[計測自動制御学会論文集
Vol. 29, No. 3, 340/346 (1993)]

混合構造型ニューラルネットワークによるプラントの同定と最適制御のシンセシス†

横山　恭*・幸田武久*・井上紘一*

Plant Identification and Synthesis of Optimal Control by Use of Neural Network with Mixed Structure

Yasushi YOKOYAMA*, Takehisa KOHDA* and Koichi INOUE*

In this paper, firstly we propose a neural network with a mixed structure, which consists of multilayer and recurrent structure, for learning the dynamics of a nonlinear plant. A neural network with a mixed structure can learn time series, therefore, it can learn the plant dynamics without knowning the plant order.

Next, we consider the optimal control synthesis problem using the neural network with a mixed structure, which has learned the plant dynamics completely, as a plant model. Procedures are as follows: (1) the neural network is expanded into an equivalent feedforward multilayer network, (2) it is shown that the gradient of criterion functional to be optimized can be easily obtained from this multilayer network, and then (3) the optimal control is generated by applying any of the existing nonlinear programming algorithms based on this gradient information.

The proposed method is sucessfully applied to the optimal control synthesis problem of a nonlinear coupled vibratory plant with a linear quadratic criterion functional.

Key Words: neural network, optimal control synthesis, multilayer network, reccurent network, nonlinear plant

1. はじめに

1986年にD. E. Rumelhartらによって，階層構造型ニーラルネットワークに対する学習法—誤差逆伝播法—が発表されて以来[1]，様々な分野でニューラルネットワーク(以下N. N.と書く)を応用した研究がなされてきた．制御の分野でも，現在まで様々なかたちでN. N.を用いた，制御システムの研究が発表されている[2]．

あるプラントに対して制御を行おうとした場合，目的に応じた制御システムを構築する前に，対象とするプラントの動特性を表わす数学的モデルを作る行為，すなわちプラントの同定を行わなければならない．そしてこの数学的モデルに対して様々な制御理論を適用して，制御システムを構築する．プラントの同定がうまくできているか，言い換えれば数学的モデルがプラントをよく近似できているかは，それを用いて構築された制御システム自身の性能に大きな影響を与える．

プラントの同定は一般に，そのプラントを構成する要素の特性を調べることによって行われる．しかし，プラント内部の特性がブラックボックス的である場合，同定はプラントの入出力応答のみに基づいて行わざるを得ない．このような場合は決して少なくはない．入出力応答のみからプラントを支配する式を求めるのは，全く何の仮定もしなければ不可能である．従来は多くの場合，線形性と次数を仮定して同定が行われていた．すなわち，「プラント特性は線形X次方程式で表わすことができる」と仮定し，そのパラメータを入出力応答から求める方法がとられてきた．

階層構造型N. N.が非線形写像を学習できることを利用して，プラントの動特性を学習させたN. N.をプラン

† 第1回インテリジェント・システム・シンポジウムで発表(1991・10)

* 京都大学工学部　京都市左京区吉田本町
* Faculty of Engineering, Kyoto University, Kyoto

(Received June 4, 1992)
(Revised August 3, 1992)

トモデルとして制御に利用する研究がなされてきた．このことによって，同定における線形性の仮定が解消され，強い非線形性をもつプラントに対して有効な制御を行うことが可能であることが報告されている[3]．

本論文では，まず時系列を学習できるN. N.として，混合構造型N. N.を提案する．混合構造型N. N.に対しても，誤差逆伝播法に類似した学習法が存在することを示す．混合構造型N. N.ではプラントの入出力応答を直接的に時系列として学習でき，同定における次数の仮定が解消できる．つぎに，プラントの動特性を学習した混合構造型N. N.をプラントモデルとして用いて行う制御の一つとして，最適制御問題を非線形計画問題として解く方法を示す．

2. 混合構造型N. N.

