論文要旨

システム制御情報学会論文誌, 4 巻, 1 号, pp. 1~10 (1991)

可能性と必然性の概念に基づくニューラルネットの学習アルゴリズム

石渕 久生・田中 英夫

本研究では, 2 群判別の問題を取り上げ, ニューラルネットによる可能性分析と必然性分析の方法を提案する。まず, 可能性と必然性の概念に基づく判別分析の方法を示す。つぎに, 可能性判別分析および必然性判別分析のためのニューラルネットの学習アルゴリズムを提案する。提案手法では, ニューラルネットの結合強度の学習は, 重み付き 2 乗誤差の総和が最小になるように行なわれる。このとき, データ点ごとの重みを学習と共に徐々に変化させることにより, 可能性あるいは必然性を考慮した判別分析を行なうことができることを示す。さらに, 例題を用いて提案手法の説明を行なう。

システム制御情報学会論文誌, 4 巻, 1 号, pp. 11~20 (1991)

ニューラルネットを用いたリモートセンシングデータのパターン認識

吉田 知司・大松 繁・寺西 大

本論文はリモートセンシングデータのパターン認識問題へニューラルネットを用いる手法を提案している。これによって, 誤認識の割合を減少させかつ従来の Bayes 法による手法と比較して識別誤差のバラツキの少ないデータ処理結果が得られることを実データに基づいて定量的に検証している。さらに, 雲の影の補正を行なって分類する手法に対しても本論文の手法が有効であることを示す。

システム制御情報学会論文誌, 4 巻, 1 号, pp. 21~27 (1991)

階層型神経回路モデルによる時空間パターンの認識

伊藤 崇之

時空間パターンを認識できるニューラルネットワークモデルを提案する。モデルは特徴抽出部と統合部の二つの部分からなっている。前者は, 入力信号の立ち上がり, 立ち下がりなど, 時間に固有の特徴を抽出する。後者は, P 細胞と T 細胞の 2 種類の細胞からなっている。 P 細胞は特徴の統合を行なう。 T 細胞は, メモリ機能を持つ。これら 2 種類の細胞層を交互に継続的に接続し, 位置不変性と変形の許容能力も実現している。コンピュータシミュレーションによって, モデルがパターンの時間伸縮や, 位置ずれ, 変形を許容できることを示した。

システム制御情報学会論文誌, 4 巻, 1 号, pp. 28~36 (1991)

チェビシェフネットワークによるパターン領域の識別

生天目 章・上田 延寿

コネクションリストモデルを用いて, 2 次元領域のパターンを識別する問題について考察する。適当な数の中間ユニットを配置した従来の多層ネットワークによる識別ではパターン領域が複雑になるにつれてその識別能力は低下し, 中間ユニットの数や学習例を増大させてもその識別性能は改善されないことを示す。また, 一般に非線形の複雑な決定領域におけるパターン識別システムをコネクションリストモデルにより実現するためにはシグモイドのような単調な非線形関数のユニットだけでは不十分でチェビシェフ関数のような非単調関数を持つユニットとの組み合わせが必要であることを示す。従来のモデルに代わるものとしてチェビシェフネットワークという新しい多層ネットワークアーキテクチャを提案する。パターン領域の境界曲線をチェビシェフネットワークに学習させ, その出力値の論理結合により識別する方法および領域の境界曲線近傍における対象領域内外のいくつかのパターンをチェビシェフ関数により非線形変換し, それらを正負の学習例として学習・識別させる二つの方法について提案する。いずれの方法においても新しく提案したチェビシェフネットワークによる識別方法は, 一般にパターン領域の複雑性に依存しない優れた識別性能を有することを示す。

システム制御情報学会論文誌, 4 巻, 1 号, pp. 37~47 (1991)

フィードバック誤差学習による閉ループシステムの学習制御

五味 裕章・川人 光男

本論文では神経回路モデルを非線形フィードバックコントローラに利用するときの学習法を提案する。学習後には制御対象の非線形性が補償され, 参照モデルで規定される応答に従うようになる。

ここでは, この学習スキームの収束性を確率微分方程式の平均化とリアプノフの方法で証明し, 有効性を倒立振子制御のシミュレーションの結果により示す。また, この学習スキームと動物の小脳における姿勢・歩行の学習制御との関連を議論する。

フィードバック誤差学習による閉ループシステムの学習制御*

五味 裕章**・川 人 光 男**

Learning Control of a Closed Loop System Using Feedback-Error-Learning*

Hiroaki Gomi** and Mitsuo Kawato**

In this paper, we propose a new learning scheme using *feedback-error-learning* for a Neural network model applied to an adaptive Nonlinear Feedback Controller (NNFC). This system uses a Conventional Feedback Controller (CFC) both as a usual feedback controller to guarantee global asymptotic stability and as a reference model of the response. The output of the conventional feedback controller is used as the error signal for a neural network model for adaptive nonlinear feedback control. The response of the controlled object follows the response of the reference model after the learning period.

The convergence properties of this learning scheme are provided by using the averaged equation and the Liapunov method. This scheme was successfully applied to the control of an inverted pendulum by computer simulation. We also pointed out the relationship of this learning scheme to the cerebellum's posture and locomotion adaptive control mechanism in animals.

1. はじめに

従来フィードバックを必要とする系における適応学習は、適応制御理論に基づいた方法、アダプティブプロダクションシステムやファジィ、神経回路モデルによる方法が提案されている。

適応制御理論は従来線形化した対象に対して多く使用されてきた。非線形性の強いロボットなどの対象に対しては、Dubousky¹らや Slotine²らの研究がある。しかし、前者の方法は局所的に線形化した系に対して線形コントローラのゲインを調整するにすぎず、非線形性を持った制御対象を高速で動かす場合には適応速度が追い付かなくなるといった問題が生ずる。また後者の方法は取り扱われている制御対象の変動パラメータが線形に表われる特性を利用しており、制御対象に未知の非線形要素が含まれる場合には使用できない。たとえば、ロボットには予めその構造より知ることのできる遠心力・コリオリ力・

重力などの非線形性のほかにアンプ・アクチュエータ・伝達機構などの既知ではない非線形性が存在するので Slotine の方法はそのままでは使うことができない³。

一方神経回路モデルを用いた学習問題では教師あり学習が多く行なわれている⁴⁻⁶が、ロボットやプラントの制御コントローラを学習によって獲得する場合、学習すべき対象すなわちコントローラの教師信号が直接得られない場合がほとんどである。このような場合、ある時点での制御対象の出力の誤差から、その制御対象への入力に誤差を制御対象のダイナミクスを考慮せずに導き出すことは不可能である。この問題に対する解決策の一つは Barto らによって提案された ASE (Associative Search Element) の考え方⁷で、コントローラの過去の動作履歴を記憶し、ある時点での失敗（誤差）から記憶している過去の動作に対し修正を加えるというものである。この考え方は、非常に一般的で魅力がある反面、学習によってどの程度制御性が向上するのかが定量的に判りにくく、また収束性も明らかでない。

もう一つの解決策は Jordan らが提案している順逆モデリング⁸ (Forward and Inverse Modeling) である。これは“制御対象からの出力の誤差”に基づく“制御対象への入力の誤差”（すなわちコントローラの出力

* 原稿受付 1990. 5. 2

** 附 ATR 視聴覚機構研究所 ATR Auditory and Visual Perception Lab. ; Sanpeidani Inuidani, Seika-cho, Soraku-gun, Kyoto 619-02, JAPAN.

