ファジィ評価と2次微分を考慮した 一般化学習ネットワークによるロバスト制御方式†

大 林 正 直*・平 澤 宏太郎*・利 光 克 之*
村 田 純 一*・胡 敬 炉*

Robust Control for Universal Learning Network Considering Fuzzy Criterion and Second Order Derivatives

Masanao OHBAYASHI*, Kotaro HIRASAWA*, Katsuyuki TOSHIMITSU*,
Junichi MURATA* and Jinglu Hu*

Control systems using neural networks have been used recently in many fields, but some problems remain to be solved. One of the problems which should be overcome is to enhance the robustness of the neural networks control systems. In this paper, a new robust control method is proposed, which is based on the second order derivatives of Universal Learning Network and fuzzy criterion function.

Key Words: neural networks, fuzzy criterion, second-order derivative, sensitivity minimization, robust control

1. ま え が き

近年、ニューラルネットワーク (Neural Network: NN) を代表とする学習ネットワークによる制御方式の研究が盛んに行われている。学習により得られた制御系にて制御を行なう場合、学習時利用したシステム環境変数 (システムパラメータ、状態初期値、参照入力、外乱等) の値が制御時に変化することを考慮する必要がある。これらの変化が小さい場合はニューラルネットワークがもつ汎下能力にて十分対処できる。すなわち、制御性能の劣化が少なく本来の制御目的を達成することができる。しかしながら、この変化が大きくなると汎下能力では対処できなくなり、制御性能の劣化やシステムの不安定性の原因となる。このような場合の対処法として、設計時に予め変化を予想し、それに対処できるように設計するロバスト制御方式と制御時にオンラインでその変化を学習しながら制御を行なう適応制御方式の二通りがある。これまで一般的に行われているのが後者の適応制御であり、その代表として川人等のフィードバック誤差学習による学習制御⁴⁾がある。

一方、前者のロバスト制御に関する論文はほとんど見受けられない。わずかに一般化学習ネットワークの2次微分を利用したロバスト制御系設計法が、システムの初期値変動⁵⁾、システムパラメータ変動⁶⁾、外部入力変動⁷⁾に対して提案されその有効性が示されている。しかしながら、これらの論文におけるロバスト性は、システム環境変数の変動に対する感度を小さくするようにコントローラを学習するが、基本的にはその感度の最小化はシステム環境変数が、ある基準点を中心に微小変動することを前提としている。従って、ロバスト性は限られた範囲で有効といえる。

本論文も前者の立場からの制御方式の提案であり、今回新たに提案する方式は、前述のシステム環境変数の変動がある値を基準とした微小変動ではなくある有限な範囲で生ずるとし、その変動範囲で制御性能を保証する制御系設計法に関するものである。

具体的には、制御の目的及び仕様を定式化した評価指標を局所最小化すると同時にその評価指標に対するシステム環境変動変数の感度を小さくするようなコントローラを学習により構成する。評価指標に対するシステム環境変数感度を評価項目として設定する場合、システム環境変数の変動が生ずる範囲において、有限な複数の点を基準点として選択し、それぞれの点での感度を評価する。また、各点での感度評価の割合、すなわち、感度評価の重みは均一でなく、システムの要求に応じて容易に設定できるようにメンバーシップ関数を利用している。以下では、システム環境変数のうち、システムパラメータが変動する場合を定式化するが、他のシステム

† 第24回知能システムシンポジウムで発表(1997.3)

* 九州大学大学院システム情報科学研究科 福岡市東区箱崎 6-10-1

* Graduate School of Information Science and Electrical Engineering, Kyushu University, Higashi-ku, Fukuoka
(Received August 21, 1997)
(Revised April 1, 1998)

環境変数の変動の場合も同様に定式化できる。環境変数の関数である評価指標とその感度をメンバーシップ関数で重み付けしているの、以降、変動するシステムパラメータをファジ変数と呼び、変動する範囲における複数点全体での評価をファジ評価と呼ぶが、これはファジ推論をベースとした一般のファジ評価とはその使用法、意味は異なる。

提案方式の有効性を検証するために以下のシミュレーションを行なった。すなわち、非線形クレーンシステムを対象とした制御において、システムパラメータ（荷の質量）が変動する場合を取り扱い、i) システムパラメータを1点に固定した通常の評価指標最小化方式、ii) システムパラメータを多点で評価する最小化方式、iii) システムパラメータを1点に固定した通常の評価指標とシステムパラメータが微小変動する場合の感度を同時に最小化する方式（従来のロバスト制御方式）^{5), 6), 7)}, iv) システムパラメータを多点で評価する指標とシステムパラメータ感度を多点で評価する指標を同時に最小化する方式（提案方式）、の四つの方式を比較検討した。