2.1 階層構造型N. N.の問題点

階層構造型N. N.は写像的な入出力関係しか学習することができない．N. N.を制御に応用する場合，このことはしばしば不利な要因になる．特に変位しか計測することのできないプラントに対する制御などに，この不利な要因は現れる．このようなプラントの動特性を学習するのに階層型N. N.を用いる場合，普通は**Fig. 1**のように遅延素子や微分素子を用いて，数ステップ前の出力や出力の微分パラメータをフィードバックする方法が採られる．この方法が妥当であるためには，プラントの最大次数がNであった場合，少なくともN時刻前までの出力やN次の微分パラメータをフィードバックしなければならない．ここで，特性を同定しなければならないプラントに対して，その最大次数だけは既知でなくてはならないという問題が生じてしまう．

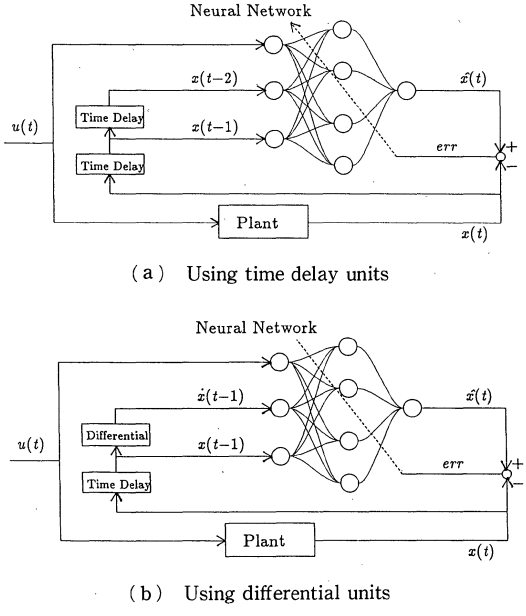

Fig. 1 Conventional method of learning plant dyamics

2.2 混合構造型N. N.

前節の問題を解決する方法として，外部に時間を考慮できるような機構を設けるのではなく，N. N.自身が内部機構によって時系列を認識できるようにすることが有効である．相互結合型N. N.は時系列を処理することができる．そこで，**Fig. 2**のような階層構造型N. N.のように階層構造をもち，中間層ユニットどうしにリカレント結合を認めた構造をもつN. N.を使用することを提案する．このようなN. N.を混合構造型N. N.と呼ぶ．混合構造型N. N.は，階層構造型N. N.と同様に1回の処理ステップ内で入力層，中間層，出力層の順で各層ごとに同期的に活性値を決定する．

Fig. 2のN. N.では，入力層のユニットは外部からの入力を受けて

$$I_k(t)=u_k(t) \tag{1}$$

によって活性値を決定する．そして中間層のユニットは，入力ユニットからの信号とリカレント結合を通して入ってくる1ステップ前の中間ユニットからの信号とを入力$net_{Hj}(t)$として受け取り，新しい活性値$H_j(t)$を決定する．

$$net_{Hj}(t)=\sum_{k=1}^{m} a_{jk}u_k(t)+\sum_{l=1}^{r} b_{jl}H_l(t-1) \tag{2}$$

$$H_j(t)=f_H(net_{Hj}(t)) \tag{3}$$

出力ユニットは，この中間ユニットからの出力を入力$net_{Oi}(t)$として受け取り，新しい活性値$O_i(t)$を決定し，これをN. N.全体の出力$x_i(t)$とする．

$$net_{Oi}(t)=\sum_{j=1}^{r} c_{ij}H_j(t) \tag{4}$$

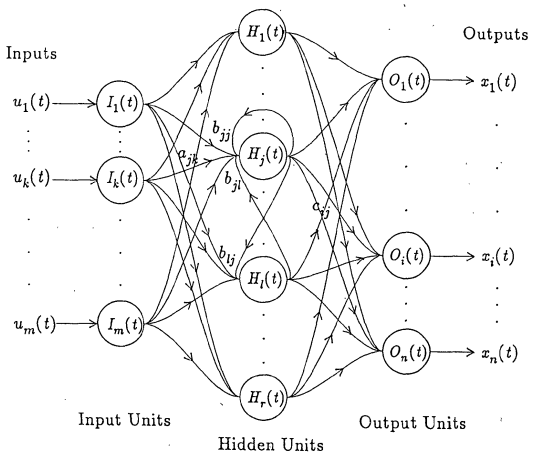

Fig. 2 Neural network with mixed structure

$$x_i(t)=O_i(t)=f_O(net_{Oi}(t)) \tag{5}$$

このようにユニットを層に分離し，層ごとに同期的に活性値を決定することによって，N. N.全体の入出力関係式は

$$x_i(t)=f_O\left(\sum_{j=1}^{r} c_{ij} f_H\left(\sum_{k=1}^{m} a_{jk} u_k(t) + \sum_{l=1}^{r} b_{jl} H_l(t-1)\right)\right) \tag{6}$$