Key Words : neural network, adaptive control, learning, inverted pendulum, animal motor control.

の誤差)を制御対象の順モデルを逆伝播して計算する方法である。この学習スキームは制御対象の順モデルを作らなければならない点、それを通して誤差を逆伝播しなければならない点が困難であることが指摘されている⁹。

筆者らは随意運動制御系において、フィードバック信号を神経回路モデルの学習のための誤差信号として用い、神経回路モデルに制御対象の逆システムを学習させて前向き制御をする方法を提案してきた¹⁰。また、このフィードバック誤差学習法を用い、神経回路モデルで構成した適応フィードバックコントローラを学習させる方法も目標位置が一定の場合についてはすでに提案している¹¹。それは規範モデルとなる基本フィードバックコントローラ (Conventional Feedback Controller) を設定し、その出力を神経回路モデルによる非線形フィードバックコントローラ (Neural network model for adaptive Nonlinear Feedback Controller) に誤差信号として与え、十分学習をした後には全系が規範モデルで規定される応答に従うというものである。

本論文では、その方法をさらに拡張し目標軌道を与えた場合にも同様の学習が行なえることを理論的に示す。そしてその学習方法による制御のシミュレーションを、不安定非線形対象である倒立振子を用いて目標軌道が一定とした場合の例題として示す。さらに、この学習スキームを動物の姿勢保持・歩行などのフィードバックを必要とする制御に対する小脳の適応機構のモデルとして議論する。

2. 制御対象の非線形性を補償する適応フィードバックコントローラ

この章では、神経回路モデルを用いたフィードフォワードコントローラの学習方法として川人らにより提案されているフィードバック誤差学習¹⁰を用い、目標軌道がある場合の神経回路モデルによる非線形フィードバックコントローラ (NNFC) の学習を行なう方法を説明する。この学習は、予め既存の基本フィードバックコントローラ (CFC) によってコントロールされている制御対象の制御性を向上させることを目的としている。フィードバック誤差学習はCFCからの出力を最小化するように学習が進むため、制御対象からの出力に対する要求 (例えば線形応答を示すという要求) をCFCに設定しておくことにより学習後に望みの応答を得ることを期待するものである。

以下に、このような学習方法によるNNFCの収束性を二つの学習スキームに分けて説明する。一つは、NNFCの入力として制御対象の位置・速度・加速度を使用し、誤差信号としてCFCからの出力と入力される

外乱の和を用いる場合である。この学習ではNNFCが制御対象の逆モデルを獲得することから、“逆モデル学習”と呼ぶ。もう一つはNNFCへの入力に制御対象の現在の加速度を用いない場合であり、この場合は学習によってNNFCが制御対象の慣性項以外の非線形性を補償することになることから、“非線形レギュレータ学習”と呼ぶ。各々の学習スキームの収束性の証明の後、それらの二つの学習スキームの違いについて述べる。

2.1 逆モデル学習

今制御対象への入力を τ 、CFCからの出力を τ_c 、NNFCからの出力を τ_n として(1)~(3)式で表わす。

$$f(\ddot{\theta}, \dot{\theta}, \theta) = \tau \quad (1)$$

$$\tau_c = K_2(\ddot{\theta}_d - \ddot{\theta}) + K_1(\dot{\theta}_d - \dot{\theta}) + K_0(\theta_d - \theta) \quad (2)$$

$$\tau_n = \Phi(\ddot{\theta}, \dot{\theta}, \theta, w) \quad (3)$$

ここで、 f は未知の非線形性を含む制御対象のダイナミクス、 $\ddot{\theta}, \dot{\theta}, \theta$ は制御対象の加速度、速度、位置のベクトル、 $\ddot{\theta}_d, \dot{\theta}_d, \theta_d$ はそれらの司令値のベクトル、 K_2, K_1, K_0 は加速度、速度、位置の各誤差のフィードバックゲインベクトル、 w はNNFC内部の結合の重み(シナプス荷重)を代表させて表わしたものである。CFCは制御対象の漸近安定性を保証しかつ学習後の応答を規定するものを設定することになるが、ここでは(2)式に示すように線形フィードバックコントローラを選んだ。また Φ は、NNFCを構成する神経回路モデルの構造に依存している。この神経回路モデルはシナプス荷重 w を最適値 $\hat{w}$ に取ることによって目的とする関数 f を任意の精度で実現できるもの、つまり

$$\Phi(\ddot{\theta}, \dot{\theta}, \theta, \hat{w}) = f(\ddot{\theta}, \dot{\theta}, \theta) \quad (4)$$

が実現できるものであればよい。例えばMLP¹² (Multi Layer Perceptron), CMAC¹³ (Cerebellar Model Articulator Controller), Table Look Up¹³, MBR¹³ (Memory Based Reasoning), Prepared Nonlinearity¹⁰などで構成することが考えられる。上式で表わされる要素を用いFig. 1のような系を構成す

Fig. 1 Inverse dynamics model learning

ると系全体のダイナミクスは、 τ_{ext} を外乱とすると、

$$\tau = \tau_n + \tau_c + \tau_{\text{ext}} \quad (5)$$

となる。ここで、制御対象の逆ダイナミクスから計算される制御入力 τ と NNFC の出力 τ_n の差を τ_{imag} とおく。

$$\tau_{\text{imag}} = \tau - \tau_n = \tau_c + \tau_{\text{ext}} \quad (6)$$

これは NNFC が対象の完全な逆モデルを与えられないために生ずる誤差トルクとみることができる。さらに CFC として与えられた規範モデルで規定される仮想的なダイナミカルシステムに対する入力 τ_{ext} に余分な擾乱 $-\tau_{\text{imag}}$ が加わっているように表わせる。

$$K_2(\ddot{\theta} - \ddot{\theta}_d) + K_1(\dot{\theta} - \dot{\theta}_d) + K_0(\theta - \theta_d) = \tau_{\text{ext}} - \tau_{\text{imag}} \quad (7)$$

Fig. 1 で表わしたようにフィードバック誤差学習を行なうとき、学習速度係数を代表させて正定行列 η で表わすと学習則は次のように書ける。

$$\frac{dw}{dt} = \eta \left(\frac{\partial \Phi}{\partial w} \right)^T (\tau_c + \tau_{\text{ext}}) = \eta \left(\frac{\partial \Phi}{\partial w} \right)^T \tau_{\text{imag}} \quad (8)$$

