

フィードバック線形化に基づく 非線形システムの制御

大西 隼人*・小路口心二*・横田 真一**

Control of Nonlinear System based on Feedback Linearization

Hayato OHNISHI, Shinji KOJIGUCHI, Shinichi YOKOTA

Abstract

This paper addresses the problem of feedback linearization of nonlinear systems. Feedback linearization is defined as the problem of finding a change of coordinates and a suitable nonlinear feedback law for a given nonlinear system, such that it behaves like a linear one. Differential geometry application to nonlinear control systems enables the system to be globally or locally feedback linearizable. Most of the work in linearization is based on the premise that the nonlinear model of the physical system is precisely known with its parameters exactly defined. However, in practical applications, the system dynamic behavior may exist as empirical data (more likely black box systems). This paper emulates Lie derivatives which realize change of coordinates using Artificial Neural Networks (ANN). ANNs are trained by error back propagation. Finally, the relative degree of feedback linearization is determined and a nonlinear feedback law is established.

1. はじめに

一般に非線形システムの制御にはかなり困難を伴う。主として数学的モデル（これは現実システムを記述していると仮定されている）が複雑で容易に解析されず、制御則の決定と実現に困難を伴うためである。このような状況の下で、非線形システムを線形化することは魅力的方法である。なぜなら線形化が実現された後は、線形システム理論からの幅広い制御用ツールが使用可能となるからである。非線形システムをフィードバック線形化によって制御することは、非線形制御の分野で重要な中心問題となってきた。

フィードバック線形化は与えられた非線形システムが、線形システムの挙動を示すような座標変換と適当な非線形フィードバック則を見出す問題として定義され、それは元の非線形システムモデルを一つの簡単な形の等価モデルに変換する。制御システムに微分幾何学を適用することにより非線形システムが大域的または局所的に

フィードバック線形化可能であるための必要且つ十分条件が得られている。[1]

システムの相対次数 r が状態変数の個数 n に等しい場合、正確なフィードバック線形化が行われるが、相対次数と状態変数の個数が等しくない場合、部分的な線形化にとどまる。この場合システムは二つのサブシステムに分解される。第一のサブシステムは線形であり、第二のサブシステムは内部ダイナミックスと呼ばれる不観測性のシステムである。またシステムがフィードバック線形化（または部分的線形化）のための条件を満足していない場合、近似的なフィードバック線形化を考えることができる。[2]

しかし、これらの線形化技法は物理的システム（現実のシステム）の非線形システムモデルのパラメタが正確にまた完全に定義されているという前提に立っているということを指摘しなければならない。現実のアプリケーションにおいては、システムのダイナミックスが実験データとしてのみ把握され得るような、いわゆるプラッ

*電子情報工学科 **大学院工学研究科
平成10年9月29日受理

クボックス的な制御対象を扱わねばならないことが多い。この場合、線形化手法の適用はできなくなる。本論文は人工ニューラルネットワーク (ANN) を適用して、このような制約を緩和しようとするものである。すなわち線形化に必要となるLie導関数を ANN でエミュレートし、座標変換と相対次数の確定を行い、それに基づいてフィードバックを実施するもので、線形化の理論過程を逐次なぞるものである。これはフィードバック線形化に対し、ANN を適用した他の研究 [3] ~[9] と方法を異にしている。本論文と同様な方法での研究報告があるが [7]、ANN の訓練データの収集にかなり問題があると考える。すなわちシステムをある状態に遷移（初期遷移）し、そこで入力をゼロに固定し、その後のシステムのダイナミックスデータを収集するといった不自然な操作を必要とする。対象となる状態空間全体において適当な分布のデータを収集するために初期遷移をどのように達成するかなど、現実には、はかり知れない面倒さを伴う。

本研究では、このような面倒な操作から免れており、ANN の訓練、相対次数の確定、フィードバック制御則の実現等において、簡単化と効率の向上を実現した。最後に提案したシステムを Van der pol システムに適用した事例を示す。