のように表わすことができる．

2.3 混合構造型 N. N.に対する学習法

N. N.に対して学習法を考えるには，誤差関数の結合度に対する勾配を求める式，すなわち勾配計算式を導出しなければならない．そのためにはつぎの二つの方法が考えられる．

Rumelhart らが指摘した[1]ように，フィードバックを含む一般的な相互結合型 N. N.は，有限時間の範囲内では階層型に展開できる．よって，適当な時間内で混合構造型 N. N.を階層型に展開し，その結果得られた階層構造型 N. N.に誤差逆伝播法を適用することによって，誤差関数の結合度に対する勾配を求めることが出来る．この学習法は，有限時間内でのプラントの振る舞い，すなわち入出力データがわかっている場合に有効であり，いわゆるオフライン学習に適しているといえる．

また合成関数の微分を用いて直接求める方法では，誤差逆伝播法と同様の勾配計算式のほかに，連立関係式と呼ばれる入力値の結合度に関する微分の値

$$B_{ipq}(t)=\frac{\partial net_{Hi}(t)}{\partial b_{pq}},\quad A_{ipq}(t)=\frac{\partial net_{Hi}(t)}{\partial a_{pq}} \tag{7}$$

に対する式を連立させることによって，誤差関数の結合度に対する勾配が求められる．すなわち階層構造型 N. N.と同様の誤差信号

$$\hat{\delta}_{Oj}(t)=f_O'(net_{Oj}(t))\frac{\partial E_r(t)}{\partial x_j(t)} \tag{8}$$

$$\hat{\delta}_{Hj}(t)=f_H'(net_{Hj}(t))\sum_{i=1}^{n}\hat{\delta}_{Oi}(t)c_{ij} \tag{9}$$

を用いれば，勾配計算式は，

$$\frac{\partial E_r(t)}{\partial c_{pq}}=\hat{\delta}_{Op}(t)H_q(t) \tag{10}$$

$$\frac{\partial E_r(t)}{\partial b_{pq}}=\sum_{j=1}^{r}\hat{\delta}_{Hj}(t)B_{jpq}(t) \tag{11}$$

$$\frac{\partial E_r(t)}{\partial a_{pq}}=\sum_{j=1}^{r}\hat{\delta}_{Hj}(t)A_{jpq}(t) \tag{12}$$

となり，連立関係式は，

$$B_{jpq}(t)=H_q(t-1)\delta_{pj} + \sum_{l=1}^{r} b_{jl} f_H'(net_{Hl}(t-1))B_{lpq}(t-1) \tag{13}$$

$$A_{jpq}(t)=\bar{u}_q(t-1)\delta_{pj} + \sum_{l=1}^{r} b_{jl} f_H'(net_{Hl}(t-1))A_{lpq}(t-1) \tag{14}$$

によって与えられる．このような勾配計算法を連立誤差逆伝播法[4]と呼ぶ．連立誤差逆伝播法はオンライン学習に用いる勾配計算法としては，最も有力であると考えられる．

3. 混合構造型 N. N.による プラント動特性の学習

3.1 プラントの同定

あるプラントに対して何らかの制御機構を施そうとする場合，その制御機構の設計者はプラントの動特性を知り，数学的モデルを作らなければならない．このプラントの特性を知る行為を，プラントの同定と呼ぶ．まずプラントの要素や環境を調べることによって，数学的モデルの構築は試みられる．しかし，これだけで数学的モデルが構築できることは一般的に希である．できない場合，制御機構の設計者はプラントの入出力データから数学的モデルを推測しなければならない．入出力データから数学的モデルを構築するためには，普通いくつかの仮定を設ける必要がある．

たとえば最もよく行われる仮定に，プラントの線形性が挙げられる．プラントの入出力関係が，線形の微分方程式あるいは代数方程式によって表わされるという仮定である．入出力の変動の幅が小さい場合，プラントは線形的な挙動を示すことが多い．しかし，多くのプラントは非線形な特性部分をもつので，入出力の変動が大きくなると非線形的な挙動を示す．そのため，このような仮定の下で構築された数学的モデルを使用した場合，不都合が生じることが多い．

