ニューラルネットワークを用いたフレキシブル・
マイクロアクチュエータの先端位置追従制御*川 福 基 裕^{*1}, 佐々木 実^{*2}

Neural Network for Trajectory Control of a Flexible Micro-Actuator

Motohiro KAWAFUKU and Minoru SASAKI

High precision positioning control of flexible micro-actuators can be achieved by imitating aspects of human and animal behavior which involves the ability to learn and adapt to changes in the environment. Artificial neural network modeling, which is a computational model for representing input/output relations, is an approach which can be applied in designing trained and self-learning motion control systems for micro-actuators. A reference signal self-organizing control system using neural networks for flexible micro-actuators is presented. The micro-actuator is made of a bimorph piezo-electric high-polymer material (Poly Vinylidene Fluoride). This control system consists of both a plant with a feedback loop and a neural network with a feedforward loop. In this system, the neural network functions as the reference input filter and it organizes a new reference signal to the closed loop system. Numerical and experimental results show that the proposed control system is effective in tracking a reference signal.

Key Words: Trajectory Control, Neural Network, Flexible Micro-Actuator, Piezo-Electric High-Polymer Material

1. ま え が き

近年のエレクトロニクス技術の進歩によって、コンピュータは小型化・高速化され、多種多様なコンピュータが産業分野から日常生活の隅々にいたるまで浸透してきている。こうしたエレクトロニクス技術の進歩に伴い、コンピュータに人間の頭脳の代替をさせようとする「人工知能(AI)」の研究開発も進歩してきた。このような人工知能の中でも、ニューラルネットワークは、人間の脳の神経回路網をモデルとし、それに類似した並列情報処理を行わせることによって、コンピュータに人間のような考え方、学習、行動を行わせようとするシステムであり、適応能力、非線形関数近似能力やはん化能力を有することから、制御系への適用が急速に増えつつある。制御系の分野においては、NNに非線形性を有するシステムや正確なモデル化が困難なシステムに対して、その逆モデルを学習させたり、または目標出力との誤差を補正させたりして高精度な制御を行わせようとする研究が盛んに行われている^{(1)~(5)}。

一方、機械システムにおいては、より高いレベルでの高速・高精度化、小型軽量化が必要とされてきている。しかし、これらの開発が進むにつれて、今までのように制御対象システムを剛体として考えてきたコントローラ的设计仕様では、剛性の低下にともない高速移動などによって発生する弾性振動には対応しきれず、これ以上の高速・高精度化は望めない。このような問題点の克服のためには、制御対象システムを弾性体として扱って、コントローラを設計していく必要がある。しかしながら、システムを弾性体として考えた場合、無限自由度系として取扱わなければならない、現実には正確なモデル化は非常に難しく、従来の制御方式ではモデルの正確さが問題となり、コントローラ的设计が困難になってきている。

また、より高精度化のためには、今までのシステムでは無視できていたほどの微小振動・微小変位にも対応しなければならず、また、環境からの外乱の影響も大きく、無視できなくなってきたり、既存のコントローラや、既存の駆動装置では摩擦や機械的な遊び等のためにこれらの微小振動・微小変位には対応できない。そのため、今までとは違った駆動方式の新しい微小変位制御用素子とコントローラが必要になってきている。

* 原稿受付 1997年11月21日。

*¹ 学生員、岐阜大学大学院(〒501-1193 岐阜市柳戸1-1)。*² 正員、岐阜大学工学部。

そこで、本論文では、制御対象であるフレキシブルアクチュエータに微小変位制御用素子として最近注目されている高分子圧電素子 PVDF (Poly Vinylidene Fluoride) を取上げ、フレキシブルマイクロアクチュエータの運動制御における基礎研究として、先端位置追従制御系に対する NN の有効性について検討する。まず、NN を用いたコントローラの構成について検討を行い、次に新たな NN 制御系として「目標値補正形 NN」を提案する。また、提案した制御方法を用い、学習の効率化・高速化を目的として、3 種類の NN の学習方法を用いて、フレキシブルマイクロアクチュエータにおける先端位置追従制御を行い、学習過程の比較を行った。最後に本論文で提案した NN コントローラの DSP による実装実験を行い、コントローラの有効性を実験により検証する。