また (8) 式の $(\partial \Phi / \partial w)^T$ は NNFC の出力に対する w の依存度を表わした項であり、これは前記の NNFC を実現する手段のいずれでもフィードバック誤差学習とは独立に表わすことが出来る。たとえば、以下の章で示すシミュレーションに用いる MLP では $(\partial \Phi / \partial w)^T$ の項を次のように計算できる。

m 層の MLP において k 層の第 q ユニットの入力の総和を i_q^k 、出力を o_q^k とし、 $k-1$ 層の第 p ユニットの k 層の第 q ユニットのシナプス荷重を w_{pq}^{k-1} とする。各ユニットの入出力関係を与える関数を h_k とおくと、それらの変数の関係は次のように表わせる^{14,15}。

$$\begin{aligned} o_q^k &= h_k(i_q^k) \\ i_q^k &= \sum_p w_{pq}^{k-1} o_p^{k-1} \end{aligned} \quad (9)$$

よって、最終段のシナプス荷重 w_{pq}^{m-1} の変化則は (10) 式ようになる。

$$\begin{aligned} \frac{dw_{pq}^{m-1}}{dt} &= \eta^{m-1} \frac{\partial \Phi}{\partial w_{pq}^{m-1}} \tau_{q \text{ imag}} \\ &= \eta^{m-1} \frac{\partial i_q^m}{\partial w_{pq}^{m-1}} \frac{\partial h_m}{\partial i_q^m} \tau_{q \text{ imag}} \end{aligned} \quad (10)$$

ここで、

$$\frac{\partial h_m}{\partial i_q^m} \tau_{q \text{ imag}} = d_q^m \quad (11)$$

とおくと、 k 層目のシナプス荷重 w_{pq}^{k-1} の変化則は

$$\begin{aligned} \frac{dw_{pq}^{k-1}}{dt} &= \eta^{k-1} \left[\frac{\partial \Phi}{\partial w_{pq}^{k-1}} \right]^T \tau_{\text{imag}} \\ &= \eta^{k-1} \frac{\partial i_q^k}{\partial w_{pq}^{k-1}} d_q^k \end{aligned} \quad (12)$$

ただし、

$$d_q^k = \frac{\partial h_k}{\partial i_q^k} \sum_r \left[\frac{\partial i_r^{k+1}}{\partial h_k} d_r^{k+1} \right] \quad (13)$$

である。すなわちこれは、 $\tau_c + \tau_{\text{ext}}$ を各重み w に対して割り振られるように逆伝播させるため、誤差逆伝播法¹⁴に相当する。この学習則で $m=2$ かつ h として線形関数を用いたとき、Widrow-Hoff の学習則¹⁶ となり、 $\tau_c + \tau_{\text{ext}}$ が誤差信号の役割を果たしていることがわかる。

以下に (8) 式の学習則を用いて学習を行なったとき、ローカルミニマムがない、あるいは回避できる場合には、 w が $\hat{w}$ に収束して τ_{imag} が 0 になることを示す。このとき、入力される外乱 τ_{ext} と司令値 $\ddot{\theta}_d, \dot{\theta}_d, \theta_d$ に対して $\ddot{\theta}, \dot{\theta}, \theta$ は (7) 式で $\tau_{\text{imag}} = 0$ を満たすように動く。つまり τ_{ext} を入力として CFC に設定された規範モデルに従って全系が振る舞う。証明の基本方針は次の三つの条件のもとで、確率微分方程式の平均化とリアプノフの安定性理論を適用するものである。数学的には Geman の定理¹⁷ を用いるもので、その適用方法は Tsukahara & Kawato¹⁸ と同様である。

条件 1

学習速度係数 η は非常に小さな正定値に設定する。

条件 2

外乱 τ_{ext} および軌道司令の加速度項 $\ddot{\theta}_d$ は 1 回微分可能な強混合強定常過程とする。

条件 3

CFC は学習開始前、学習中、学習後において制御対象からの出力が漸近安定になるよう設計する。

これらの条件のもとで、(6), (8) 式は次の確率微分方程式で置き換えられる。

$$\begin{aligned} f(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) \\ - \Phi(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega)) \\ = K_2(\ddot{\theta}_d(t, \omega) - \ddot{\theta}(t, \omega)) + K_1(\dot{\theta}_d(t, \omega) - \dot{\theta}(t, \omega)) \\ + K_0(\theta_d(t, \omega) - \theta(t, \omega)) + \tau_{\text{ext}}(t, \omega) \end{aligned} \quad (14)$$

$$\begin{aligned} \frac{dw(t, \omega)}{dt} \\ = \eta \left(\frac{\partial \Phi(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega))}{\partial w} \right)^T \\ \times \{ \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) + \tau_{\text{ext}}(t, \omega) \} \end{aligned} \quad (15)$$

ここで、 ω は確率空間での1サンプル点である。さて、Geman の定理を考えると、(15) 式の解は平均化方程式 (16) の解によって近似されることから、(16) 式の解 M の収束性に関し以下で議論する。

$$\begin{aligned} \frac{dM}{dt} &= \eta E \left[\left(\frac{\partial \Phi(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega))}{\partial w} \right)^T \right. \\ &\quad \times \{ \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) + \tau_{\text{ext}}(t, \omega) \} \Big]_{w=M} \end{aligned} \quad (16)$$

まず (17) 式に示す関数 L を用いて、平均化方程式のリアプノフ関数の候補として (18) 式に示す関数 V を考える。

$$\begin{aligned} L &= \frac{1}{2} \{ \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) + \tau_{\text{ext}}(t, \omega) \}^T \\ &\quad \times \{ \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) + \tau_{\text{ext}}(t, \omega) \} \\ V(M, t) &= E[L(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), \tau_{\text{ext}}(t, \omega))]_{w=M} \\ &= E[L(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), \ddot{\theta}_d(t, \omega), \\ &\quad \dot{\theta}_d(t, \omega), \theta_d(t, \omega), w(t, \omega), \tau_{\text{ext}}(t, \omega))]_{w=M} \\ &\quad (\because (6) \text{ 式}) \end{aligned} \quad (17)$$

関数 V の時間微分は次のようになる。

$$\begin{aligned} \frac{dV(M, t)}{dt} &= E \{ \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) + \tau_{\text{ext}}(t, \omega) \}^T \\ &\quad \times \frac{d}{dt} \{ \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) \\ &\quad + \tau_{\text{ext}}(t, \omega) \} \Big]_{w=M} \end{aligned} \quad (19)$$

簡単化のため、式を省略して次のように表わす。

$$\begin{aligned} \frac{dV}{dt} &= E \left[(\tau_c + \tau_{\text{ext}})^T \left\{ \frac{\partial \tau_c}{\partial \ddot{\theta}} \frac{d\ddot{\theta}}{dt} + \frac{\partial \tau_c}{\partial \dot{\theta}} \frac{d\dot{\theta}}{dt} \right. \right. \\ &\quad \left. \left. + \frac{\partial \tau_c}{\partial \theta} \frac{d\theta}{dt} + \frac{d\tau_{\text{ext}}}{dt} \right\} \right] \end{aligned} \quad (20)$$