また，プラントの次数に対する仮定もよく行われる．すなわちプラントが何次の微分方程式に支配されているか，あるいは何ステップ前までの出力や入力が現在の出力に影響を与えるかを仮定するのである．この仮定も非常に問題がある．なぜなら，このような仮定は設計者の経験と勘に依存しているからである．

3.2 N. N.のプラント同定への応用

N. N.は非線形な特性を学習できる．このことを利用して，非線形なプラントの同定を行う試みが行われてきた．すなわち，非線形プラントの動特性を N. N.に学習させるのである．N. N.をプラントモデルとして用いると，同定における線形性の仮定をなくすことができる．ところが今までは，学習法が確立している階層型 N. N.を用いていたため，Fig. 1 のような方法でしかプラントの動特性を学習させることができなかった．しかし，混合構造型 N. N.を用いれば，プラントの動特性を単に入力と出力の時間的関係として出力のフィードバックなしに学習させることができる．その結果，プラントの同定における次数の仮定もなくすことができる．

3.3 プラントの動特性の学習例

非線形プラントの例として，典型的な非線形振動の一つであるRayleighの方程式から導いた仮想的な2次の非線形振動系

［プラントA］

$$\ddot{x}_1+2.5\dot{x}_1-\dot{x}_2+0.3\dot{x}_1^3+0.8x_1-0.3x_2=0$$
$$\ddot{x}_2-\frac{2}{3}\dot{x}_1+\frac{2}{3}\dot{x}_2+0.2\dot{x}_2^3-0.2x_1+\frac{8}{15}x_2=u \qquad (15)$$

の動特性の学習を，混合構造型N. N.に行わせた．この系は，平衡点（$x_1=x_2=0$）で漸近安定である(注1)．また混合構造型N. N.は離散システムなので，サンプリング時間0.1でこのプラントを離散化したものを用いた．

プラントAの入力変数の数は1，出力変数の数は2であるから，使用する混合構造型N. N.の入力ユニットの数は1，出力ユニットの数は2とし，中間層ユニットの数は15のN. N.を使用した．学習は，500サンプリング時間ごとのオフライン学習で行い，勾配法としてはBFGS（Broyden-Fletcher-Goldfarb-Shanno）法[5]を用いた．すなわち入力時系列$\{u(0),\cdots,u(500)\}$と，これに対応する出力時系列$\{x_1(0),\cdots,x_1(500)\}$，$\{x_2(0),\cdots,x_2(500)\}$を用いて，誤差関数

$$E=\sum_{t=0}^{500}\{(x_1(t)-\tilde{x}_1(t))^2+(x_2(t)-\tilde{x}_2(t))^2\}$$

をBFGS法を用いて，十分に小さな設定値ε以下になるまで減少させる．この操作をここでは，1回のオフライン学習と呼ぶこととする．学習法としてオフライン学習を用いたのは，オンライン学習が準ニュートン法や共役勾配法と相性が良くないからである．学習に用いた入力信号は**Fig. 3**に示すような，乱数矩形波信号である．このプラント学習時の，1回のオフライン学習の間の誤差関数の減少の様子を**Fig. 4**に示す．

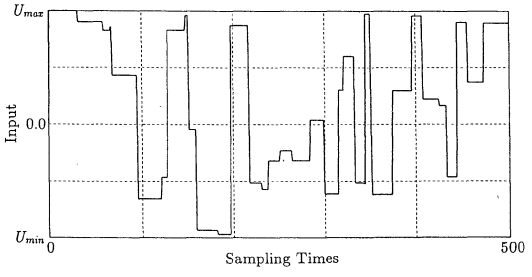

Fig. 3 Random rectangle wave used in learning of plant dynamics

（注1）(15)式を$dx/dt=Ax+f(x)$と線形部分と非線形部分に分けて表現したベクトル微分方程式に変形すると，Aのすべての固有値の実数部は負であり，かつ$\|x\|\to 0$のとき$\|f(x)\|/\|x\|\to 0$が成立するので，$x=0$は漸近安定である．