本論文は 1 入力 1 出力 (SISO) 非線形アファインシステムに関するものであるが、多入力多出力 (MIMO) システムにも容易に拡張され得る。

本論文は以下、2 章においてフィードバック線形化理論を提示し、3 章にて ANN の学習による座標変換と相対次数の確定、フィードバック則の実現など本研究の中心となる事項を記述する。4 章にて Van der pol の事例によって本技法を補足説明する。最後に研究成果と今後の展開を述べる。

2. フィードバック線形化

ここでは連続時間、1 入力 1 出力 (SISO) の非線形システムに対する相対次数、入力一出力線形化制御系の構成について記述する。

(2.1) 式で表現される非線形アファインシステムを考察の対象とする。

$$\begin{aligned}\dot{x}_1 &= f_1(x_1, x_2, \dots, x_n) + g_1(x_1, x_2, \dots, x_n)u \\ \dot{x}_2 &= f_2(x_1, x_2, \dots, x_n) + g_2(x_1, x_2, \dots, x_n)u \\ &\vdots \\ \dot{x}_n &= f_n(x_1, x_2, \dots, x_n) + g_n(x_1, x_2, \dots, x_n)u\end{aligned}$$

$$\begin{aligned}y &= h(x_1, x_2, \dots, x_n) \\ (2.1)\end{aligned}$$

これらは (2.2) 式のような形に書かれる。

$$\begin{aligned}\dot{x} &= f(x) + g(x)u \\ y &= h(x) \\ (2.2)\end{aligned}$$

ここで $x \in \mathbb{R}^n$, $u \in \mathbb{R}$, $y \in \mathbb{R}$, $f(x)$ 及び $g(x)$ はベクトル場であり $h(x)$ はスカラーである。また $f(x) \in \mathbb{R}^n$, $g(x) \in \mathbb{R}^n$, $h(x) \in \mathbb{R}$ とする。

2.1 相対次数

1 入力 1 出力制御システムに対しての相対次数 r は、出力 $y(t)$ を何回時間微分すれば式の中に入力 $u(t)$ が明示的に出現するかという、その回数で定義される。

(2.1) 式あるいは (2.2) 式で記述されるシステムが相対次数 $r = 1$ を持つならば、出力 $y(t)$ の 1 次微分は

$$\dot{y} = L_f h(x) + L_g h(x) u \quad (2.3)$$

によって与えられる。ここに $L_f h(x)$ と $L_g h(x)$ はベクトル場 $f(x)$ と $g(x)$ の方向におけるスカラー関数 $h(x)$ の Lie導関数として知られている。すなわち、

$$\begin{aligned}L_f h(x) &= \sum_{i=1}^n \frac{\partial h(x)}{\partial x_i} f_i(x) \\ L_g h(x) &= \sum_{i=1}^n \frac{\partial h(x)}{\partial x_i} g_i(x) \quad (2.4)\end{aligned}$$

もし $L_g h(x) = 0$ なら、 $r \neq 1$ である。相対次数が $r = 2$ ならば、出力 $y(t)$ の 2 次微分は

$$\ddot{y} = L_f^2 h(x) + L_g L_f h(x) u \quad (2.5)$$

によって与えられる。ここに

$$\begin{aligned}L_f^2 h(x) &= \sum_{i=1}^n \frac{\partial L_f h(x)}{\partial x_i} f_i(x) \\ L_g L_f h(x) &= \sum_{i=1}^n \frac{\partial L_f h(x)}{\partial x_i} g_i(x) \quad (2.6)\end{aligned}$$

一般に

$$\begin{aligned}L_g L_f^i h(x) &= 0, (i=1, \dots, r-2) \\ L_g L_f^{r-1} h(x) &\neq 0 \quad (2.7)\end{aligned}$$

ならば、(2.1) 式あるいは (2.2) 式の非線形システムは相対次数 r を持つと言われる。また $L_f^0 h(x) = h(x)$ である。

2.2 入力一出力線形化

システム (2.1) 式が相対次数 r を持つならば、座標変換

$$\begin{aligned}z &= \phi(x) = [\phi_1(x) \phi_2(x) \cdots \phi_n(x)]^t \\ &= [z_1 \ z_2 \ \cdots \ z_n]^t \quad (2.8)\end{aligned}$$

