(z^{-1}) = -\frac{\Delta_H(z^{-1})}{1 + \Delta_H(z^{-1})} \quad (18)$$

一方、(16)式より入力 $u(k) = G(z^{-1})e(k)$ は

$$u(k) = G_n(z^{-1})e(k) + \Delta_u(k) \quad (19)$$

$$\Delta_u(k) = \Delta_G(z^{-1})G_n(z^{-1})e(k) \quad (20)$$

と書くことができる。また、(4)式より出力 $y(k)$ は

$$y(k) = H_n(z^{-1})u(k) + H_n(z^{-1})\Delta_y(k) \quad (21)$$

$$\Delta_y(k) = \Delta_H(z^{-1})u(k) \quad (22)$$

となる。ただし、 $\Delta_u(k)$ 、 $\Delta_y(k)$ はそれぞれ入力の補正量、モデル化誤差の出力である。(19)、(20)、(22)式から

$$\frac{\Delta_u(k)}{\Delta_y(k)} = \frac{\Delta_G(z^{-1})}{\Delta_H(z^{-1})[1 + \Delta_G(z^{-1})]} \quad (23)$$

を得る。(18)式を(23)式に代入して整理すると、

$$\Delta_u(k) = -\Delta_y(k) \quad (24)$$

となる。NNの学習に用いる同定誤差 $\epsilon(k) = \hat{y}(k) - y(k)$ は、

$$\hat{y}(k) = H_n(z^{-1})[u(k) + y_{NN}(k)] \quad (25)$$

および(21)式を用いて

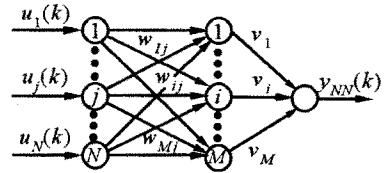


Fig. 3 Neural network used in the NBAC

$$\epsilon(k) = H_n(z^{-1})[y_{NN}(k) - \Delta_y(k)] \quad (26)$$

と変形することができるから、十分学習が進めば、 $y_{NN}(k) = \Delta_y(k)$ と期待できる。(24)、(26)式より、制御系の応答を望ましい応答((15)式)に一致させるためには、Fig.2に示すように $\Delta_u(k) = -y_{NN}(k)$ とすればよいことがわかる。

2.3 ニューラルネットの構成

Fig.3にNBACで使用する階層型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、 $w_{ij}(k)$ 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、 $v_i(k)$ 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 $W(k) \in R^{M \times N}$ と $V(k) \in R^{M \times 1}$ と書くことにする。Fig.2より、NNの入力ベクトル $U_{IN}^T(k) = [u_1(k), u_2(k), \dots, u_N(k)] \in R^{1 \times N}$ は

$$\begin{aligned} U_{IN}^T(k) &= [u(k), u(k-1), \dots, u(k-q), \\ &\quad \Delta_y(k-1), \dots, \Delta_y(k-p)] \end{aligned} \quad (27)$$

で定義される。ただし、 $p \geq h$ 、 $q \geq l$ で、 $N = p + q + 1$ である。

入力層の j 番目のユニットの出力 I_j は $I_j = u_j(k)$ ($j = 1, \dots, N$)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 $\sigma(x) \equiv \frac{1}{\gamma} \tanh(\gamma x)$ を用いることにする。ただし、 γ はシグモイド関数の形状を決める正のパラメータである。このシグモイド関数の入出力関係をFig.4に示す。図から $\gamma \leq 0.1$ のとき $\sigma(x)$ は線形関数に近づき、 $\gamma \geq 1$ のとき $\sigma(x)$ は双曲線関数の特性をもつことがわかる。同様に、出力層のユニットの出力 O_k は $O_k = \sigma(\kappa)$ 、 $\kappa = \sum_{i=1}^M v_i H_i$

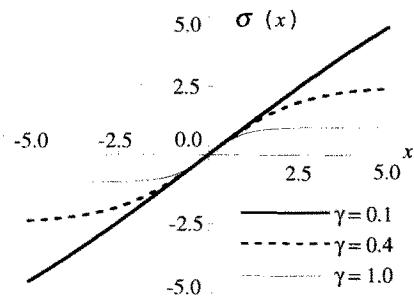


Fig. 4 Sigmoid function used in the neural network

である。

次に、同定誤差 $\epsilon(k)$ を用いて、NN の学習のための評価関数 $J(k)$ を $J(k) = \frac{1}{2}\epsilon^2(k)$ と定義する。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¹⁸⁾による重みの更新則は次式に従い 1 サンプリング時間ごとに行うものとする。

$$\mathbf{V}(k+1) = \mathbf{V}(k) - \eta H_n(z^{-1})\epsilon(k) \frac{\partial y_{NN}(k)}{\partial \mathbf{V}(k)} \quad (28)$$

$$\mathbf{W}(k+1) = \mathbf{W}(k) - \eta H_n(z^{-1})\epsilon(k) \frac{\partial y_{NN}(k)}{\partial \mathbf{W}(k)} \quad (29)$$