500サンプリング時間のオフライン学習（$\varepsilon=0.001$）を1回行ったN. N.をN. N. 1，2回行ったN. N.をN. N. 2とする．これら二つのN. N.が，プラントの動特性をどの程度学習しているかを知るために，その周波数応答を調べた．プラント，N. N. 1とN. N. 2のx_1に振幅0.3の正弦波入力を与えたときの周波数応答を**Fig. 5**に示す．Fig. 5から，プラントとN. N.の違いは，低周波領域よりも，高周波領域のほうに大きく現れることがわかる．そして当然のことながら，N. N. 1よりもN. N. 2のほうが，プラントの応答に近くなっている．すなわち混合構造型N. N.にこのようなプラントの動特性を学習させた場合，低周波の入出力応答は比較的速く学習できるが，高周波の応答を学習するのが遅いことがわかる．このことは，学習の進行をはかる評価基準として，高周波応答を用いることが有効であることを示している．

4. 最適制御入力の決定法

4.1 最適制御問題

プラントの動特性を学習した混合構造型N. N.を用いて，プラントに対する最適制御問題が解けることを示す．一般に非線形プラントの最適制御はつぎのように行われる．

1. プラントの数学的モデルを構築する．
2. 得られた数学的モデルに対して最適制御問題を定

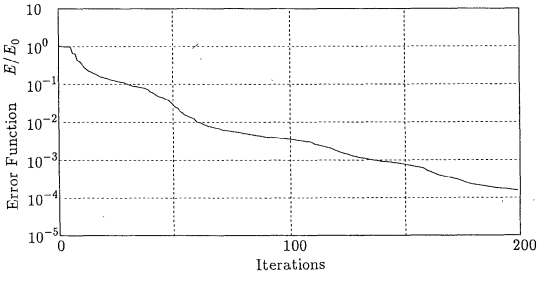

Fig. 4 Convergence properties of error function

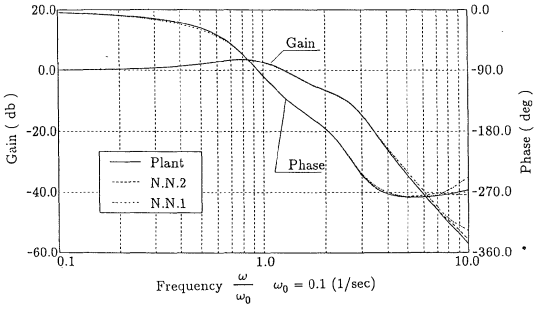

Fig. 5 Frequency response of N. N. 1, N. N. 2, and plant for $0.3\sin\omega t$

式化し，変分法や微分動的計画法などを用いて解く．

3. 得られた最適制御入力をプラントに与える．

数学的モデルがしっかりしたプラントに対しては，このような最適制御の適用は何の問題も生じない．しかし数学的モデルがあやふやな仮定の下に構築されている場合，この方法は非常に問題がある．一般に数学的モデルの精度は，行う制御が複雑になればなるほど大きな影響をもたらす．そういう意味で，最適制御は数学的モデルに高い精度を要求する．

4.2 問題の定式化

つぎの離散プラントに対する最適制御問題を考える．

［問題＊］

制御対象プラント

$$\begin{aligned} &\vec{x}(0)=\vec{x}_0 \\ &\vec{x}(t)=\vec{f}(\vec{u}(t),\ \vec{x}(t-1),\ \vec{x}(t-2),\cdots) \\ &\quad t=0,\cdots,T \end{aligned} \tag{16}$$

に対して，$\vec{x}(t)$ と $\vec{u}(t)$ によって記述される評価関数

$$E=E(\vec{x}(t),\ \vec{u}(t)) \tag{17}$$

を最小にする最適制御入力系列

$$\vec{u}_{opt}(t) \quad t=1,\cdots,T \tag{18}$$

を求める．

ここで，一般の最適制御問題と異なるところは，プラントの特性を表わす(16)式が未知であることであり，その代わりにプラントの動特性を学習した混合構造型 N. N.があることである．

4.3 混合構造型 N. N.の階層型への展開

最適制御問題を解く前に，その準備として **Fig. 6** のような階層構造型 N. N.を考える．この N. N.は，学習のときと同様な階層型展開により時刻 0 から T までに展開した N. N.に，常に活性値が 1 であるようなユニットと，このユニットと入力ユニット群との結合度として，$\vec{u}(1),\cdots,\vec{u}(T)$ を考えたものである．Fig. 6 の N. N.の出力層群の出力は，初期状態が $H_j(0)$ であるようなもとの混合構造型 N. N.に，入力時系列 $\vec{u}(1),\cdots,\vec{u}(T)$ を与えたときの出力時系列 $\vec{x}(0),\cdots,\vec{x}(T)$ に等しいことがわかる．