ちなみに、評価指標のシステム環境変数感度は1次微分となり、勾配法で学習する場合これをさらにコントローラのパラメータで微分するので上記 5), 6), 7) および本論文においては2次微分計算が必要になる。

2. 一般化学習ネットワークの基本構成

一般化学習ネットワークは、非線形システムをモデル化・制御することを目的とし、ニューラルネットワークにおける構成・機能・学習方式等を一般化したネットワークである^{1) 2)}。

一般化学習ネットワークの基本構成を Fig.1 に示す。

Fig. 1 Basic structure of Universal Learning Network

基本方程式を以下の式とする。

$$h_j(t) = f_j(\{h_i(t - D_{ij}(p)) | i \in JF(j), p \in B(i, j)\}, \{r_n(t) | n \in N(j)\}, \{\lambda_m(t) | m \in M(j)\}, \{a_q | q \in Q\}) \quad j \in J, t \in T \quad (1)$$

$h_j(t)$: j ノードの t 時刻の出力値

$r_n(t)$: n 外部入力変数の t 時刻の値

$\lambda_m(t)$: m パラメータの t 時刻の値

f_j : j ノードの非線形関数

$D_{ij}(p)$: i ノードから j ノードへの p 番目のブランチの遅れ時間

J : ノード番号の集合

$JF(j)$: j ノードへ接続するノード番号の集合

N : 外部入力変数番号の集合

$N(j)$: j ノードへ接続する外部入力変数番号の集合

M : パラメータ番号の集合

$M(j)$: j ノードへ接続するパラメータ番号の集合

$B(i, j)$: i ノードから j ノードへ接続するブランチ番号の集合

T : 時刻の集合

a_q : q 番目のファジ変数の値

Q : ファジ変数の番号の集合

一般化学習ネットワークは、任意の非線形処理ノードを任意の遅れ時間を介して任意の接続を行うことにより構成される。

評価指標を以下のように設定する。

$$E_R = \sum_{q \in Q} \sum_{l \in L(q)} [\mu_E(a_q(l)) E(a_q(l)) + k_1 \mu_S(a_q(l)) \left(\frac{\partial^\dagger E(a_q(l))}{\partial a_q(l)} \right)^2] \quad (2)$$

E : 通常の評価指標, k_1 : 正の定数

$a_q(l)$: q 番目のファジ変数の l 番目の離散値

$L(q)$: q 番目のファジ変数の離散化番号の集合

$\mu_E(a_q(l))$: E に関するメンバーシップ関数

$\mu_S(a_q(l))$: 感度に関するメンバーシップ関数

この評価指標の意味するところを説明する。上式において、右辺第2項の $\frac{\partial^\dagger E(a_q(l))}{\partial a_q(l)}$ は、 E を $a_q = a_q(l)$ でテイラー展開した時の一次近似に関する項であり、 a_q が微小変動した時の評価指標 E の変動量、すなわち、感度である。したがって、この値が小さければ a_q の近傍においてシステムは安定となる。従来のロバスト制御方式では、システムパラメータのある一点のみの感度を考慮した最適化を行っている。したがって、最適化を行った点の近傍ではシステムは安定となるがそれ以外の点においてシステムが安定となる保証はない。最悪の場合、過学習がおこると、システムは不安定になることさえある。提案手法では、(2) 式から分かるように感度を含めてシステムパラメータを多点で評価し最適化を行うことにより、より安定なシステムを構築することを目的としている。また、メンバーシップ関数を用いて多点評価の重み付けをすることにより、各点で均一に最適化を行うだけではなく、目的に応じて多点に重み付けをした最適化を行うことが可能となる。 $\dagger$ は Werbos¹⁰⁾ の提案した ordered 微分であり、他の変数を固定し、 $a_q(l)$ のみを微小変動させた場合の E の変動分を表している。

3. 学習アルゴリズム

パラメータ変数の学習は、勾配法によりおこなう。

$$\lambda_m \leftarrow \lambda_m - \gamma \frac{\partial^\dagger E_R}{\partial \lambda_m} \quad (3)$$

$$\begin{aligned} \frac{\partial^\dagger E_R}{\partial \lambda_m} = & \sum_{q \in Q} \sum_{l \in L(q)} \left[\mu_E(a_q(l)) \frac{\partial^\dagger E(a_q(l))}{\partial \lambda_m} \right. \\ & \left. + 2 k_1 \mu_S(a_q(l)) \left(\frac{\partial^\dagger E(a_q(l))}{\partial a_q(l)} \right) \frac{\partial^{\dagger 2} E(a_q(l))}{\partial a_q(l) \partial \lambda_m} \right] \end{aligned} \quad (4)$$