が存在する。この新しい座標によるシステムの状態方程式は

$$\dot{z}_1 = z_2$$

$$\begin{aligned}
 \dot{z}_2 &= z_3 \\
 &\vdots \\
 \dot{z}_{r-1} &= z_r \\
 \dot{z}_r &= L_f^r h(x) + L_g L_f^{r-1} h(x) u \\
 &\quad \triangle b(x) + a(x) u \\
 \dot{z}_{r+1} &= L_f \phi_{r+1}(x) + L_g \phi_{r+1}(x) u \\
 &\vdots \\
 \dot{z}_n &= L_f \phi_n(x) + L_g \phi_n(x) u
 \end{aligned} \tag{2.9}$$

で与えられる。ここで

$$\begin{aligned}
 \phi_1 &= h(x) \\
 \phi_2 &= L_f h(x) \\
 &\vdots \\
 \phi_r &= L_f^{r-1} h(x)
 \end{aligned} \tag{2.10}$$

であるが、残りの $(n-r)$ 個の関数 $\phi_{r+1}, \dots, \phi_n$ は、写像 $\phi(x)$ が正則なヤコビアンを持つように選ばれるものとする。

相対次数 r が状態の個数 n に等しい場合 ($r=n$)
この場合 (2.9) 式は

$$\begin{aligned}
 \dot{z}_1 &= z_2 \\
 \dot{z}_2 &= z_3 \\
 &\vdots \\
 \dot{z}_{n-1} &= z_n \\
 \dot{z}_n &= L_f^n h(x) + L_g L_f^{n-1} h(x) u
 \end{aligned} \tag{2.11}$$

となり、システムに対する入力が

$$u = \frac{v - L_f^n h(x)}{L_g L_f^{n-1} h(x)} \tag{2.12}$$

と定義されるなら、得られたシステムは新しい入力 v と出力 y との間で線形となる。制御において、規範信号 y_r を漸近的にトラッキングすることが要請されているなら

$$v = y_r^{(n)} - \sum_{i=1}^n c_{i-1} (z_i - y_r^{(i-1)}) \tag{2.13}$$

を適用する。ここで、 $y_r^{(i)}$ は y_r の i 次の時間微分を表す。 c_0, c_1, \dots, c_{n-1} は実数とする。誤差 $e(t)$ を

$$e(t) = y(t) - y_r(t) \tag{2.14}$$

と定義する。フィードバック則 (2.13) を適用すれば

$$c_r^{(n)} + c_{n-1} e^{(r-1)} + \dots + c_1 \dot{e} + c_0 e = 0 \tag{2.15}$$

が得られる。特性方程式 (2.15) 式の根は、定数 c_0, c_1, \dots, c_{n-1} の選択によって任意に決定され得る。

相対次数 r が状態の個数 n よりも小さい場合 ($r < n$)
 $\dot{z}_r = b(x) + a(x) u$

に対して

$$u = \frac{v - b(x)}{a(x)} \tag{2.17}$$

を適用することによって、部分的線形化が実現される。この場合システムは、2個のサブシステムに分解される。一つのサブシステムは (2.17) 式のフィードバック則によって実現される次数 r の線形システムである。他は次数 $(n-r)$ の非線形システムであり、内部ダイナミクスと呼ばれ出力では観測できない。

本論文で提案された技法は、システムについてどんな予備知識も持たないで制御を行うことを目的としている。従って、前もってフィードバック線形化のための条件を検証することは不可能である。そのため事前に条件が検証されており線形化手法が適用されるものと仮定して以下に記述する線形化技法を行うことになる。

3. 線形化技法

たとえ非線形プラントのダイナミックス特性があまり複雑でないとしても、その詳細な構造とパラメタは現実の状況において未知の場合が多い。このようなケースでは前章で記述した結果はそのまま適用できない。本研究では座標変換 ϕ を見出すため人工ニューラルネットワーク (ANN) に基づいた方法を提案する。