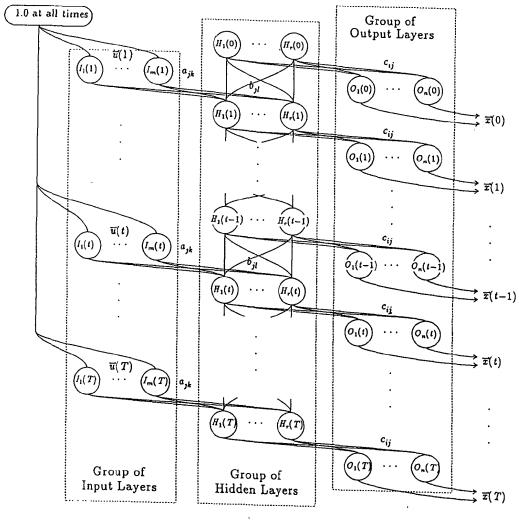

Fig. 6 Equivalent multilayer N. N. representation of N. N. with mixed structure

4.4 最適制御入力の決定法

Fig. 6 の階層構造型 N. N.を用いて，［問題＊］の解，すなわち最適制御入力を求めることが出来る．

誤差逆伝播法は，誤差関数を最小化するために誤差関数の結合度に対する勾配を求めるアルゴリズムである．一般に最小化する誤差関数 E としては誤差 2 乗和関数が用いられるが，実際には誤差関数 E の形は N. N.の出力 $x_i(t)$ の関数であればどんな形でもかまわない．いま，一般的な階層構造型 N. N.に対して，出力層のユニットに対する誤差逆伝播信号として，

$$\delta_{oi}(t)=f_o'(net_{oi}(t))\frac{\partial E(\vec{x}(\tau))}{\partial x_i(t)} \tag{19}$$

が与えられたとする．誤差逆伝播法を行って中間層のあるユニット i に逆伝播された誤差信号を δ_i とし，ユニット i に結合度 w_{ij} を通して信号を出力しているユニット j の活性値(あるいは出力)を a_j とすると，誤差関数 $E(\vec{x}(\tau))$ の結合度 w_{ij} に関する勾配は

$$\frac{\partial E(\vec{x}(\tau))}{\partial w_{ij}}=\delta_i a_j \tag{20}$$

と表わされる．

ここで，誤差関数は結合度を含む式であっても構わない．たとえば，誤差関数が

$$E=E(\vec{x}(\tau),\ w_{ij}) \tag{21}$$

で与えられている場合，合成関数の微分の公式から，

$$\begin{aligned} \frac{\partial E(\vec{x}(\tau),\ w_{ij})}{\partial w_{ij}}=&\frac{\partial E}{\partial w_{ij}}(\vec{x}(\tau),\ w_{ij}) \\ &+\sum_i \frac{\partial E}{\partial x_i(t)}\frac{\partial x_i(t)}{\partial w_{ij}} \end{aligned} \tag{22}$$

となる．右辺の第 1 項は誤差関数 E に陽に含まれる結合度 w_{ij} に対する偏微分を表わし，簡単に求められる．第 2 項の値は，出力層のユニットに対する誤差逆伝播信号として，

$$\delta_{oi}(t)=f_o'(net_{oi}(t))\frac{\partial E(\vec{x}(\tau),\ w_{ij})}{\partial x_i(t)} \tag{23}$$

を与えたとき，誤差逆伝播法で得られる誤差信号 δ_i を用いて，

$$\sum_i \frac{\partial E}{\partial x_i(t)}\frac{\partial x_i(t)}{\partial w_{ij}}=\delta_i a_j \tag{24}$$

と得られ，誤差関数の結合度に関する勾配(22)式が求められる．

Fig. 6 の N. N.において，$\vec{u}(t)$ は結合度になっている．よって[問題＊]の評価関数は，Fig. 6 の N. N.の結合度と出力で構成された式である．したがって，上で得られた結果から，評価関数の $u_p(\tau)$ に関する勾配は，

$$\frac{\partial E}{\partial u_p(\tau)}=\frac{\partial E}{\partial u_p(\tau)}(\vec{u}(t),\ \vec{x}(t))+\sum_{t=0}^{T}\sum_{i=1}^{n}\frac{\partial E}{\partial x_i(t)}\frac{\partial x_i(t)}{\partial u_p(\tau)} \tag{25}$$