ここで、 $\eta > 0$ は学習係数である。

2.4 制御系の安定性について

NBAC(Fig.2)では、NN のシグモイド関数に含まれるパラメータ γ を十分小さな値に選び、かつ、プラントが線形のモデル化誤差のみを有する場合、系の漸近安定性を保証することができる⁹⁾。これは等価的に線形 NN を用いることに相当する。そこで本節では、(4)式で表される線形近似したプラントモデルを用いて、双曲線関数の特性を有する非線形 NN を用いたニューラルネットの重みの最適値の近傍における漸近安定性を示す。

多層型 NN を用いれば、同定誤差 $\epsilon(k)$ を零とする重みが存在する^{19), 20)}。この重みの最適値の近傍において、NN の出力 $y_{NN}(k)$ は

$$y_{NN}(k) \approx \varrho \mathbf{V}^T(k) \mathbf{W}(k) \mathbf{U}_{IN}(k) \quad (30)$$

のように線形近似できる。ここで、 $\varrho > 0$ はシグモイド関数の傾きを表す。

一方、(11), (22)式より、出力 $\Delta_y(k)$ は

$$\begin{aligned} \Delta_y(k) &= [\sum_{i=0}^l \beta_i z^{-i}] u(k) - [\sum_{j=1}^h \alpha_j z^{-j}] \Delta_y(k) \\ &= \boldsymbol{\theta}^T \mathbf{U}_{IN}(k) \end{aligned} \quad (31)$$

と書くことができる。ただし、パラメータ $\boldsymbol{\theta} \in R^{N \times 1}$ は

$$\boldsymbol{\theta} = [\beta_0, \beta_1, \dots, \beta_l, 0, \dots, 0, -\alpha_1, \dots, -\alpha_h, 0, \dots, 0]^T$$

である。このとき、(26)式の同定誤差は

$$\epsilon(k) = H_n(z^{-1}) \boldsymbol{\varphi}^T(k) \mathbf{U}_{IN}(k) \quad (32)$$

となる。ここで、

$$\boldsymbol{\varphi}^T(k) = \varrho \mathbf{V}^T(k) \mathbf{W}(k) - \boldsymbol{\theta}^T \in R^{1 \times N} \quad (33)$$

はパラメータ誤差を表す。

Fig.2より、同定誤差 $\epsilon(k)$ を安定化できれば、NBAC の安定性を保証することができる。(32)式から $H_n(z^{-1})$ が制御かつ $\mathbf{U}_{IN}(k)$ が有界な入力とする場合、同定誤差の安定性を保証するためには、パラメータ誤差 $\boldsymbol{\varphi}(k)$ が安定であることを示せばよい。

そこで、リアブノフ関数の候補として次のスカラー関数 $\Psi(k)$ を考える。

$$\Psi(k) = \boldsymbol{\varphi}^T(k) \boldsymbol{\varphi}(k) \quad (34)$$

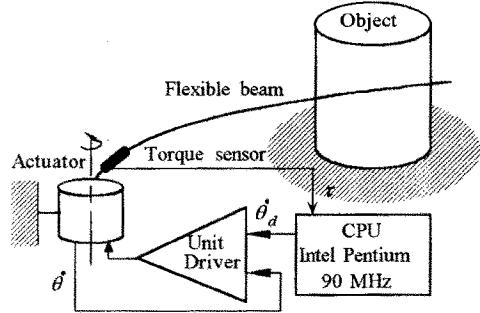


Fig. 5 Experimental setup for torque control of a flexible beam

この関数 $\Psi(k)$ の時間変化 $\Delta\Psi$ が $\Delta\Psi < 0$ となることを示すことができれば、リアブノフの定理によって提案する制御系のパラメータ誤差 $\boldsymbol{\varphi}(k)$ の漸近安定性を保証することができる。

NN の学習が十分に行われ $\epsilon^2(k) \approx 0$ が成り立つとすると、シグモイド関数を用いた多層型 NN に基づく NBAC の局所的な漸近安定性についての十分条件は、

$$\frac{2}{\varrho \zeta \|Q(k)\|_\infty} > \eta > 0 \quad (35)$$

$$\zeta = \sup_{0 \leq \omega \leq \infty} |H_n^2(e^{-j\omega T})| \quad (36)$$

$$\|Q(k)\|_\infty = \sup_{0 \leq k \leq k_L} \bar{\sigma}\{Q(k)\} \quad (37)$$

を満足する学習係数 η を選ぶことである（証明は付録参照）。ここで、 k_L は学習時間、 T はサンプリング周期、 $\bar{\sigma}$ は $Q(k)$ の最大特異値で、 $Q(k) \in R^{N \times N}$ は

$$\begin{aligned} Q(k) &= \mathbf{U}_{IN}(k) [\mathbf{U}_{IN}^T(k) \mathbf{W}^T(k) \boldsymbol{\Omega}_1(k) \mathbf{W}(k) \\ &\quad + \mathbf{V}^T(k) \boldsymbol{\Omega}_2(k) \mathbf{V}(k) \mathbf{U}_{IN}^T(k)] \end{aligned} \quad (38)$$