また、 $\ddot{\theta}$ は (21) 式で表わされる関数であるから、

$$\begin{aligned} \ddot{\theta}(t, \omega) &= h(\dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega), \\ &\quad \ddot{\theta}_d(t, \omega), \dot{\theta}_d(t, \omega), \theta_d(t, \omega), \tau_{\text{ext}}(t, \omega)) \end{aligned} \quad (21)$$

よって、(20) 式は (22) 式で表わされる。

$$\begin{aligned} \frac{dV}{dt} &= E \left[(\tau_c + \tau_{\text{ext}})^T \left\{ -K_2 \left[\frac{\partial \ddot{\theta}}{\partial w} \frac{dw}{dt} + \frac{d\ddot{\theta}}{dt} \right. \right. \right. \\ &\quad \left. \left. + \frac{\partial \ddot{\theta}}{\partial \theta} \frac{d\theta}{dt} + \frac{\partial \ddot{\theta}}{\partial \dot{\theta}_d} \frac{d\dot{\theta}_d}{dt} + \frac{\partial \ddot{\theta}}{\partial \theta_d} \frac{d\theta_d}{dt} \right. \right. \end{aligned}$$

$$\left. \left. + \frac{\partial \ddot{\theta}}{\partial \tau_{\text{ext}}} \frac{d\tau_{\text{ext}}}{dt} \right\} - K_1 \frac{d\dot{\theta}}{dt} - K_0 \frac{d\theta}{dt} + \frac{d\tau_{\text{ext}}}{dt} \right\} \Big]_{w=M} \quad (22)$$

w と θ に着目して、二つの部分に分けると (23) 式のようになる。

$$\begin{aligned} \frac{dV}{dt} &= E \left[(\tau_c + \tau_{\text{ext}})^T \left\{ -K_2 \frac{\partial \ddot{\theta}}{\partial w} \right\} \frac{dw}{dt} \right]_{w=M} \\ &\quad + E \left[(\tau_c + \tau_{\text{ext}})^T \left\{ -K_2 \left(\frac{\partial \ddot{\theta}}{\partial \dot{\theta}} \frac{d\dot{\theta}}{dt} + \frac{\partial \ddot{\theta}}{\partial \theta} \frac{d\theta}{dt} \right. \right. \right. \\ &\quad \left. \left. + \frac{\partial \ddot{\theta}}{\partial \dot{\theta}_d} \frac{d\dot{\theta}_d}{dt} + \frac{\partial \ddot{\theta}}{\partial \theta_d} \frac{d\theta_d}{dt} \right. \right. \\ &\quad \left. \left. + \frac{\partial \ddot{\theta}}{\partial \tau_{\text{ext}}} \frac{d\tau_{\text{ext}}}{dt} \right\} - K_1 \frac{d\dot{\theta}}{dt} - K_0 \frac{d\theta}{dt} \right. \\ &\quad \left. \left. + \frac{d\tau_{\text{ext}}}{dt} \right\} \right]_{w=M} \end{aligned} \quad (23)$$

(23) 式右辺第2項は $w = M$ に固定したときの関数 L の時間平均を微分したもの ((24) 式) と等しいが、これは次に示す理由により 0 となる。

$$\begin{aligned} \frac{d}{dt} E[L(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), \ddot{\theta}_d(t, \omega), \\ \dot{\theta}_d(t, \omega), \theta_d(t, \omega), M, \tau_{\text{ext}}(t, \omega))] \end{aligned} \quad (24)$$

θ は条件3のもとで安定性が補償されているため、 $\ddot{\theta}, \dot{\theta}, \theta$ および L は強定常過程 $\ddot{\theta}_d, \dot{\theta}_d, \theta_d, \tau_{\text{ext}}$ の Baire 関数となる。そのため、 $E[L(\ddot{\theta}, \dot{\theta}, \theta, \ddot{\theta}_d, \dot{\theta}_d, \theta_d, M, \tau_{\text{ext}})]$ は時間に依存せず一定であり、その微分は 0 となる。よって、関数 V の時間微分は (23) 式の第1項目のみが残り、(25) 式で表わされる。

$$\frac{dV}{dt} = E \left[(\tau_c + \tau_{\text{ext}})^T \left\{ -K_2 \frac{\partial \ddot{\theta}}{\partial w} \right\} \frac{dw}{dt} \right]_{w=M} \quad (25)$$

つぎに、(25) 式中の $\partial \ddot{\theta} / \partial w$ を計算するため、(14) 式を使って (21) 式を w で偏微分する。

$$\begin{aligned} \frac{\partial f}{\partial \ddot{\theta}} \frac{\partial \ddot{\theta}}{\partial w} - \frac{\partial \Phi}{\partial \ddot{\theta}} \frac{\partial \ddot{\theta}}{\partial w} - \frac{\partial \Phi}{\partial w} &= -K_2 \frac{\partial \ddot{\theta}}{\partial w} \\ \Leftrightarrow \frac{\partial \ddot{\theta}}{\partial w} &= \left(\frac{\partial f}{\partial \ddot{\theta}} - \frac{\partial \Phi}{\partial \ddot{\theta}} + K_2 \right)^{-1} \frac{\partial \Phi}{\partial w} \end{aligned} \quad (26)$$

(26) 式を (25) 式に代入すると (27) 式を得る。

$$\begin{aligned} \frac{dV}{dt} &= E \left[(\tau_c + \tau_{\text{ext}})^T \left\{ -K_2 \left(\frac{\partial f}{\partial \ddot{\theta}} - \frac{\partial \Phi}{\partial \ddot{\theta}} + K_2 \right)^{-1} \frac{\partial \Phi}{\partial w} \right\} \frac{dw}{dt} \right]_{w=M} \\ &= E \left[-(\tau_c + \tau_{\text{ext}})^T K_2 \left(\frac{\partial f}{\partial \ddot{\theta}} - \frac{\partial \Phi}{\partial \ddot{\theta}} + K_2 \right)^{-1} \right. \\ &\quad \left. \frac{\partial \Phi}{\partial w} \eta \left(\frac{\partial \Phi}{\partial w} \right)^T (\tau_c + \tau_{\text{ext}}) \right]_{w=M} \end{aligned} \quad (27)$$

さて条件3を考えると、次の行列は準正定であることがわかる。

$$K_2 \left(\frac{\partial f}{\partial \theta} - \frac{\partial \Phi}{\partial \theta} + K_2 \right)^{-1} \frac{\partial \Phi}{\partial w} \eta \left(\frac{\partial \Phi}{\partial w} \right)^T \quad (28)$$