となり，この式の第2項は Fig. 6 の N. N.の出力層群に誤差信号として

$$\delta_{oi}(t)=\frac{\partial E}{\partial x_i(t)}f_o'(net_{oi}(t)) \tag{26}$$

を与えたときに誤差逆伝播法から得られる，入力層群に対する誤差信号 $\delta_{ip}(t)$ を用いれば，

$$\sum_{t=0}^{T}\sum_{i=1}^{n}\frac{\partial E}{\partial x_i(t)}\frac{\partial x_i(t)}{\partial u_p(\tau)}=\delta_{ip}(\tau) \tag{27}$$

となる．したがって，勾配を求める式は

$$\frac{\partial E}{\partial u_p(\tau)}=\frac{\partial E}{\partial u_p(\tau)}(\vec{u}(t),\ \vec{x}(t))+\delta_{ip}(\tau) \tag{28}$$

となる．この式は，任意の形の評価関数に対して，そのパラメータに対する勾配が簡単な算術計算と誤差逆伝播法により求められることを示している．得られた勾配を用いれば，評価関数を最小にするような入力を求めることができる．すなわち，[問題＊]で与えられるような一般的な評価関数に対する最適制御問題を解くことができる．

4.5 計　算　例

3章で得られた，プラント A の動特性を学習した N. N. 1 と N. N. 2 を用いて，最適制御問題を解いた結果をつぎに示す．

プラント A に対して，初期状態

$$\begin{aligned}&x_1(0)=0.4 \quad x_2(0)=1.0\\&\dot{x}_1(0)=0.0 \quad \dot{x}_2(0)=0.0\end{aligned} \tag{29}$$

で，評価関数

$$\begin{aligned}&E(x_1(t),\ x_2(t),\ u(t))\\&=\sum_{\tau=0}^{100}\{x_1(\tau)^2+x_2(\tau)^2+0.2u(\tau)^2\}\\&\quad+100.0(x_1(100)^2+x_2(100)^2)\end{aligned} \tag{30}$$

を最小にする最適制御入力を求めた．

プラントを支配する(15)式がわかっているならば，微分動的計画法[6](DDP)によってこの最適制御入力は求めることができる．N. N. 1, N. N. 2 と DDP を用いて求めた入力を比較したものを **Fig. 7** に示す．これを見れば，N. N. 2 を用いて求めた入力と DDP によって求めた入力は一致しているが，N. N. 1 で求めた入力はこれらと少しずれている．また，求めた入力に対して評価関数を求めてみると，N. N. 1 は 6.70, N. N. 2 は 6.68 となり，N. N. 1 で求めたほうがよい入力であることがわかる．

このように混合構造型 N. N.を用いた方法においてもほかの方法と同様に，同定によって得られたモデルの質が制御の質に影響を与える．

評価関数を減少させるために用いた勾配法は，前出の BFGS 法である．N. N. 2 を用いたときの，評価関数の収束の様子を **Fig. 8** に，その際の制御入力の収束の様子を **Fig. 9** に示す．

5. おわりに

混合構造型 N. N.を使って制御プラントを同定することにより，同定時にプラントの線形性や次数を仮定しなくてよいことを示した．さらに，プラントの動特性を学習した混合構造型 N. N.を，プラントに対するモデルとして用いて，最適制御問題を解くことができることを示