ここでは非線形システムは一つのブラックボックスとして取り扱われる。プラントダイナミックスについてどんな予備知識も有していないので、相対次数 r も未知である。システム状態変数 x から新しい状態変数 z への写像として座標変換 (2.10) 式を眺めると、この写像を ANN でエミュレートすればよいと気づく。相対次数 r の確定と $h(x), L_f h(x), L_f^2 h(x), \dots, L_f^r h(x), L_g L_f^{r-1} h(x)$ などのエミュレートがここでのトピックスとなる。ANN は以下の操作手順によって訓練される。

Step 0

最初、Fig. 1 に示す構成によって、ニューラルネットワーク NN_0 を訓練する。入力 u によって励起されたシステムの状態変数 x とシステム出力 y を観測し、これの対信号を教師信号として NN_0 を訓練する。 NN_0 は $h(x)$ をエミュレートするように学習させられる。ANN としては、Fig. 2 に示すような 3層構造を持ったニューラル

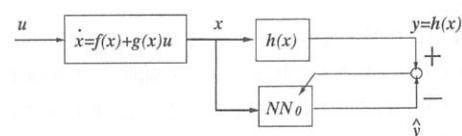


Fig. 1: Training scheme for y

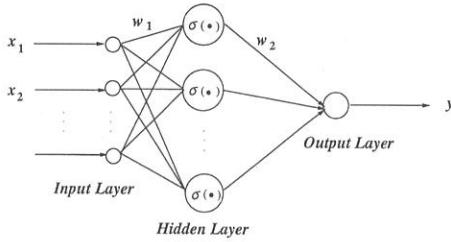
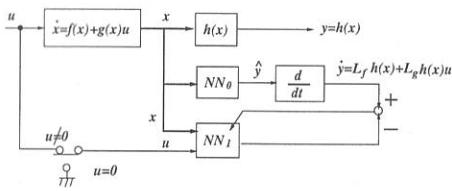


Fig. 2: Neural network scheme

Fig. 3: Training scheme for \dot{y} and Test for $r=1$

ネットワークを使用した。入力層と出力層は線形要素であるが、隠れ層は $\tanh(\cdot)$ なる非線形写像を行う人工ニューロンで構成されている。学習はバックプロパゲーションによって層間の結合係数 w_1, w_2 を調整することによって行われる。

Step 1

次に Step 0 で得た NN_0 を使用して、Fig. 3 に示す訓練システムを構成する。 NN_0 の出力 \hat{y} の時間微分は $\dot{\hat{y}} = L_f h(x) + L_g h(x)u$ と書けるので、 x と u を入力として $\dot{\hat{y}}$ の時間微分データを出力としてニューラルネットワーク NN_1 を訓練する。訓練終了後、入力切替 SW によって入力 u を強制的に $u=0$ に固定した場合と、 $u \neq 0$ の場合との NN_1 出力応答をチェックする。もし差がないならば、 u は明示的な影響を与えていないと判断し $\dot{y} = L_f h(x) + L_g h(x)u$ において $L_g h(x)=0$ とみなす。すなわち相対次数 $r \neq 1, r > 1$ と結論し次のステップへ進む。もし応答に差があれば $L_g h(x) \neq 0$ で $r=1$ と結論する。

Step 2～(r-1)

Step 1 の操作と同様に $\ddot{y}, \dots, \dot{y}^{(r-1)}$ について、逐次訓練と相対次数のテストを行う。

Step r

Fig. 4 は相対次数が $(r-1)$ ではないことが判明し、次のステップに進んだ状況で $y^{(r)}$ を訓練し、相対次数 r のテストを行うための構成を示している。Fig. 4 において破線で囲んだ部分、即ち NN_1, \dots, NN_{r-1} は Step 1 から Step $(r-1)$ の過程で訓練されたニューラルネット

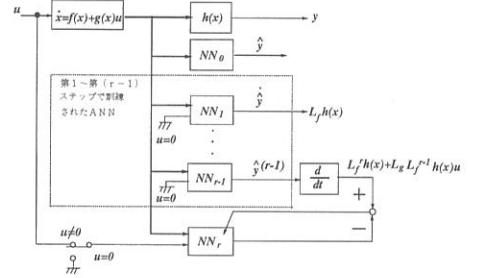
Fig. 4: Training scheme for $y^{(r)}$ and Test for r