で与えられる。対角マトリクス $\boldsymbol{\Omega}_1(k) \in R^{M \times M}$ 、 $\boldsymbol{\Omega}_2(k) \in R^{M \times M}$ の対角要素 $\omega_{1ii}(k)$ 、 $\omega_{2ii}(k)$ は

$$\omega_{1ii}(k) = \frac{\sigma'(\kappa)\sigma(s_i)}{s_i}, \quad (s_i = 0 \text{ のとき}, \omega_{1ii}(k) = 0) \quad (39)$$

$$\omega_{2ii}(k) = \sigma'(\kappa)\sigma'(s_i) \quad (40)$$

である。ただし、 $\sigma'(\cdot)$ は $\sigma(\cdot)$ の微分を表す。(35)式の条件は正の小さな学習係数を選べば、一般に満足することが可能である。

3. フレキシブルビームのトルク制御

3.1 実験装置と概略値モデル

Fig.5に、実験に用いたフレキシブルビームのトルク制御装置を示す¹¹⁾。ビームには全長 0.32m、直径 0.8mm のスチール製の丸棒を用い、トルクセンサとしてはアルミ製の薄板に半導体歪みゲージを張付けたものを用いている。ビーム先が固定対象物と接触した時、ビームの関節部に加わるトルク τ はこのトルクセンサにより測定することができる。また、本実験装置で採用した DC サーボアクチュエータコントロー

ルユニット(HS-230-05 ハーモニックドライブシステム(株)製)にはモータ制御部に速度フィードバックが組み込まれている。このため、コンピュータから指令したアナログ電圧がモータ制御への速度指令値 $\dot{\theta}_d$ に対応し、直接電流を制御することができない。本論文では、このようなシステム(制御対象)に対して電流制御を用いなくても、学習的にある程度トルク制御が可能であることを示す。

前述したように、この実験装置にはさまざまな非線形要素、未知要素が含まれており、厳密な動特性モデルを求めるることはきわめて難しい。また対象物との接触点の位置に依存して関節部で感じるビームの回転剛性は大きく変化する。関節から接触点への距離が小さい場合には関節は硬くなり、接触点が関節から離れるにつれて柔らかくなる。つまり、システムのパラメータが接触点に依存して大きく変化するのである。

ここではまず、NBACで用いる線形の概略値モデル $H_n(z^{-1})$ の同定を行った。制御用コンピュータからの出力であるフレキシブルビームの目標関節角速度 $\dot{\theta}_d$ から関節に生じるトルク τ までの伝達関数を近似的に

$$H_n(s) = \frac{K_s K_b}{s(t_s s + 1)} \quad (41)$$

のように表現する。ただし、 K_s は速度制御系のゲイン、 t_s は系の時定数、 K_b はフレキシブルビームのバネ定数である。(41)式の各パラメータのうち、ビームのバネ定数 K_b は接触点距離 L に依存して変化する。ここで、フレキシブルビームのヤング率を E 、断面2次モーメントを I とすると、 K_b は、

$$K_b \approx \frac{3EI}{L} \quad (42)$$

と近似することができる¹⁰⁾。 E 、 I はビームの材質、断面形状によって決まる定数なので、 L により K_b が大きく変化することがわかる。なお、今回使用したビームの場合は $L = 0.20\text{ m}$ のとき、 $K_b \approx 0.425\text{ Nm/rad}$ であった。なお、フレキシブルビームは実際には非線形バネ特性を有するため、(41)式には非線形同定誤差が含まれることに注意されたい。

本論文では(41)式を離散化し、離散時間プラント

$$H_n(z^{-1}) = \frac{b_1 z^{-1} + b_2 z^{-2}}{1 + a_1 z^{-1} + a_1 z^{-2}} \quad (43)$$

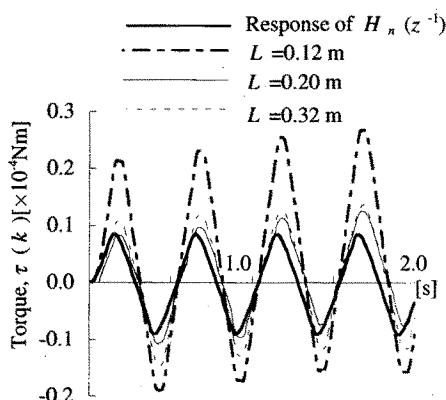


Fig. 6 Measured and predicted torques of the flexible beam

を概略値モデルとする。そして、このパラメータを同定するため、関節から $L = 0.20\text{ m}$ の点でビームを固定し、目標関節角速度を振幅 $2.0 \times 10^{-4}\text{ rad/s}$ 、周期 0.5 s の矩形波に遮断周波数 5 Hz の一次低域通過フィルタをかけて平滑化した信号として、関節トルクの時間変化を測定した(サンプリング周波数 100 Hz)。