以上より、

$$\frac{dV}{dt} \leq 0 \quad (29)$$

等号は、 $\tau_{\text{imag}} \neq 0$ の状態で $\partial \Phi / \partial w \neq 0$ すなわちローカルミニマムに陥らなければ、 $\tau_{\text{imag}} = 0$ の時だけ成り立つ。平均化方程式の解は実際の方程式の解を近似するため¹⁷ $w \rightarrow \hat{w}$ が得られる。また、以上の説明では τ_{ext} と θ_d の両方の入力を設定しているが、証明からわかるように、どちらか片方の入力があれば θ も non-trivial な軌道を取るため同様に収束する。

すなわち、フィードバック誤差学習により、NNFCには制御対象の逆ダイナミクスモデルが形成されると言える。換言すれば、制御対象の非線形性を完全に補償して(7)式の右辺第2項が0となるのでCFCに設定する応答モデルに従うモデル規範型適応制御が可能となる。また、上記の証明の中ではCFCとして(2)式で表わされる線形コントローラを設定し、線形規範モデルの応答に従うよう学習が進行することを示しているが、CFCとして非線形の規範モデルを用意すれば、この学習スキームのままでその非線形規範モデルの応答に従うように学習が行なわれる。上記の証明は、川人により示された閉ループ系の軌道制御のためのフィードバック誤差学習の安定性の証明の枠組と基本的に同じ手法を用いている¹⁹。

2.2 非線形レギュレータ学習

この証明では、制御対象のダイナミクスを加速度に依存する項とそれ以外の項に分けて次式のように表わす。

$$R(\theta)\ddot{\theta} + N(\theta, \dot{\theta}) = \tau \quad (30)$$

ここで、 R, N は未知の非線形項を含む制御対象のダイナミクスによって決まる項であり、多くのロボットなどのダイナミクスは(30)式のように表わせる。CFCは2.1と同様(2)式のように設定する。また、NNFCはフィードバック信号 $\theta, \dot{\theta}$ とフィードフォワード信号(軌道司令) $\ddot{\theta}_d, \dot{\theta}_d, \theta_d$ を入力としかつ内部にシナプス荷重 w があるため次のように表わせる。

$$\tau_n = \Phi(\ddot{\theta}_d, \dot{\theta}_d, \theta_d, \dot{\theta}, \theta, w) \quad (31)$$

これらを用いて Fig. 2 のような系を構成すると全体のダイナミクスは

$$\begin{aligned} \tau &= \tau_c + \tau_n \\ \Leftrightarrow K_2(\ddot{\theta}_d - \ddot{\theta}) + K_1(\dot{\theta}_d - \dot{\theta}) + K_0(\theta_d - \theta) \\ &\quad + \Phi - R(\theta)\ddot{\theta} - N(\theta, \dot{\theta}) = 0 \end{aligned} \quad (32)$$

Fig. 2 Nonlinear regulator learning

となる。ここで、NNFCで実現する関数 Φ が

$$\begin{aligned} \Phi_d &= N(\theta, \dot{\theta}) \\ &\quad + R(\theta)\ddot{\theta}_d + R(\theta)K_2^{-1}(K_1(\dot{\theta}_d - \dot{\theta}) + K_0(\theta_d - \theta)) \end{aligned} \quad (33)$$

となる時、(32)式より

$$\begin{aligned} (R(\theta) + K_2)(\ddot{\theta}_d - \ddot{\theta}) + K_1(\dot{\theta}_d - \dot{\theta}) + K_0(\theta_d - \theta) \\ + R(\theta)K_2^{-1}(K_1(\dot{\theta}_d - \dot{\theta}) + K_0(\theta_d - \theta)) = 0 \end{aligned} \quad (34)$$

よって、

$$\begin{aligned} (I + R(\theta)K_2^{-1})(K_2(\ddot{\theta}_d - \ddot{\theta}) + K_1(\dot{\theta}_d - \dot{\theta}) \\ + K_0(\theta_d - \theta)) = 0 \end{aligned} \quad (35)$$

となる。すなわち $\xi = \theta_d - \theta$ とおくと、通常 $I + R(\theta)K_2^{-1} \neq 0$ であるから、

$$K_2\ddot{\xi} + K_1\dot{\xi} + K_0\xi = 0 \quad (36)$$

言い換えると、目標値 θ_d と実際の出力 θ の誤差の自由応答は設定したCFCの出力が0となるように動くことになる。

ここでは、CFCからの出力をNNFCの学習のための誤差信号として学習を進めた時、(36)式の応答に一致するようになることを簡単に説明する。まず関数 P を次のようにおく。

$$\begin{aligned} P &= \Phi - [N(\theta, \dot{\theta}) + R(\theta)\ddot{\theta}_d + R(\theta)K_2^{-1} \\ &\quad (K_1(\dot{\theta}_d - \dot{\theta}) + K_0(\theta_d - \theta))] \\ &= -(I + R(\theta)K_2^{-1})\tau_c \quad I: \text{unit matrix} \end{aligned} \quad (37)$$

また、Fig. 2 のようにフィードバック誤差学習を行なうとNNFCの学習則は(38)式で表わすことが出来る。

$$\frac{dw}{dt} = \eta \left(\frac{\partial \Phi}{\partial w} \right)^T \tau_c \quad (38)$$

ここで、(32)(38)式の確率微分方程式を考えその平均化方程式に対するリアプノフ関数の候補 J を次のように設定する。

$$J = E \left[\frac{1}{2} P^T P \right]_{w=M} \quad (39)$$

すると前証明と同様の手順で、

$$\frac{dJ}{dt} \leq 0 \quad (40)$$

であることを示すことができ、NNFC内の学習でローカルミニマムに陥らなければ、フィードバック誤差学習により Φ は(33)式に収束し、システムの自由応答は(36)式に従う。

2.3 議論

以上二つの学習の結果を比較すると、逆モデル学習のほうはNNFCへのフィードバック信号によって制御対象の非線形性を慣性項まで補償するという利点がある。しかし、逆モデル学習では学習時に入力される外乱は微分可能な連続性を持っている必要がある。そのため対象システムでのデータサンプリング間隔が長くて、外乱がその条件を全く満たさないとみれる場合など、実際の制御において適用が困難な場合もある。

両学習において、学習後のNNFC内部に形成されるものは異なるが、どちらを用いた場合でも結果としてこの学習システムの要求であるCFCに設定した規範モデルで規定される応答に近づくよう学習が進行する。制御する対象と要求にあわせて学習スキームを選択するのが望ましいと考える。

また、証明においては学習中にローカルミニマムに陥らないことを仮定しているが、神経回路モデルを使った学習の場合の完全な回避方法は現在のところ見あたらない。しかし、これをある程度回避する方法はいくつか提案されており、実際の問題にMLPを適用した場合にもかなりうまくいくことは多数報告されている¹⁴。さらに、ここで提案した学習ではランダムな外乱あるいは目標軌道により系を駆動するため、ある程度ローカルミニマムは回避できると考える。