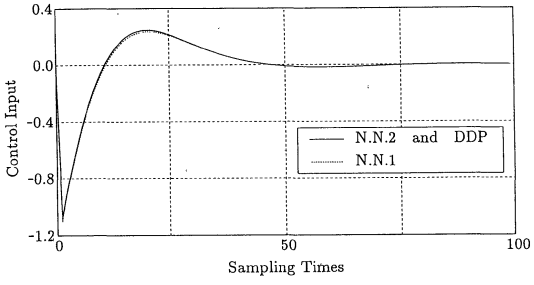

Fig. 7　Comparison of optimal control input

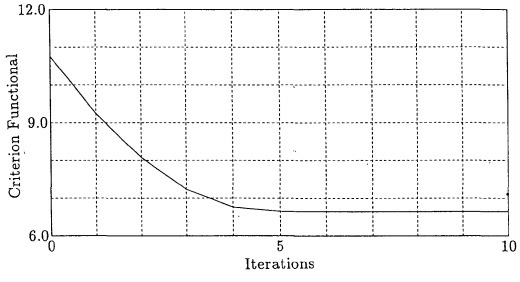

Fig. 8　Convergence properties of criterion functional

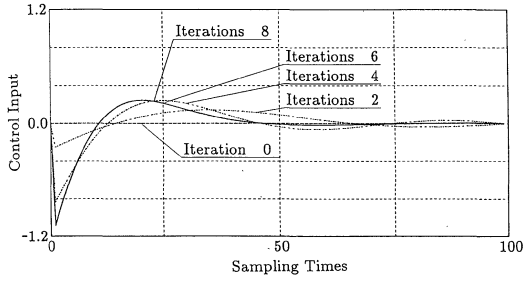

Fig. 9　Convergence properties of control input

した．また，実際に，この方法を非線形プラントに対して適用して，その動特性が学習でき，最適解が求められることをシミュレーション計算によって確かめた．

従来の階層構造型 N. N.によるプラントの動特性の学習は，プラントの入力空間と出力空間の写像関係を学習しているに過ぎない．入力と出力の対応関係を教師信号としてもっているのならば，入力空間に代表点をいくつか取り，それに対応する出力空間の点をメモリに記憶しておき，補間によって全写像を表現する方法と本質的に代わることはない．しかし，動特性の学習に混合構造型 N. N.を用いると，入力空間と出力空間のほかに時間空間に対する関係も学習できる．時間空間における関係は N. N.の内部的機構によって理解され，学習される．すなわち，われわれは入力と出力の関係だけを教師信号として意識しているだけで良く，時間的な関係は勝手に学習してくれるといって良いだろう．

時間的な関係を N. N.に学習させることは，時間的概念を要求する制御では必須である．また，混合構造型 N. N.を用いることにより，従来の N. N.には難しいとされていた，最適制御入力の発生法を比較的簡単に得ることができた．

提案した方法の今後さらに検討すべき点として，つぎのような問題がある．まず，混合構造型 N. N.は階層構造型 N. N.に比べ，N. N.の構造が複雑であるため，計算量が多くなる点が挙げられる．また，動特性が学習できないプラントも存在する．N N.に任意のプラントをシミュレートさせるためには，積和ユニットを導入する必要があろう．しかし，このことは N. N.の構造をさらに複雑にし，ノイマン型コンピュータの上でその有効性を確かめるのは難しいと考えられる．

参 考 文 献

1) D. E. Rumelhart, G. E. Hinton and R. J. Williams: Parallel Distributed Processing, **1**, 318, MIT Press (1987)
2) 北村新三：ニューラルネットワーク応用の現状と展望—計測制御の立場から，システム/制御/情報，**35**-1, 2/10 (1991)
3) D. H. Nguyen and B. Widrow: Neural Networks for Self-Learning Control Systems, IEEE Control Systems Magazine, **10**-3, 18/23 (1990)
4) R. J. Williams and D. Zipser: A Learning Algorithm for Continually Running Fully Recurrent Neural Networks, Neural Computation, **1**-1, 270/280 (1989)
5) R. Fletcher: A New Approach to Variable Metric Algorithms, Computer Journal, **13**-3, 317/326 (1970)
6) S. B. Gershwin and D. H. Jacobson: A Discrete-Time Differential Dynamic Programing Algorithm with Application to Optimal Orbit Transfer, AIAA Journal, 8-9, 1616/1626 (1970)

[著 者 紹 介]

横 山 恭

1992 年，京都大学大学院工学研究科航空工学専攻修士課程修了，同年日本電気(株)入社，現在に至る．制御理論に対するニューラルネットワークの応用に関する研究に従事．

幸 田 武 久（正会員）

1983 年，京都大学大学院工学研究科精密工学専攻博士課程修了，同年通産省工業技術院機械技術研究所入所，88 年京都大学工学部航空工学教室助手，91 年同助教授，現在に至る．システム制御工学および信頼性工学の研究に従事(工学博士)．

井 上 紘 一（正会員）

1968 年，京都大学大学院工学研究科数理工学専攻博士課程修了，同年京都大学工学部数理工学教室助手，69 年同精密工学教室助教授，86 年同航空工学教室教授，現在に至る．制御工学およびシステム工学の教育・研究に従事(工学博士)．