測定結果の一例を Fig.6 に示す(図中、細線)。一方、 $L = 0.20\text{ m}$ の測定結果から(43)式のパラメータを同定し($\hat{a}_1 = -1.20296$, $\hat{a}_2 = 0.20121$, $\hat{b}_1 = 0.03063$, $\hat{b}_2 = 0.07341$)、このパラメータを用いて計算した概略値モデルの応答波形を太線に示す。制御時間が経過するにつれて実際の応答との誤差が増加することが分かる。

また同じ実験装置を用いてビームを固定する位置 L だけを変化させた場合の測定結果を同様に Fig.6 に示す。一点鎖線は $L = 0.12\text{ m}$ 、点線は $L = 0.32\text{ m}$ の場合の結果である。図から L を変えると関節トルクが大きく変化し、 $L = 0.20\text{ m}$ に対して同定した概略値モデルの応答波形(太線)とは大きく異なってしまうことが分かる。本論文では、 $L = 0.20\text{ m}$ に対して同定した概略値モデルを用いて NBAC を構成し、さまざまな L に対してトルク制御を試みた。

3.2 制御性能

実験に用いた NBAC では、NN の重みの初期値を $[-1.0 \times 10^{-3}, 1.0 \times 10^{-3}]$ の一様乱数、学習係数を $\eta = 0.05$ 、シグモイド関数のパラメータを $\gamma = 1$ と設定した。なお、モデル化誤差 $\Delta_H(z^{-1})$ の次数の範囲をカバーできるように最大次数を想定し($p = 2$, $q = 2$)、(27)式より入力層のユニット数 $N = 5$ 、中間層のユニット数 $M = 10$ とした。

制御系には目標関節角速度 $\dot{\theta}_d(k)$ として、振幅 $2.0 \times 10^{-4}\text{ Nm}$ 、周期 5 s の矩形波を与え、制御器 $G_n(z^{-1})$ はゲイン $G_n(z^{-1}) = 1$ とした。そして、 $L = 0.12\text{ m}$, 0.16 m , 0.20 m , 0.24 m , 0.28 m , 0.32 m の 6 種類の条件に対して NBAC を試みた。なお、制御時間はそれぞれ 100 s とした。Fig.7 ~ 9 に実験結果の一例を示す。Fig.7 は $L = 0.20\text{ m}$ 、Fig.8 は $L = 0.12\text{ m}$ 、Fig.9 は $L = 0.32\text{ m}$ の場合の結果で、いずれも破線が $G_n(z^{-1})$ のみを用いた場合(FBC)、細線がモデル規範型適応制御(ここでは MRAC と呼ぶ)²¹⁾、太線が NBAC を用いた場合の制御結果である。Fig.7 の $L = 0.20\text{ m}$ の場合には、概略値モデルの同定に用いた L と実際の接触点の位置が一致するため、FBC, MRAC と NBAC との結果の間に大きな差異は見られない。しかし、 L が異なる場合にはモデル化誤差が存在するので、FBC の結果には大きなオーバーシュートや過減衰が見られる。一方、MRAC は線形のモデル化誤差に対しては有効なので、制御結果は FBC より改善されている。これに対して NBAC では、線形、非線形のモデル化誤差に NN が適応し、かなり安定した制御結果が得られている。いずれの場合も、概略値モデルとして $L = 0.20\text{ m}$ で同定したパラメータを用いていることに注意されたい。Fig.10 に制御時間 90 s から 100 s の間の平均 2 乗誤差 $E_L = (1/10) \sum_{k=9000}^{10000} e^2(k)$ を示す。黒丸印は NBAC、三角印は MRAC、白丸印は FBC

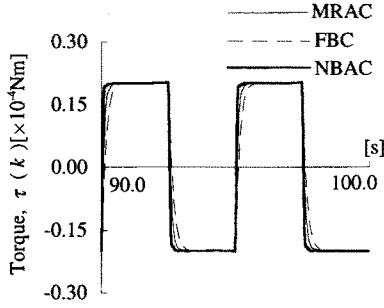


Fig. 7 Experimental results of the torque control of a flexible beam with $L=0.20\text{m}$

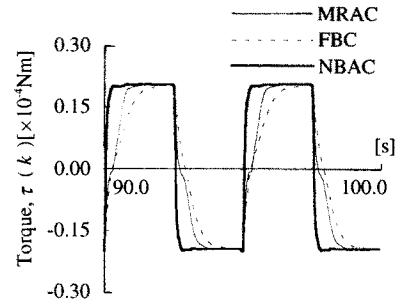
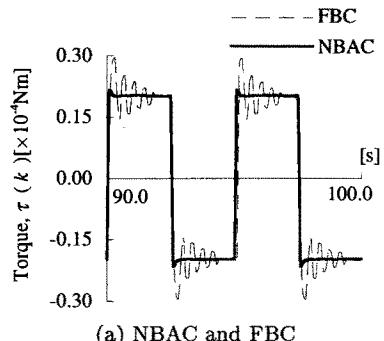
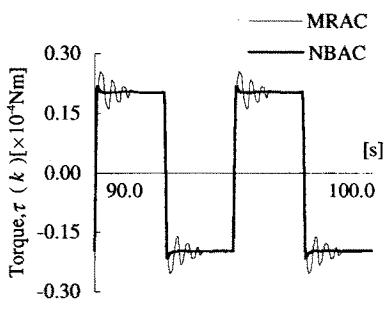