Table. 1: Emulated functions in ANN

NN_0	$h(x)$
NN_1	$L_f h(x)$
NN_2	$L_f^2 h(x)$
\vdots	\vdots
NN_{r-1}	$L_f^{r-1} h(x)$
NN_r	$L_f^r h(x) + L_g L_f^{r-1} h(x)u$

ワークである。これらのネットワークは入力 u には無関係なので、これにいかなる値を入力しようとも出力には影響しない。ここでは分り易くするため、各ニューラルネットワークの入力 u 端子にはゼロの入力が与えられている。

相対次数が r の場合、Fig. 4 の構成でニューラルネットワークを訓練した後 NN_r に対し $u=0$ とした場合と、 $u \neq 0$ とした場合とで出力に相違が生じる。即ち $L_g L_f^{r-1} h(x) \neq 0$ となる。これによって相対次数 r を確定

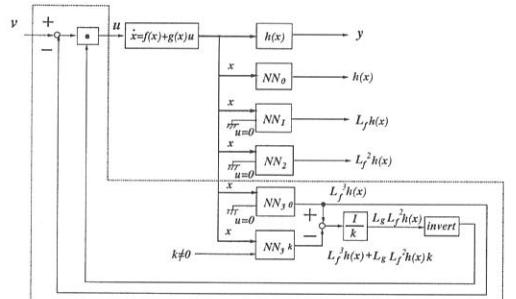


Fig. 5: Feedback Linearization

できる。

以上で各ニューラルネットワークの訓練を終了する。ここまでに訓練されたニューラルネットワークの個数は $(r+1)$ 個であり、それぞれ Table. 1 に示す関数をエミュレートする。

これによって、 $NN_0 \sim NN_{r-1}$ の出力は (2.10) 式の座標変換を実現し得ることが分る。次にフィードバック則を実現するため、Fig. 5 のようなシステムを構成する。簡単化のため、 $r=3$ の場合について示す。Fig. 5において、 $r=3$ ステップで訓練されたニューラルネットワークと同じものを 2 個準備し、一方には $u=0$ 、他方には一定入力 $u=k(\neq 0)$ を入力する。そして各々 NN_{30}, NN_{3k} と番号付けをする。元来 NN_3 の出力は $L_f^3 h(x) + L_g L_f^2 h(x)u$ であるが、 NN_{30} では $L_g L_f^2 h(x)u$ の項が強制的にゼロとされており、 NN_{3k} では $L_f^3 h(x) + L_g L_f^2 h(x)k$ となる。この差を取り、これに $1/k$ を掛けると、 $L_g L_f^2 h(x)$ なる項が抽出される。これの逆数を取り、 $[v - L_f^3 h(x)]$ と掛算することによって $(v - L_f^3 h(x)) / L_g L_f^2 h(x)$ なるフィードバック制御を実現できる。Fig. 5 の破線で囲まれた部分は、まさにこのような制御 u の実現を示す。この時

$$\dot{z}_1 = z_2$$

$$\dot{z}_2 = z_3$$

$$\dot{z}_3 = v$$

のような線形化が行われる。

次の章において、この線形化手法を Van der pol システムに適用し、これを基にトラッキング制御を実施した結果を示す。

4. 線形化手法の適用

Van der pol システムは (4.1) 式で示される。

$$\begin{aligned} \dot{x}_1 &= x_2 \\ \dot{x}_2 &= (1-x_1^2)x_2 - x_1 + (1+x_1^2+x_2^2)u \\ y &= x_1 \end{aligned} \quad (4.1)$$

状態変数 x_1, x_2 は可観測であるものとする。システムについてどんな予備知識も仮定しておらず、相対次数 r も未知である。各ステップにおいて $h(x), L_f h(x), \dots$ が A NN によって実現され、相対次数が確定されねばならない。

$y=h(x)$ を実現するブロック NN_0 は、2 入力と 1 出力、および中間層 10 個のニューロンをもつたニューラルネットワークで構成した。また \dot{y} をエミュレートするブロック NN_1 は、状態変数 x_1, x_2 及び制御入力 u の 3 入