3. 学習のシミュレーション結果

つぎに、上記のアルゴリズムの有効性を倒立振り制御を例題としたシミュレーションによって確認する。この問題においては、目標値一定となるためレギュレータ問題となる。まず、制御対象の逆モデルを形成するのに必要な非線形変換した後の信号(Prepared Nonlinearity)を入力として持つ2層のMLPをNNFCに用いて「逆モデル学習」を示す。つぎに、一般的な非線形関数を実現できる3層のMLPをNNFCに用いて「非線形レギュレータ学習」を示す。

3.1 逆モデル学習による倒立振り制御

制御対象とした倒立振子のダイナミクスは、台車に対しての加速度を入力信号とし、クーロン摩擦に相当する速度に依存した非線形摩擦項を加え次式のようにおいた。

$$-(J+ml^2)\ddot{\theta} - \left(\frac{2}{1+\exp(-a\dot{\theta})} - 1 \right) + mgl \sin \theta = mlu \cos \theta \quad (a \text{ は定数}) \quad (41)$$

ただし、

m : 振り重量	0.0411	[kg]
l : 振子の長さ	1.26	[m]
J : 振子の慣性モーメント	0.0647	[kgm/sec ²]
θ : 振子傾き角		[rad]
u : 入力加速度		[m/sec ²]
g : 重力加速度	9.81	[m/sec ²]

このシミュレーションでは、逆モデル学習により神経回路モデルが制御対象の逆モデルを獲得することを明確に示すため、制御対象の逆モデルを形成するのに必要な非線形変換をした後の信号を入力とする2層のMLPをNNFCとして用いた。このようにすると、NNFC内部での学習はローカルミニマムのない凹関数の学習問題となる。したがって w が大域的な安定点に収束することを示すことが出来る。また、後に述べる小脳の学習モデルとして考えた場合、小脳プルキンエ細胞に苔状線維から平行線維を経て入る信号は顆粒細胞付近で前処理を受けており、その処理を非線形変換ユニットとしてモデル化するという考え方もある¹⁰。ここでは、NNFCが対象の逆モデルを形成するのに必要な非線形ユニットとして次のものを用意した。

$$\begin{aligned} f_0 &= \tan \theta \\ f_1 &= \frac{1}{\cos \theta} \left(\frac{2}{1+\exp(-a\dot{\theta})} - 1 \right) \\ f_2 &= \frac{1}{\cos \theta} \ddot{\theta} \end{aligned} \quad (42)$$

学習によって制御対象の逆モデルが形成されるとすると、NNFCを次式のように設定した時、

$$\tau_n = \sum_{k=0}^2 w_k f_k \quad (43)$$

各々のシナプス荷重 w_k の目標値 $\hat{w}_k$ は次の値である。

$$\begin{aligned} \hat{w}_0 &= g \\ \hat{w}_1 &= -\frac{1}{ml} \\ \hat{w}_2 &= -\frac{J+ml^2}{ml} \end{aligned} \quad (44)$$

シミュレーションではフィードバック用の位置と速度信号は状態量が計測可能として使用し、加速度信号は速度信号の後退差分を使用した。また、外乱は、証明で用いた条件2を満たすためOrnstein-Uhlenbeck過程を用いた。CFCに設定したフィードバックゲインは $K_2=1, K_1=3.5, K_0=20$ である。

まず、学習中の各シナプス荷重の変化の様子と目標値

を Fig. 3 に, NNFC に対する誤差信号および NNFC の出力の各々の自乗移動平均の変化の様子 (25,000 iteration ごと) を Fig. 4 に示す。それらの図から, 学習が進むにつれ NNFC 内部のパラメータは目標値に収束し, 誤差信号が減少していくことがわかる。

Fig. 3 Time courses of weights during inverse dynamics model learning

Each actual value, w_2, w_1, w_0 , approached to the each desired value, $\hat{w}_2, \hat{w}_1, \hat{w}_0$, gradually.

Fig. 4 Moving average square of the NNFC output and the error for NNFC during inverse dynamics model learning (25,000 times average)

The NNFC output increased for compensation of controlled object dynamics. As a consequence of such adaptation, the error signal for NNFC decreased gradually.

つぎに, Fig. 5 に外乱に対する学習前後の応答と目標応答および従来の線形コントローラを用いたときの応答を示す。従来, 線形コントローラの設計は, 制御対象を動作点近傍で線形化した簡単なモデルを考え, そのモデルが目標応答を出力するように各線形フィードバック

Fig. 5 Controlled object response for the disturbance

The input disturbance is $\tau_{ext} = -5 \sin(\pi t/2) [\text{m/sec}^2]$. The response obtained after learning corresponded perfectly to the desired response such as :

$$K_2(\ddot{\theta} - \ddot{\theta}_d) + K_1(\dot{\theta} - \dot{\theta}_d) + K_0(\theta - \theta_d) = \tau_{ext}$$

(In this case, $\hat{\theta}_d = \theta_d = 0, K_2 = 1, K_1 = 3.5, K_0 = 20$)

The response driven by the linear controller that was designed for linearized object, didn't correspond to the desired response because of object nonlinearity and unconsidered factor, friction.

クゲインを決定するのが一般的である。ここで使用した線形コントローラも, その手法に従い, 原点近傍で線形化しかつ摩擦を考慮しなかった (45) 式で表わされるモデルを考え,

$$-(J + ml^2)\ddot{\theta} + mgl\theta = mlu \quad (45)$$

そのモデルが外乱 τ_{ext} に対して目標応答が得られるように設計した。この線形コントローラを用いた場合には図からもわかるように, コントローラ設計の際に考慮していない「制御対象の構造による非線形性」と「摩擦」により, 外乱に対し目標とする応答が得られていない。これに対し, 学習後には目標に一致した応答が得られている。

また, Fig. 6 に学習後に外乱を入力したときの NNFC と CFC の出力の様子を示す。CFC からの出力が制御対象に加わる外乱と等しくなるように, すなわち (7) 式で $\tau_{img} = 0$ とおいた応答に従うように NNFC が補償をかけている様子がわかる。

3.2 非線形レギュレータ学習による倒立振り子制御

この学習スキームのシミュレーションでは, 提案した学習則がより一般的な神経回路モデルでも十分有効であることを示すため, NNFC に 3 層の MLP を使用した。ここで, 入力層は振子の位置・速度を入力するための二つの線形ユニット, 中間層は五つのシグモイド関数を持ったユニット, 出力層は一つの線形ユニットで構成し, 線形な部分の学習を促進するため入力層から出力層への直

Fig. 6 Controller output response for the disturbance

The learned NNFC output compensated the nonlinear dynamics of controlled object to neglect the disturbance τ_{ext} by the CFC output τ_c .