2. アクチュエータの構造、動作原理、およびモデル化

フレキシブルマイクロアクチュエータは、図 1 に示すように、長さ方向に伸縮する 2 枚の高分子圧電素子フィルムを弾性金属板にはり合せたバイモルフ構造になっている。上層と下層に逆位相の電界を印加すると、一方は伸び、他方は縮み、全体として屈曲振動が起こる。

フレキシブルマイクロアクチュエータの数式モデル化において、曲げ方向への変位を $w(x, t)$ 、固定端からの距離を x 、アクチュエータの x 方向に対する長さを l 、電圧の印加により発生するモーメントを $\mathcal{M}_c$ としたとき、運動方程式は⁽⁶⁾、

$$EI \left(1 + \gamma \frac{\partial}{\partial t} \right) \frac{\partial^4 w(x, t)}{\partial x^4} + \rho A \frac{\partial^2 w(x, t)}{\partial t^2} = \mathcal{M}_c \{ \delta'(x) - \delta'(x-l) \} \quad (1)$$

の 4 階偏微分方程式で表される。ただし、 $\delta(x)$ は Dirac のデルタ関数、 EI はアクチュエータ全体の曲

げ剛性、 ρ は密度、 A は断面積、 γ は内部構造減衰である。また、アクチュエータの境界条件は

$$\left. \begin{aligned} w(0, t) &= 0, \quad \frac{\partial w(0, t)}{\partial x} = 0, \\ -EI \left(1 + \gamma \frac{\partial}{\partial t} \right) \frac{\partial^2 w(l, t)}{\partial x^2} &= 0, \\ EI \left(1 + \gamma \frac{\partial}{\partial t} \right) \frac{\partial^3 w(l, t)}{\partial x^3} &= 0. \end{aligned} \right\} \quad (2)$$

となる。

これらを用いて状態方程式を導くため、偏微分方程式 (1) の一般解をモード関数 $X(t)$ と時間関数 $f(t)$ の積として考え、

$$w(x, t) = X(x)f(t) = \sum_{i=1}^{\infty} X_i(t)f_i(t) \quad (3)$$

であると仮定する。式 (2) を考慮して、式 (3) を式 (1) に代入し、正規直交性を考慮してモード展開を行うと、 i 次の時間に関する運動方程式として

$$\frac{d^2 f_i(t)}{dt^2} + \gamma w_i^2 \frac{df_i(t)}{dt} + w_i^2 f_i = \frac{1}{\rho A} \mathcal{M}_c \frac{dX_i(l)}{dx} \quad (4)$$

を得る。各振動モードについて状態変数を $x_i^T = [f_i(t) \dot{f}_i(t)]$ とおくことにより、無限自由度の状態方程式を得ることができる。

しかし、無限自由度の状態方程式を用いて数値シミュレーションを行うことは困難であることから、 n 次モードまでの有限自由度系として扱うように、低次元化を行う。以上から、運動方程式 (1) より、次式のような状態方程式が導かれる。

$$\begin{aligned} \frac{dx}{dt} &= Ax + B\mathcal{M}_c \\ y &= Cx \end{aligned} \quad (5)$$

ここで

$$A = \begin{pmatrix} A_1 & \cdots & 0 \\ & \ddots & \\ \vdots & A_i & \vdots \\ & & \ddots \\ 0 & \cdots & A_n \end{pmatrix},$$

Fig. 1 Flexible micro-actuator model

Table 1 Actuator parameters

EI [Nm ²]	ρA [kg/m]	γ [kgm/s]
3.52×10^{-8}	3.13×10^{-3}	4.77×10^{-4}
l [m]	b [m]	c [m]
2.90×10^{-2}	1.64×10^{-2}	8.0×10^{-7}

$$x = \begin{bmatrix} f_1 \\ \dot{f}_1 \\ f_2 \\ \dot{f}_2 \\ \vdots \\ f_i \\ \dot{f}_i \\ \vdots \\ f_n \\ \dot{f}_n \end{bmatrix}, B = \begin{pmatrix} B_1 \\ \vdots \\ B_i \\ \vdots \\ B_n \end{pmatrix}, C = (C_1 \cdots C_i \cdots C_n) \quad \dots\dots\dots (6)$$