Fig. 9 Experimental results of the torque control of a flexible beam with $L=0.32$



(a) NBAC and FBC



(b) NBAC and MRAC

Fig. 8 Experimental results of the torque control of a flexible beam with $L=0.12$

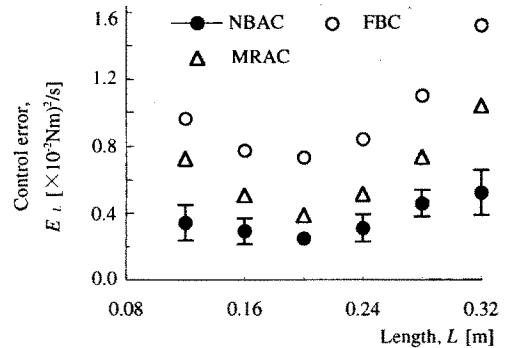


Fig. 10 Change of the control performance with the length of the beam

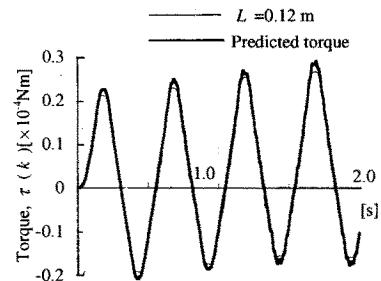


Fig. 11 Predicted torque by the NBAC

の結果で、NBAC は 10 種類の重み初期値による平均値と標準偏差を表している。 L が変化すると制御対象の特性が大きく変化し、概略値モデル $H_n(z^{-1})$ と実際の特性との間に大きな偏差が生じるにもかかわらず、NBAC による制御結果はかなり安定していることがわかる。

3.3 同定能力

NBAC の特徴は、モデル化誤差を含む制御対象を適応的に制御するだけでなく、同時に制御対象の同定モデルを学習的に構築できるという点にある (Fig.2 の $\hat{y}(k)$ 参照)。そこで、ビームの接触点位置 $L=0.12\text{m}$ に対して、制御時間が 100s 経過した NBAC (Fig.9 に相当する) を用いて同定能力を調べた。

Fig.11 は、Fig.6 と同じ目標関節角速度を用いて、 $L=0.12\text{m}$ のとき測定した関節トルク $\tau(k)$ と (25) 式から計算した同定モデルの出力 $\hat{y}(k)$ である。図より NBAC の同定モデルに

よって予測されたトルクが実際の測定値とほぼ一致していることがわかる。Fig.7~9 と同様、 $L=0.20\text{m}$ で同定した概略値モデル $H_n(z^{-1})$ を用いていることに注意されたい。すなわち、Fig.6 で見られた同定誤差が NN の学習により減少し、制御対象の同定と制御がただ一つの NN によって実現されたことが分かる。

3.4 他の手法との比較

本節では、本論文で提案した NBAC と NN を利用した他の適応制御法との比較を行った。比較のために用いた制御法はセルフチューニング型 (ここでは STNC と呼ぶ)²⁾、フィードフォワード型 (ここでは FNAC と呼ぶ)³⁾、並列型 (ここでは PNAC と呼ぶ⁵⁾) の 3 種類である。三つの制御法のプロック線図を Fig.12 に示す。なお、文献 1) の方法ではパラメータの選択がかなり難しく、安定な学習を実現できなかった。