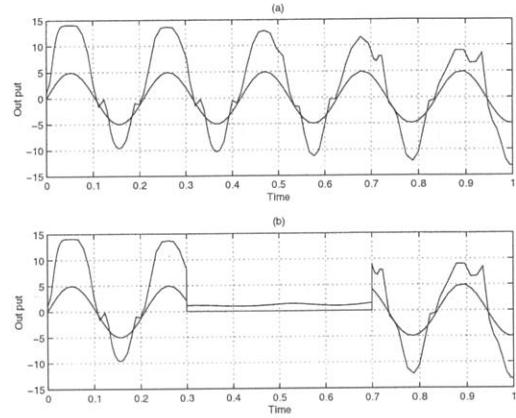


Fig. 6: Test of relative degree: time (sec) - u, \dot{y}

力と 1 出力、および中間層 10 個のニューロンをもつたニューラルネットワークで構成した。訓練終了後 NN_1 の制御入力 u をゼロまたは任意の値としても、同じ状態変数 x_1, x_2 に対しては同一出力を与えることが確認できた。従って相対次数 r は $r \neq 1, r > 1$ であると判断された。 (NN_1) の出力は制御入力 u に依存しないので、以後 $u=0$ に固定した)

NN_1 の出力の時間微分は \dot{y} に相当する。これをエミュレートするブロック NN_2 は同様に、状態変数 x_1, x_2 と入力 u の 3 入力と 1 出力、および 25 個の中間層ニューロンをもつたニューラルネットワークとした。訓練終了後、相対次数のテストを実施した。Fig. 6 は NN_2 の出力の入力 u に対する依存性を示す。すなわち、入力 u (正弦波形) をある時間区間 (この場合 0.3 秒から 0.7 秒まで) の間、強制的にゼロとする。この期間だけ Fig. 6(a), Fig. 6(b) の出力は異なるものとなる。これにより、 \dot{y} は明示的に入力 u に依存していると判断される。従って $r=2$ となり、相対次数とシステム次数とが一致する (この場合、大域的線形化が実現できる)。ニューラルネットワーク NN_2 は $\dot{y}=L_f^2 h(x) + L_g L_f h(x)u$ で表される写像

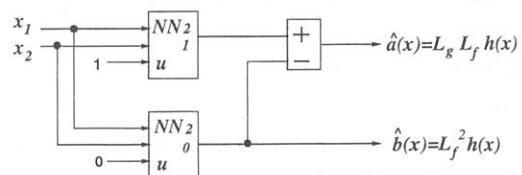


Fig. 7: Separation of $L_f^2 h(x)$ and $L_g L_f h(x)$

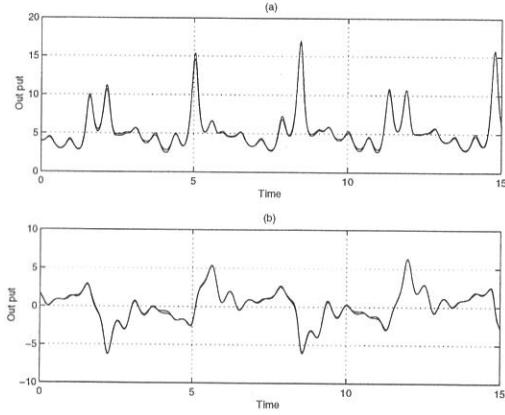


Fig. 8: (a) actual $a(x)$ and $\hat{a}(x)$, (b) actual $b(x)$ and $\hat{b}(x)$ horizontal axis: time (sec)