であり, i 次モードにおける各係数行列の要素は

$$A_i = \begin{pmatrix} 0 & 1 \\ -\omega_i^2 & -\gamma\omega_i^2 \end{pmatrix}, B_i = \begin{pmatrix} 0 \\ \frac{1}{\rho A} \frac{dX_i(l)}{dx} \end{pmatrix}, \quad \dots\dots\dots (7)$$

$$C_i = (X_i(l) \ 0)$$

である. また, 使用したアクチュエータの各パラメータを表1に示す.

ここで, b, c , はそれぞれアクチュエータの幅, 厚さである.

実際のプラントにおけるパワースペクトルなどとの比較から, 今回はモード次数を3次まで考慮した. 図2に, ステップ入力に対する数値シミュレーション結果と, 実際の実験結果を示す. 図2において, 導出した数式モデルは, 実際のマイクロアクチュエータの挙動と比較して, 行き過ぎ量, 最終値などにおいてほぼ一致しており, 満足のいく数式モデルが導出されたことが確認できる.

3. NN 制御系の構成

NN の学習アルゴリズムとしては, 一般的なバックプロパゲーション法(BP法)を用いた. このとき,

Fig. 2 Step response

NN における入力 I_i と出力 O_k の関係式は次式のようになる.

$$O_k = f \left[\sum_j v_{kj} g \left(\sum_i w_{ji} I_i \right) \right] \quad \dots\dots\dots (8)$$

ここで v_{kj}, w_{ji} はそれぞれ入力・中間層間, 中間層・出力層間における NN の荷重係数であり, $f(\cdot), g(\cdot)$ はそれぞれ出力層, 中間層の入出力関数である.

このとき, NN の目標出力を O_{kd} としたとき, 実際の NN の出力との誤差 e の二乗和は

$$E = \frac{1}{2} \sum e^2 = \frac{1}{2} \sum (O_{kd} - O_k)^2 \quad \dots\dots\dots (9)$$

であり, v_{kj}, w_{ji} の修正量は次のようになる.

$$\left. \begin{aligned} \Delta v_{kj}(n) &= -\eta_1 \frac{\partial E}{\partial v_{kj}} + \alpha_1 \Delta v_{kj}(n-1) \\ \Delta w_{ji}(n) &= -\eta_2 \frac{\partial E}{\partial w_{ji}} + \alpha_2 \Delta w_{ji}(n-1) \end{aligned} \right\} \quad \dots\dots\dots (10)$$

ここで, α, η はそれぞれ, 各荷重係数に対するモーメント, 学習率である. 一般に, NN の学習過程における安定性, 収束特性は α, η の値に依存している. しかしながら, NN の内部関数は複雑であり, NN が安定であるための, α, η の値を決定する一般的な解析的解法は定まっていない. そこで, 本制御対象における NN 制御系が, 安定であるための α, η の適用範囲を数値シミュレーションを行って調べた.

NN を制御系に適用し, 逆システムを獲得させる方法としては, 大きく分けて

1. 直接学習法

Fig. 3 Block diagram of direct inverse control system

Fig. 4 Block diagram of feedback-error-learning control system

(a) The direct inverse control system ($\eta=0.015$) (b) The feedback-error-learning system ($\eta=0.006$)

Fig. 5 Training curve

2. 並列学習法

の二つに分類できる。1. は NN の出力を直接制御入力として用い、逆システムを獲得する方法であり⁽¹⁾、2. は NN の出力と従来の制御系の出力の和を制御入力とするタイプであり、代表的なものにフィードバック誤差学習法⁽⁷⁾がある。

本論文ではまず、NN の学習方法として、直接学習法およびフィードバック誤差学習法の二つの学習方法を用いて、本対象システムに対する NN の学習時における安定性を調べた。図 3 および 4 は、それぞれの学習方法を用いた場合のブロック線図である。