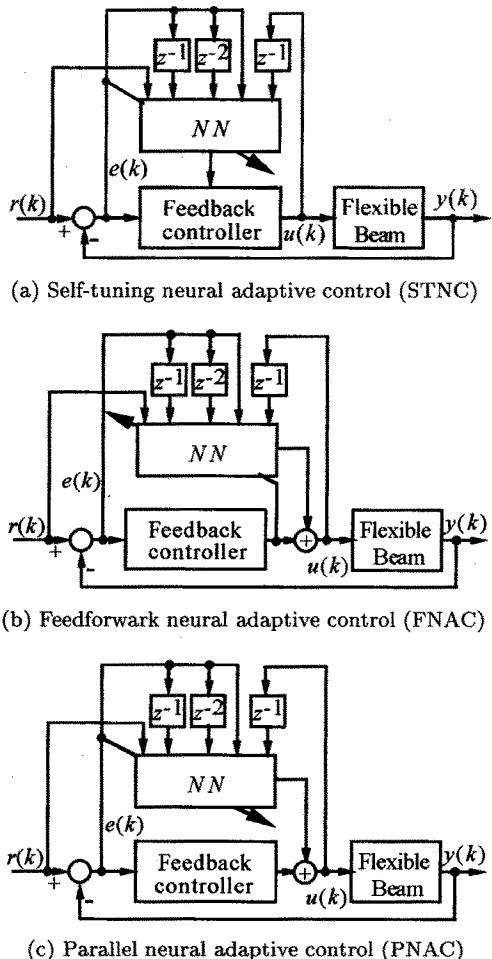


Fig. 12 Block diagrams of the adaptive control system using neural networks

なお、制御時間は60秒で、他の実験条件はすべて3.2節の条件に統一した。

Fig.13は、4種類の制御法の学習過程で、矩形波である目標関節角速度の1周期における平均二乗誤差 $E_n = (1/5) \sum_{k=1}^{500} e^2 [500(n-1) + k]$ ($n=1, 2, \dots, 12$) の変化を表している。図からNBACの学習速度が他の方法に比べて速いことがわかる。STNC, PNAC, FNACに含まれるNNが

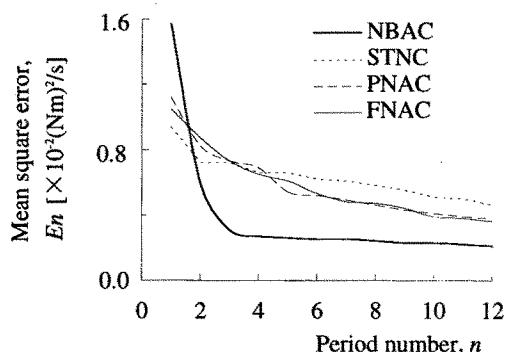


Fig. 13 Comparison of the learning history

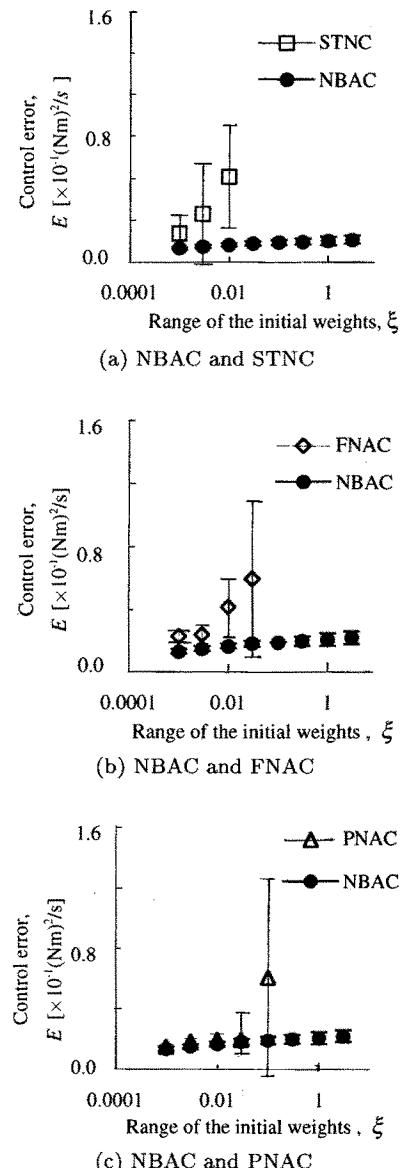


Fig. 14 Change of the control performance with the initial weights on NN

いずれもフレキシブルビームに対する適応制御器(逆モデル)を学習する必要があるに対して、NBACのNNは制御対象のモデル化誤差を学習するだけでよい。NBACでは、NNに要求される学習の負担が他の方法に比べて軽減されているのである。

このことは、NNの初期重みの選択範囲の観点からも確認できる。学習の初期段階ではNNの出力は系に対する外乱として動くので、大きなNNの出力を生じるような初期重みを設定すると系が不安定になり、学習が収束しなくなる場合がある。そこで、NNの重みの初期値によって各制御法の制御性能がどのように変化するか比較した。

Fig.14は、NNの重みの初期値を設定する際に用いた一様乱数の範囲 $[-\xi, \xi]$ と制御時間50秒～60秒の10秒間ににおける平均二乗誤差 $E = 1/2(E_{11} + E_{12})$ の関係で、いずれ

も10種類の重みの初期値による平均値と標準偏差である。STNC, FNAC, PNACでは、いずれも初期重みの範囲が大きくなるにつれて、誤差の平均値、標準偏差とも大きくなる。またSTNCでは $\xi > 0.01$, FNACでは $\xi > 0.03$, PNACでは $\xi > 0.1$ で系が不安定となり、学習が収束しなくなる。これに対してNBACではかなり大きな初期重みを用いても安定した学習が実現されている。