接結合を設けている。また問題の対称性から各ユニットに対するバイアス入力はいっていない。制御対象およびCFCは前例と同じく各々(41)式、(2)式で表わされるものを使用し、各パラメータも同様に設定した。この学習では、60 [deg]からの自由応答5 [sec]を繰り返して行ない各時点でのCFCの出力をNNFCに対する誤差信号として学習を行なった。

まず、学習途中での両フィードバックコントローラ出力の移動平均の変化の様子(250,000 iteration [1回の自由応答]ごと)をFig. 7に示す。学習が進行するにつれ、CFCからの出力が減少していくのがわかる。

Fig. 7 Moving average square of controller output during nonlinear regulator learning (250,000 times average)

つぎに、Fig. 8に目標とする応答、学習前後の応答および従来型の線形コントローラでの応答を示す。線形コントローラは逆モデル学習の時と同様に、制御対象を原点近傍で線形化しかつ摩擦がないとして目標応答が得られ

Fig. 8 Controlled object response from initial position of 60 [deg]

The response obtained after learning corresponded almost to the desired response such as :

$$K_2(\ddot{\theta} - \ddot{\theta}_d) + K_1(\dot{\theta} - \dot{\theta}_d) + K_0(\theta - \theta_d) = 0$$

(In the case, $\theta_d = \theta_d = 0$, $K_2 = 1$, $K_1 = 3.5$, $K_0 = 20$)

The response obtained by using only the linear controller that was designed for linearized object, didn't correspond to the desired response because of object nonlinearity and unconsidered factor, friction.

よう設計したものである。ただし、ここでは外乱に対する応答性ではなく、自由応答時の目標への収束性のみを評価対象としているため、加速度のフィードバックはかけず、位置と速度の情報のみで線形コントローラを構成した。逆モデル学習の際示した結果と同様、線形コントローラを用いた制御では設計時に考慮しなかった制御対象の非線形性のため大きく目標応答からはずれるが、学習後の応答は大幅に改善され目標応答にほぼ近い軌道が得られている。しかし、逆モデル学習で示した結果ほど目標応答に一致していない。これは逆モデル学習では、完全に目的関数を実現できるものをNNFCに用意しているのに対し、この学習では目的関数を未知として3層のMLPを用いたためである。数学的には3層のMLPによって、任意の非線形関数を任意の精度で実現することが示されているが¹²、実際の問題では、そのサイズやローカルミニマムへのトラップによって制限される。

学習後の応答時のCFCとNNFCの出力の時間応答をFig. 9に示す。CFCの出力はNNFCの出力に比べ非常に小さく、また θ が線形的な応答を示しているにも関わらずNNFCの出力は非線形応答を示していることがわかる。すなわち、対象の非線形性を補償してCFCに設定した線形の目標特性に近付くように学習が行なわれたといえる。

Fig. 10に学習時とは異なる始点(30 [deg])からの各応答の比較を示す。線形コントローラを用いたときの応答は、対象の非線形性のための目標応答および線形コ

Fig. 9 Controller output response from initial position of 60 [deg]

The learned NNFC output became such a sinuous response to hold the CFC output to zero because of object nonlinearity.

Fig. 10 Controlled object response from initial position of 30 [deg]

The response for the initial position of 30 [deg] obtained by using the linear controller was different from the response for the initial position of 60 [deg] because of the object nonlinearity. The response obtained after learning was closed to the desired response in this case, too. Thus, we can consider that the nonlinear controller has good generalization capability.

ントローラによる 60 [deg] からの応答と違う挙動を示している。しかし、学習後の NNFC を用いた場合は、学習時と異なる応答（学習は 60 [deg] からの応答で繰り返し学習を行なっている）も目標応答にはほぼ等しく、これは MLP を用いたこの学習が汎化能力を持っていることを示している。

4. 動物の姿勢制御における適応機構

人間は直立姿勢という、支持面積に比べてかなり高い位置の重心を 2 本の足で支える不安定な状態の保持が可

能であるが、これは現在の状態を逐次観測し修正動作を掛けるフィードバック系を有しているためである。そのためのセンサとしての役割を、固有感覚受容器 (Proprioceptors)・前庭器官 (Vestibular Organ)・視覚が担っていることが指摘されてきた^{20,21}。固有感覚受容器は四肢 (Limbs) や体幹 (Body Trunk) の位置・速度・力を、前庭器官は頭部の速度・加速度および傾きを、視覚は速度・位置を主に検出する。また、それらのセンサから入ってくる情報に基づき各筋肉に指令を送っている部位として、脊髄 (Spinal Cord)、脳幹 (Brain Stem)、小脳 (Cerebellum) があげられ、それらの部位が協調して姿勢制御系を構成していると考えられている^{20,22}。

運動の適応学習については、伊藤らにより小脳が重要な役割をしていることが明らかにされている²³。そして、小脳の四つの主な部分 (片葉 (Flocculus)、虫部 (Vermis)、中間部 (Intermediate part of hemisphere)、外側部 (Lateral part of hemisphere)) のうち、小脳片葉については、藤田により前庭動眼反射の適応機構モデル²⁵が提案され、小脳外側部については随意運動制御の適応機構モデル¹⁰が川人らにより提案されている。

姿勢制御に関しては、あるセンサからの入力断たれた時に発生する Ronberg 徴候²⁰などにみられる制御性の劣化が他のセンサからの入力で補われる適応機構がある²⁰ことが知られており、さらに Nashner の研究で小脳を損傷した患者は姿勢制御における適応機構が著しく劣化してしまうことが指摘されている²²。このことから、小脳が姿勢制御の適応能力をにおいても重要な役割を果たしていることがわかる。

また、小脳の四つの部位に対する入出力ルートは解剖学的に調べられている²⁴。その中で小脳虫部は脊髄・視聴覚・前庭からの入力を主に受け、出力の最終目標が脳幹・運動野になっており、その機能として体幹の姿勢保持が揚げられている²⁴。また中間部では脊髄からの入力を主に受け出力先は赤核・大脳運動野となっていて、機能は肢の制御であるとされている。

小脳における適応の仕組みとしては、小脳の各部位では顆粒細胞を通り平行線維を伝わってくる信号と下オリーブ核より伝播され登上線維に至る末梢からの信号とがプルキンエ細胞に同時に到着したとき、異シナプス可塑性により平行線維からのシナプス伝達効率が減少することが生理学的研究で明らかにされており²³、小脳の構造の一樣性も解剖学的に知られている。

以上の事柄から、姿勢保持や歩行の制御においては小脳虫部・中間部がその適応機構を担っており、反射系か

Fig. 11 Adaptive motor control in cerebellum

らの信号が下オリブ核を通して虫部・中間部に誤差信号として与えられ学習が行なわれるシステムになっていることが推察できる。以前提唱された片葉および外側部のモデルと併せて小脳四つの部位の適応機構のモデルをブロック図で表わすと Fig. 11 ようになる。図の中で虫部・中間部のモデルは先の章で述べたフィードバック誤差学習による閉ループ適応学習系と多くの類似点を持つ