シミュレーションにおける先端目標波形として、周期 0.2 s、振幅 4.5×10^{-6} m の正弦波を用いた。サンプリングレートは 1.0×10^{-3} s とした。NN はサンプリングごとに学習する逐次修正形とし、最大学習回数は 2000 周期とした。また、誤差は 1 周期分の誤差の自乗和で表している。図 5 は、 α の値を変化させたときの、それぞれの学習方法による学習時の誤差の推移を示している。このとき η の値は、直接学習法では 0.015、並列学習法では 0.006 の各値を用いている。図 5(a) からわかるように、直接学習法による学習において、モーメント α の値によっては、学習初期段

(a) The direct inverse control system

(b) The feedback-error-learning system

Fig. 6 Error surface

Fig. 7 Block diagram of reference signal self-organizing control system

階において、誤差が大きくなってしまふことがある。また、図 5 (b) のフィードバック誤差学習法における学習過程においては、 α の値によらず、350 周期目あたりの誤差が増加していることがわかる。

図 6 は、 α, η の値を変化させていったときの最終的な誤差を示している。図 6(a), (b) において、 α の値は零から 0.5 まで 0.1 刻みで変化させ、 η の値は 0 から 0.03 まで 0.003 刻みで変化させたときの誤差の二乗和をプロットしてある。これらの図において、学

習が収束せずに発散した場合は黒く塗りつぶしてある。図6を見ると、フィードバック誤差学習に比べて直接法の方が学習収束安定範囲が広く、また、その最小二乗和誤差は、フィードバック誤差学習の場合が0.154、直接法の場合が0.162となっている。これらのことから、本制御対象に関しては、直接学習法がより安定した制御ができるものと思われる。しかしながら、直接法では実際に制御を行う際に、センサノイズや予期せぬ外乱の影響で、学習の初期の段階でシステムが不安定になってしまい学習が不成功になってしまうことが考えられる。このような問題に対し、制御系に閉ループ系を加えシステムを安定化し、ある程度の外乱にも対応できるようにすることによって、NNの学習が成功しやすくなるものと考えられる。

そこで本論文では、図3において、閉ループ系が安定になるような比例ゲインをかけた閉ループ系を含んだシステムをプラントとして用いる「目標値補正型NN」を提案する。この方法では、閉ループ系において安定化制御を行い、NNは新しい目標値を出力する目標入力フィルタの役割を果たしていると考えられることができる。図7に目標値補正型NN制御系のブロック線図を示す。図7において、網掛けした閉ループ系では通常のフィードバック量に目標値を加えあわせた値を、プラントへの制御入力として用いている。これは制御対象の高分子圧電素子の動作において、印加電圧と先端位置が比例関係にあるため、定常位置においても電圧を加え続けなければならないためである。

また、従来形のBP法を用いた場合、誤差がある目標値に収束するまでに時間がかかることが問題となってくる。そのため、本論文では学習の効率化と学習回数を短縮する目的で、下記の二つの学習方法を導入した。

(a) 適応学習率を用いた高速逆伝播法(ALBP法)⁽⁸⁾

ALBP法における荷重係数の更新式は式(10)と同様であるが、適応学習率を用いることにより学習回数の短縮をねらった学習法である。適応学習率とは、ある初期学習率から学習を開始し、学習が高速かつ安定に収束するように、ある定められた学習率増加係数や学習率減少係数を用いて学習率を変化させる方法である。また、学習過程において、誤差がある設定した誤差率より大きい割合で増加する場合に、学習率を初期学習率に引き戻し、学習が発散しないようにしている。

(b) Levenberg-Marquardt法(LMBP法)⁽⁹⁾

通常、BP法是最急降下法を用いて最小値探索を行

っているのに対して、この方法はニュートン法と最急降下法を併用して最小値探索を行っていく。式(9)を荷重係数 w に関して最小にしたいとき、ニュートン法において、変化率 Δw は

$$\Delta w = -[\nabla^2 E]^{-1} \nabla E \quad (11)$$

と表現できる。ここで、 $\nabla^2 E$ はヘッセ行列であり、 ∇E は E の傾きである。また、式(9)は、NNの目標出力と実際のNNの出力との誤差 e の二乗和であることから、