4. まとめ

本論文では、モデル化誤差を含む離散時間プラントに対するNBACを構成し、非線形NNの重みの最適値の近傍での漸近安定性を保証するための十分条件を導出した。次にこのNBACをフレキシブルビームのトルク制御問題へ応用し、制御対象の特性が大きく非線形的に変化した場合でもNNの学習能力によって制御が実現できることを示した。本手法はただ一つのNNでプラントの同定、制御を同時に実現することができ、フレキシブルビームのトルク制御問題のように概略値モデルの精度を高めることができ難い場合に有効である。今後は、より一般的な非線形プラント、多変数系への拡張などについて検討する必要があると考えている。最後に、実験装置の使用を快く許可いただいた九州工業研究所上野直広氏に感謝します。また、本研究の一部は(財)中国電力技術研究財団の研究助成によるもので、ここにあらためて謝意を表します。

参考文献

- 1) 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)
- 2) S. Akhyar and S. Omatsu: Self-tuning PID Control by Neural Networks, in Proceedings of International Joint Conference on Neural Networks, 2749/2752 (1993)
- 3) R. Carelli, E.F. Camacho and D. Patiño: A Neural Network Based Feedforward Adaptive Controller for Robots, IEEE Trans. On Systems, Man, and Cybernetics, SMC-25-9, 1281 / 1288 (1995)
- 4) M. Kawato, Y. Uno, M. Isobe and R. Suzuki: A Hierarchical Model for Voluntary Movement and Its Application to Robotics, IEEE Control Systems Mag., 8-2, 8/16 (1988)
- 5) L. G. Kraft, III and D. P. Campagna: A Summary Comparison of CMAC Neural Network and Traditional Adaptive Control Systems, In W. Thomas Miller, III, Richard S. Sutton, and Paul J. Werbos: Neural Networks for Control, MIT Press (1990)
- 6) K. S. Narendra and K. Parthasarathy: Identification and Control of Dynamical Systems Using Neural Networks, IEEE Trans. on Neural Networks, 1-1, 4~27, Mar.(1990)
- 7) Y. Iguchi and H. Sakai: A Nonlinear Regulator Design in the Presence of System Uncertainties Using Multilayered Neural Networks, IEEE Trans. on Neural Networks, 2-4, 4/27 (1990)
- 8) C. Ku and K.Y. Lee: Diagonal Recurrent Neural Networks for Dynamic Systems Control, IEEE Trans. on Neural Networks, 6-1, 144/156 (1995)
- 9) 徐炳鴻・辻敏夫・金子真: 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, 計測自動制御学会論文集, 32-4, 510/516 (1996)
- 10) 金子真・上野直広: 能動触角(Active Antenna)に関する基礎的研究, 日本ロボット学会誌, 13-1, 149/156 (1995)
- 11) N. Ueno, M. Kaneko and M. Svinin: Theoretical and Experimental Investigation on Dynamic Active Antenna, Proc. the IEEE Int. Conference on Robotics and Automation, 3557/3563 (1996)
- 12) 福田敏男・北村尚之・谷江和雄: 対象物の特性を考慮したロボットの力制御方式(第1報、適応力制御によるグリッパの把握動作の力制御), 日本機会学会論文集(C編), 53-487, 726/730 (1987)
- 13) 長田正俊・福田敏男: 神経回路モデルによるロボットマニピュレータの力制御(追加学習型ニューラルネットワークを用いた一自由度マニピュレータの適応力制御), 日本ロボット学会誌, 14-1, 75/82 (1996)
- 14) 福田敏男・荒川淳: フレキシブルロボットアームの制御(第2報、2自由度連成系のモデル化と基本特性)日本機会学会論文集(C編), 53-488, 954/961 (1987)
- 15) E. Rijanto, A. Moran, T. Kurihara and M. Hayase: Robust Tracking Control of Flexible Arm Using Inverse Dynamics Method, Proc. 4th International Workshop on Advanced Motion Control, 669/674 (1996)
- 16) D. S. Kwon and W. J. Book: A Time-Domain Inverse Dynamic Tracking Control of a single-link Flexible manipulator, ASME, Journal of Dyn. Sys., measurement and Control, Vol.116, 193/200 (1994)
- 17) J. Lu, M. Shafiq and T. Yahagi: Vibration Control of Flexible Robotic Arms Using Robust Model Matching Control, Proc. 4th International Workshop on Advanced Motion Control, 663/668 (1996)
- 18) D.E. Rumelhart, G.E. Hinton & R.J. Williams: Learning Representations by Error Propagation, In D.E. Rumelhart, J.L. McClelland & PDP Research Group: Parallel Distributed Processing, Vol.1, MIT Press (1986)
- 19) G. Cybenko: Approximation by Superposition of a Sigmoid Function, Math. Control Signal Systems, 2, 303/314 (1989)
- 20) K. Funahashi: On the Approximate Realization of Continuous Mappings by Neural Networks, Neural Networks, 2, 183/192 (1989)
- 21) K. J. Åstrom and W. Wittenmark: Adaptive Control, Addison-Wesley (1989)
- 22) A. Weinmann: Uncertain Models and Robust Control; Springer-Verlag Wien New York (1991)