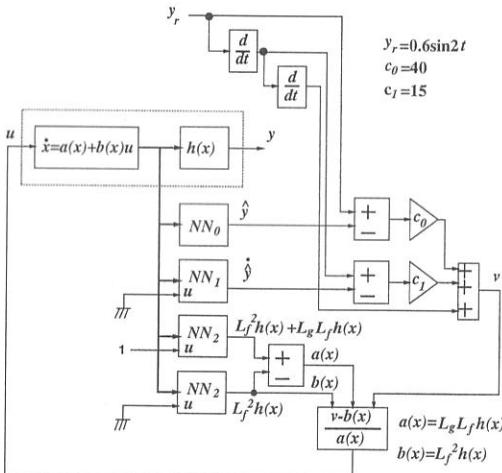


Fig. 9: Tracking control based on Linearized system

を実現している。ここで、 NN_2 と全く同じニューラルネットワークをもう一つ準備し、Fig. 7 に示す回路を構成することによって、 $L_f^2 h(x)$ と $L_g L_f h(x)$ を分離して抽出することができる。ここで $L_f^2 h(x)$ と $L_g L_f h(x)$ を $\hat{b}(x)$ と $\hat{a}(x)$ で表す。

実際の $\hat{a}(x)$ は $1+x_1^2+x_2^2=a(x)$ であり、 $\hat{b}(x)$ は $(1-x_1^2)x_2-x_1=b(x)$ である。Fig. 8 はシステムのある時間応答に対する $\hat{a}(x)$ 及び $a(x)$ 、 $\hat{b}(x)$ 及び $b(x)$ を示している。

システムの線形化を実現するため、外部指令 v に対してシステムの制御信号を $u=(v-\hat{b}(x))/\hat{a}(x)$ とする。この実験においてシステムが漸近的にトラッキングすべき

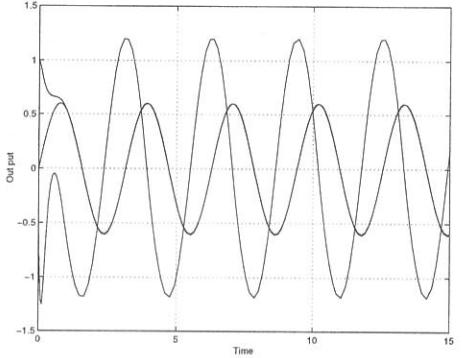


Fig. 10: Actual and desired output: time (sec)- y and y_r and control u

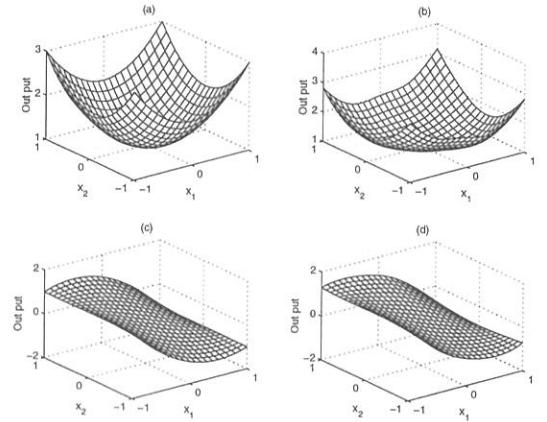


Fig. 11: Network surface: (a) $a(x)$, (b) $\hat{a}(x)$, (c) $b(x)$, (d) $\hat{b}(x)$

信号を y_r とし、 v を $v=\dot{y}_r-c_1(\ddot{y}-\dot{y}_r)-c_0(y-y_r)$ とする。Fig. 9 に線形化に基づくトラッキング制御システムの構成を示す。誤差を $e(t)=y(t)-y_r(t)$ とすると、 $u=(v-\hat{b}(x))/\hat{a}(x)$ の制御則を用いることは

$$\ddot{e}(t)+c_1 \dot{e}(t)+c_0 e(t)=0$$

であることを意味する。この特性方程式の根は定数 c_0 、 c_1 の選択によって任意に割り付けられ $t \rightarrow 0$ で $e(t) \rightarrow 0$ とすることができます。

$y_r=0.6\sin 2t$ なる規範指令信号に対して、 $c_0=40$ 、 $c_1=15$ の場合のシステム出力応答をFig. 10に示す。出力は初期値 1.0 の状態から約 1 秒で指令信号をトラッキングしていることが分る。Fig. 10には制御信号 $u(t)$ も表示している。