$$\nabla E = J^T e \quad (12)$$

$$\nabla^2 E = J^T J + S \quad (13)$$

とすることができる。ここで、 J はヤコビアンであり、

$$S = \sum_{i=1}^N e_i \nabla^2 e_i \quad (14)$$

である。 $S \approx 0$ において、式(11)は、

$$\Delta w = [J^T J]^{-1} J^T e \quad (15)$$

となり、ガウスニュートン法と考えることができる。

以上のことからLevenberg-Marquardt法における更新式は

$$\Delta w = [J^T J + \mu I]^{-1} J^T e \quad (16)$$

と書くことができる。ここで μ はスケーリングパラ

(a) Learning with Momentum

(b) Momentum & Adaptive Learning Rate

(c) Levenberg-Marquardt Approximation

Fig. 8 Time response of the displacement after training (Numerical simulation)

(a) Learning with Momentum

(b) Momentum & Adaptive Learning Rate

(c) Levenberg-Marquardt Approximation

Fig. 9 Training curve (Numerical simulation)

メータと呼ばれる係数で、誤差 E が減少する場合に、 μ を大きくし、逆に E が増加していく場合には μ を小さくする。

このように μ を変化させることにより、 μ の値が大きいときには最急降下法を用いて最小値探索を行い、 μ が小さいときはガウスニュートン法を用いて最小値探索を行うことになる。

以下では、図 7 の制御系を用い、BP 法、ALBP 法、LMBP 法の三つの学習法について、学習速度や収束のようすについて比較・検討を行う。

4. 数値計算結果

図 7 において、プラントには三次モードまで考慮に入れたモデルを用い、先端目標変位には周期 0.2 s、振幅 4.5×10^{-6} m の正弦波を用いた。NN は、入力、中間層 2 層、出力層の 4 層構造とし、それぞれのユニット数は 4, 5, 5, 1 個とした。中間層の入出力関数にはバイポーラ型のシグモイド関数

$$g(u) = \frac{2}{1 + \exp(-u)} - 1 \quad \dots\dots\dots (17)$$

を用いた。学習は 1 周期ごとの一括修正を行うようにして演算時間の短縮を試み、目標出力とプラント出力の差を誤差とし、一周分分の誤差の二乗和の目標最小誤差は 1.0×10^{-2} に設定した。また、最大学習回数は

Fig. 10 Experimental Setup

(a) Without neural controller

(b) With neural controller

Fig. 11 Time response (Experimental results)

2000 周期とした。本論文では、LMBP 法における μ の初期値として $\mu_{ini} = 1.0 \times 10^{-3}$ とし、最大値として $\mu_{max} = 1.0 \times 10^{10}$ とし、10 刻みで自動的に変化させた。このとき、図 7 における Gain の値は 0.22 を用いた。

図 8 に、それぞれの学習方法での学習後の目標波形とプラントの出力を示してある。図 8 を見る限りどの学習方法も良好な結果を示している。しかしながら、図 9 の誤差の学習曲線を見てみるとそれぞれの学習過程と最小収束誤差にかなりの違いが見られる。

図 9 (b) において 708 周期目以降、誤差が一定になっている。これは学習率が初期学習率(本論文では

1.0×10^{-3} に設定)に引き下げられるためにおきている。このため、これ以上学習が進まず、最大学習回数まで学習してしまっているものと思われる。

図9(c)においては、わずか7周期をもって学習が終了しており、ほかの方法に比べて著しく学習回数が少なく、かつ効率的に学習が行われ、学習の高速化において十分満足のいく結果を得ることができている。

5. 実験結果

本論文において、制御系設計はすべて数値計算支援ソフトである MATLAB を用いて行った。また、前節の数値計算結果から、LMBP 法が優れていることから、この数値シミュレーションで得られた結果を用いて NN コントローラの実装実験を行った。また、NN は積和演算を多用することから、演算処理の高速化のためにデジタル信号処理を専門に行う DSP (Digital Signal Processor) を用いて、コントローラの実装を行った。本研究では、dSPACE 社製 TMS 320 C 31 浮動小数点 DSP シングルコントローラボード (40 MFlops), 16 bit 10 μ s AD コンバータ, 12 bit 4 μ s DA コンバータを用いて制御系の実装実験を行った。