《付録》

A. (35)式の証明⁹⁾

シグモイド関数を用いるときの重み更新則(28), (29)式は

$$\begin{aligned} \mathbf{V}(k+1) &= \mathbf{V}(k) - \eta H_n(z^{-1})\epsilon(k)\Omega_1(k) \cdot \\ &\quad \mathbf{W}(k)\mathbf{U}_{IN}(k) \end{aligned} \quad (\text{A.1})$$

$$\begin{aligned} \mathbf{W}(k+1) &= \mathbf{W}(k) - \eta H_n(z^{-1})\epsilon(k)\Omega_2(k) \cdot \\ &\quad \mathbf{V}(k)\mathbf{U}_{IN}^T(k) \end{aligned} \quad (\text{A.2})$$

となる。ここで、双曲線関数の特性より(39), (40)式の対角要素は $|\omega_{1ii}(k)| \leq M_1$, $|\omega_{2ii}(k)| \leq M_2$ となり、 $\Omega_1(k)$, $\Omega_2(k)$ は有界なマトリクスであることがわかる。ただし、 M_1 , M_2 は正の定数である。

重みの更新則(A.1), (A.2)式より、 $\epsilon(k)$ が微小のとき次

式が成立する。

$$\begin{aligned} & \mathbf{V}^T(k+1)\mathbf{W}(k+1) \\ & \approx \mathbf{V}^T(k)\mathbf{W}(k) - \eta H_n(z^{-1})\epsilon(k) \\ & [\mathbf{U}_{IN}^T(k)\mathbf{W}^T(k)\Omega_1(k)\mathbf{W}(k) \\ & + \mathbf{V}^T(k)\Omega_2(k)\mathbf{V}(k)\mathbf{U}_{IN}^T(k)] \end{aligned} \quad (\text{A.3})$$

上式に(32)式を代入すると、

$$\begin{aligned} & \mathbf{V}^T(k+1)\mathbf{W}(k+1) \\ & \approx \mathbf{V}^T(k)\mathbf{W}(k) - \eta H_n^2(z^{-1})\varphi^T(k)\mathbf{Q}(k) \end{aligned} \quad (\text{A.4})$$

となる。

ここで、(33)、(A.4)式によって、

$$\varphi^T(k+1) = \varphi^T(k)[\Gamma - \eta\varrho H_n^2(z^{-1})\mathbf{Q}(k)] \quad (\text{A.5})$$

となる。ただし、 $\Gamma \in R^{N \times N}$ は単位マトリクスとする。このとき、 $\Delta\Psi$ は

$$\begin{aligned} \Delta\Psi &= \Psi(k+1) - \Psi(k) \\ &= -\eta\varrho H_n^2(z^{-1})\varphi^T(k)[\mathbf{Q}(k) + \mathbf{Q}^T(k) \\ &\quad - \eta\varrho H_n^2(z^{-1})\mathbf{Q}(k)\mathbf{Q}^T(k)]\varphi(k) \end{aligned} \quad (\text{A.6})$$

である。したがって、

$$\mathbf{Q}(k) + \mathbf{Q}^T(k) - \eta\varrho H_n^2(z^{-1})\mathbf{Q}(k)\mathbf{Q}^T(k) > 0 \quad (\text{A.7})$$

を満足するような学習係数 η を選べば、 $\Delta\Psi < 0$ を保証することができる。

そこで、次に(A.7)式を満足する学習係数 η の条件を導出しよう。マトリクスのノルムを用いると、(A.7)式は

$$\|\mathbf{Q}(k) + \mathbf{Q}^T(k)\|_\infty > \eta\varrho\|H_n^2(z^{-1})\mathbf{Q}(k)\mathbf{Q}^T(k)\|_\infty \quad (\text{A.8})$$

となる。 $\mathbf{Q}(k)$ を非負定行列と仮定すると、

$$\begin{aligned} \|\mathbf{Q}(k) + \mathbf{Q}^T(k)\|_\infty &= \|\mathbf{Q}(k)\|_\infty + \|\mathbf{Q}^T(k)\|_\infty \\ &= 2\|\mathbf{Q}(k)\|_\infty \end{aligned} \quad (\text{A.9})$$

が成立し²²⁾、(A.8)式は

$$\begin{aligned} 2\|\mathbf{Q}(k)\|_\infty &> \eta\varrho\zeta\{\|\mathbf{Q}(k)\|_\infty\}^2 \\ \frac{2}{\varrho\zeta\|\mathbf{Q}(k)\|_\infty} &> \eta > 0 \end{aligned} \quad (\text{A.10})$$

となる。

[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）在学中。情報工学、ニューラルネット、適応制御、ロボット制御などの研究に従事。計測自動制御学会などの学生員、IEEEの会員

辻敏夫（正会員）



1985年、広島大学大学院工学研究科博士課程前期修了。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、マシン・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年九州工业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）