$\hat{a}(x)$ 及び $\hat{b}(x)$ がどの程度の精度で写像を実現しているかを検証することは大切である。Fig. 11 で(a)は $\hat{a}(x)$

の実現すべき関数（理想の状態），(b)は $\hat{a}(x)$ のニューラルネットワークで実現された関数を表示している。同様に(c)は $\hat{b}(x)$ の実現すべき関数（理想の状態），(d)は $\hat{b}(x)$ のニューラルネットワークで実現された関数を表示している。

ニューラルネットワークの訓練領域を越えた周辺領域で誤差は大きくなるが、中心部では誤差はほぼゼロとなっている。

5. おわりに

本論文において我々はシステムの非線形ダイナミックスが実験データとしてのみ把握され得るような、いわゆるブラックボックス的な制御対象に線形化技法を適用する方法を示した。それは出力 $y=h(x)$ のLie導関数 $L_f h(x), L_f^2 h(x), \dots, L_f^r h(x), L_g L_f^{r-1} h(x)$ を人工ニューラルネットワーク（ANN）でエミュレートしながら線形化の理論過程を逐次なぞる方法である。いかにして各Lie導関数を訓練するか、またいかにして相対次数 r を決定するかが問題であった。さらには $L_f^r h(x)$ と $L_g L_f^{r-1} h(x)$ の抽出等に工夫と考案がなされた。Van der polシステムにおけるトラッキング制御の実験によって検証を行い、良好なトラッキング性能を得た。ニューラルネットワークの学習精度に対して実験データを示したが、これらはデータ個数、学習回数等によって影響される。この学習方式では微分動作を行うため、ノイズの増大があると懸念される。しかしこれはANNが本来持っているノイズ排除能力によって補償されることが指摘される。

本論文にて示した考え方は、離散時間非線形システムにも適用される。これについては、同時に報告される文献[10]に詳細を記述している。

参考文献

- [1] Edited by A. J. Fossard, D. Normand-Cyrot, Nonlinear system vol. 3, ch. 4, J. Le'vine, 'Static and dynamic state feedback linearization', Chapman and Hall, 1997.
- [2] A. Krener, 'Approximate Linearization by state Feedback and Coordinate Change', Systems and Control Letters, vol. 5, pp181-185, 1984.
- [3] A. Delgado, C. Kambhampati, K. Warwick, 'Dynamic recurrent neural network for system identification and control', IEE proc.-Control Theory Appl. vol. 142 No. 4 pp307-314, 1995.
- [4] D. J. Swanston, C. Kambhampati, S. Manchanda, M. T. Tham, K. Warwick, 'Relative Order Defines a Topology for Recurrent Network', 'Artificial Neural Networks', 26-28. June 1995. Conference Publication NO. 409 @IEE, 1995.
- [5] A. Yesildirek, F. L. Lewis, 'Feedback Linearization Using Neural Networks', Automatica. vol. 31. No. 11, pp1659-1664, 1995.
- [6] M. A. Hussain, J. C. Allwright, L. S. Kershbaum, 'Nonlinear Control with Linearised Models and Neural Networks', 'Artificial Neural Networks', 26-28. June 1995, Conference Publication No. 409 @IEE, 1995.
- [7] H. A. A. Fattah, A. F. Sakr, A. Bahgat, 'Non-linear System Control Via Feedback Linearization Using Neural Networks', IEEE Int. Conf. Neural Netw. Proc. (USA) 1996 [vol. 4], pp2238-2243, 1996.
- [8] M. H. R. F. Rahman, R. Devanathan, Z. Kuanyi, 'Dynamic Neural Networks for Input-Output Linearization', IEEE Int. Conf. Neural Netw. Proc. (USA) 1996 [vol. 4], pp2214-2219, 1996.
- [9] T. Zhang, S. S. Ge, C. C. Hang, 'Neural-based direct adaptive control for a class of general non-linear systems', International Journal of System Science, vol. 28, No. 10, pp1011-1020, 1997.
- [10] 小路口心二, 横田真一, 大西隼人, 'ニューラルネットワークを使用した非線形離散時間システムの制御', 久留米工業大学研究報告, No. 22, pp81-85, 1998.