ている。このことは、前章で提案した適応学習系が動物の姿勢保持・歩行制御の適応学習系モデルとして妥当なものであるということを示唆している。

5. まとめ

フィードバック誤差学習を用いた適応フィードバックコントローラの学習を提案し、その学習により制御対象の非線形性を補償するモデル規範型制御が可能であることを証明し、シミュレーションにより有効性を確認した。従来の MARC (Model Reference Adaptive Control) に代表される適応制御と最も異なる点は、従来の方法が適応対象の非線形性を補償するのに、適応パラメータ調整を制御対象の非線形性の出現に対して素早く行ない一時的に局所線形対象と見なして線形ゲインを調整する手法であるのに対し、本方法では非線形制御対象の持つ未知の非線形特性を推定し補償する制御を行なうことである。従来は、線形適応制御を用いた場合適応パラメータが収束するのにある程度の時間を要するため高速に動くロボットなどの未知の非線形性の適応補償は困難であったが、本方法ではこれを改善できる可能性を持っている。ここで提案した学習則は、フィードバックコントローラによって制御を行なっている場合にその制御性を改善する汎用的な方法である。本論文では、倒立振子の制御を例に取りその有効性を示したが、この方法はロボットや一般の自動機械、プラントなどの適応学習制御にも応用可能であり適用範囲は非常に広いと考える。特にロボットマニピュレータを対象とした学習では、規範モデルを作業座標系で設定することにより、対象物の操作などに重要な概念である「インピーダンス制御」が可能となることをすでに示している²⁶。

しかし、実際の利用に際しては、加速度の検出や学習時の安定性の確保、NNFC に設定する神経回路モデルの種類とその効果的な学習など多くの解決しなければならない問題もある。

また最後に議論した、本論文で提案した学習スキームと動物の姿勢制御系の適応学習機構との関係は多くの未知の部分を残しており、今後さらにその関連性について調べていこうと考えている。

謝辞

本研究の機械を与えていただいた ATR 視聴覚機構研究所 佐川英司社長、中根一成認知研究室長、有意義な討論をしてくださる和田、片山、平山研究員ならびに多くのご助言をいただいた視聴覚機構研究所の皆様へ感謝致します。また H. G. は、NTT 基礎研の河原主幹研究員、NTT HI 研の岩城主任研究員に貴重なご意見をいただいたことを感謝致します。

参 考 文 献

- 1) S. Dubowsky & D. T. DesForges : The Application of Model Referenced Adaptive Control to Robotic Manipulators ; Journal of Dynamic Sys., Meas. and Cont, Vol. 101, pp. 193~200 (1979)
- 2) J. E. Slotine & W. Li : On the adaptive control of robot manipulators ; Int. J. Robotics Research, Vol. 6, No. 3, pp. 49~59 (1987)
- 3) 有本：これからのロボットのモデリング；JRSJ, Vol. 7, No. 2, pp. 84~88 (1989)
- 4) 池田, 北村：ニューラルネットワークによる倒立振子安定化の学習制御；第31回自動制御連合講演会, pp. 257~258 (1988)
- 5) A. Guez & J. Selinsky : A neuromorphic controller with a human teacher ; ICNN Proc., Vol. 2, pp. 595~602 (1988)
- 6) V. V. Tolat & B. Widrow : An adaptive "Broom Balancer" with visual input ; ICNN Proc., Vol. 2, pp. 641~647 (1988)
- 7) A. G. Barto, R. S. Sutton & C. W. Anderson : Neuronlike adaptive elements that can solve difficult learning control problems ; IEEE Trans. on Sys., Man and Cyb. Vol. SMC-13, pp. 834~846 (1983)
- 8) M. I. Jordan : Supervised learning and Systems with excess degrees of freedom ; COINS technical Report 88-27, pp. 1~41 (1988)
- 9) 川人：計算論的神経科学；日本 ME 学会 BME, Vol. 3, No. 10, pp. 18~26 (1989)
- 10) M. Kawato, K. Furukawa & R. Suzuki : A Hierarchical Neural-Network Model for Control and Learning of Voluntary Movement ; Biol. Cybern. 57, pp. 169~185 (1987)
- 11) 五味, 川人：フィードバック誤差学習による不安定システムの学習制御；信学会 NC 研究会, NC-89-62, pp. 7~12 (1990)
- 12) B. Irie & S. Miyake : Capabilities of three-layered perceptrons ; Proc. ICNN88, Vol. 1, pp. 641~648 (1988)
- 13) 川人：ニューラルネットワーク；スペクトラム, Vol. 3, No. 4, pp. 68~77 (1990)
- 14) D. E. Rumelhart, J. L. McClelland & PDP Research Group : Parallel Distributed Processing Vol. 1, The MIT Press (1986)
- 15) 麻生：ニューラルネットワーク情報処理, 産業図書, pp. 50~52 (1987)
- 16) B. Widrow & M. E. Hoff : Adaptive switching circuits ; WESCON conv. Rec., pt. 4 (1960)
- 17) S. Geman : Some averaging and stability results for random differential equations ; SIAM J. Appl.-Math. Vol. 36, pp. 86~105 (1979)
- 18) N. Tsukahara & M. Kawato : Dynamic nad plastic properties of the brain stem neuronal networks as the possible neuronal basis of learning and memory ; In S. Amari & M. A. Arbib (Ed), Lecture Notes in Biomathematics 45, Cometition and Coopratiion in Neural Nets, Springer-Verlag, Berlin, pp. 430~441 (1982)
- 19) M. Kawato : The feedback-error-learning neural network for supervised motor learning ; In R. Eckmiller (Ed), Neural Network for Sensory and Motor Systems, Elsevier, Amsterdam, pp. 365~372 (1990)
- 20) 田中：姿勢の制御, 入来, 外山 (編), 生理学 1, 文光堂, pp. 514~516 (1987)
- 21) 吉田：眼球運動の制御, 入来, 外山 (編) 生理学 1, 文光堂, pp. 536~559 (1987)
- 22) T. J. Carew : Posture and Locomotion ; In E. R. Kandel (Ed), Principles of Neural Science, Chapter 37, Elsevier Inc., pp. 478~486 (1985)
- 23) M. Ito : The Cerebellum and Neural Control, Raven Press, Section 25, pp. 354~373 (1984)
- 24) C. Ghez, S. Fahn : The Cerebellum ; In : E. R. Kandel, (Ed) Principles of Neural Science, Chapter 39, Elsevier Inc., pp. 502~522 (1985)
- 25) M. Fujita : Simulation of adaptive modification of the vestibulo-ocular reflex with an adaptive filter model of the cerebellum ; Biol. Cybern., Vol. 45, pp. 207~214 (1982)
- 26) 五味, 川人：対象物操作のための運動学習制御；信学会 NC 研究会, NC-90-19, pp. 45~52 (1990)