図10は実験装置の概略を示している。本論文では、高分子圧電素子フレキシブルマイクロアクチュエータとして、Penwalt 社製 KYNER PIEZO FILM BDT 1-028 A を用いた。実験におけるサンプリングレートは 1.0×10^{-3} s とし、NN における各荷重係数の初期値はシミュレーションによって得られたものを用いた。

また、先端目標変位はシミュレーション時と同様に、周期 0.2 s, 振幅 4.5×10^{-6} m の正弦波を用いた。図11(a)は、図7における網掛けをしてある部分の閉ループ系を用いた場合の実験結果であり、図11(b)は、NN コントローラを制御系に入れたときの実験結果である。シミュレーションと同様に、図7における Gain の値は 0.22 を用いた。

図11(a)のときに見られた位相遅れや振幅の違い、中心軸のずれは図11(b)では見られず、NN コントローラを用いることによってマイクロアクチュエータの応答がかなり改善されることがわかる。なお、図11におけるスパイク状の高周波ノイズは、使用しているワークステーションや DSP からのノイズである。

以上の結果から、本論文で提案した NN コントローラのフレキシブルマイクロアクチュエータの先端位置追従制御系に対する有効性が、数値シミュレーションと実装実験の両面から確認できる。

6. ま と め

本論文では、高分子圧電素子を用いたフレキシブルマイクロアクチュエータの先端位置追従制御系に対して NN を用いた制御系として「目標値補正形 NN」を提案した。また、NN の演算時間短縮のため、新しい学習法として適応学習率を用いた高速逆伝ば法と Levenberg-Marquardt 法を導入し、数値シミュレーションを行い、その結果を用いて作成したコントローラを DSP に実装し、その制御性能を実験的に検証した。その結果、シミュレーションにおいては演算時間が短縮され、オーバーシュートがよく押さえられており、目標軌道に追従した満足のいく結果を得ることができた。しかし、実験においては、ワークステーションと DSP からのノイズによるスパイク状の成分が応答波形に現れており、これらの影響によって NN の学習が発散してしまうこともあった。また、分布定数系システムの場合、学習すべき周波数成分が多数存在し、そのために学習が失敗する確率が高いと考えられる。これらの欠点を克服するために、状態推定器などを付加し、システムの内部状態を考慮に入れた学習方法についての検討を今後の課題とし、次の機会に報告する。

文 献

- (1) Narendra, K. S. and Parthasarathy, K., Identification and Control of Dynamical Systems Using Neural Networks, *IEEE Trans. on Neural Networks*, 1-1 (1990), 4-27.
- (2) 新井史人・柴莉莉・福田敏男, 柔軟構造物のフレキシビリティ制御(第5報, ニューラルネットワークを用いた柔軟材の位置・姿勢制御), 機論, 59-562, C(1993), 155-162.
- (3) 小島宏行・張 敏・松浦勉・ほか2名, フレキシブルロボットアームの位置と力のニューロ適応制御, 機論, 59-562, C(1993), 163-168.
- (4) Register, A., Book, W. and Alford, C. O., Artificial Neural Network Control of a Nonminimum Phase, Single-Flexible-Link., *Int. Conf. Rob. Auto.*, (1996), 1935-1940.
- (5) 高橋和彦・山田一郎, ニューラルネットワークコントローラによる弾性アームの制御(1リンク弾性ロボットアームの位置決め制御), 日本機械学会第71期全国大会講演論文集(E), (1993-10), 525-527.
- (6) 佐々木実・猪岡光, 高分子圧電素子アクチュエータの動特性と動的制御, 機論, 57-534, C(1991), 174-178.
- (7) 川人光男・宇野洋二・鈴木良次, 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.
- (8) Vogl, T. P., Mangis, J. K., Zink, W. T. and Alkon, D. L., Accelerating the Convergence of the Back-Propagation Method. *Biological Cybernetics*, 59(1988), 257-263.
- (9) Hagan, M. T. and Menhaj, M. B., Training Feedforward Networks with the Marquardt Algorithm. *IEEE Trans. on Neural Networks*, 5-6 (1994), 989-993.