(4) 式を見てもわかるように、学習を行うためには2次微分の計算が必要となる。計算量を軽減するために、通常のバックワードプロパゲーションを使用せず、フォワードプロパゲーション一般化学習ネットワーク理論²⁾により、上式の計算を行う。

評価指標 E_R の局所最小化はコントローラのパラメータに関する勾配に基づいて行われるが、 E_R が評価指標 E 及び評価指標 E のファジィ変数に対する微分の和により構成されていることから、それぞれが、コントローラのパラメータにより微分可能でなければ、 E_R を局所最小とする制御系は構成できない。従って、本論文では、コントローラは連続微分可能な関数で構成し、また制御対象のノード出力がやはり連続微分可能であるような場合を取り扱うものとする。このとき E_R の局所最小化による学習は次式の如く計算できる。以下、結果のみを示す。

$\frac{\partial^\dagger E}{\partial a_q(l)}$ の計算

$$\frac{\partial^\dagger E}{\partial a_q(l)} = \sum_{r \in R_o} \sum_{s \in S_o} \left[\frac{\partial E}{\partial h_r(s)} \frac{\partial^\dagger h_r(s)}{\partial a_q(l)} \right] + \frac{\partial E}{\partial a_q(l)} \quad (5)$$

$$\frac{\partial^\dagger h_k(t)}{\partial a_q(l)} = P_1(k, t, a_q(l)) \quad (6)$$

$$\begin{aligned} P_1(k, t, a_q(l)) = & \sum_{j \in JF(k)} \sum_{p \in B(j, k)} \left[\frac{\partial h_k(t)}{\partial h_j(t - D_{jk}(p))} \right. \\ & \times P_1(j, t - D_{jk}(p), a_q(l)) \Big] \\ & + \frac{\partial h_k(t)}{\partial a_q(l)} \end{aligned} \quad (7)$$

$\frac{\partial^{\dagger 2} E}{\partial a_q(l) \partial \lambda_m}$ の計算

$$\begin{aligned} \frac{\partial^{\dagger 2} E}{\partial a_q(l) \partial \lambda_m} = & \sum_{r \in R_o} \sum_{s \in S_o} \left[\frac{\partial^\dagger \left(\frac{\partial E}{\partial h_r(s)} \right)}{\partial \lambda_m} \frac{\partial^\dagger h_r(s)}{\partial a_q(l)} \right] \\ & + \sum_{r \in R_o} \sum_{s \in S_o} \left[\frac{\partial E}{\partial h_r(s)} \frac{\partial^{\dagger 2} h_r(s)}{\partial a_q(l) \partial \lambda_m} \right] \\ & + \frac{\partial^\dagger \left(\frac{\partial E}{\partial a_q(l)} \right)}{\partial \lambda_m} \end{aligned} \quad (8)$$

$$\frac{\partial^{\dagger 2} h_k(t)}{\partial a_q(l) \partial \lambda_m} = P_2(k, t, a_q(l), \lambda_m) \quad (9)$$

$$P_2(k, t, a_q(l), \lambda_m)$$

$$\begin{aligned} = & \sum_{j \in JF(k)} \sum_{p \in B(j, k)} \left[\frac{\partial^\dagger \left(\frac{\partial h_k(t)}{\partial h_j(t - D_{jk}(p))} \right)}{\partial \lambda_m} \right. \\ & \times P_1(j, t - D_{jk}(p), a_q(l)) \Big] \\ & + \sum_{j \in JF(k)} \sum_{p \in B(j, k)} \left[\frac{\partial h_k(t)}{\partial h_j(t - D_{jk}(p))} \right. \\ & \times P_2(j, t - D_{jk}(p), a_q(l), \lambda_m) \Big] \\ & + \frac{\partial^\dagger \left(\frac{\partial h_k(t)}{\partial a_q(l)} \right)}{\partial \lambda_m} \end{aligned} \quad (10)$$

但し、 R_o 評価に関するノード番号の集合
 S_o 評価に関する時刻の集合

4. シミュレーション

Fig.2 の非線形クレーンシステムを対象として、提案手法の有効性を検証する。台車の位置、荷の振り角、荷の巻き上げ位置を、 x, θ, l とすると非線形クレーンシステムは、次式で近似できる。

$$\frac{d^2 x}{dt^2} = -\frac{mg}{M} \theta - \frac{D+G}{M} \frac{dx}{dt} + \frac{G}{M} u_1 \quad (11)$$

$$\frac{d^2 \theta}{dt^2} = -\frac{M+m}{lM} g \theta - \frac{D+G}{lM} \frac{dx}{dt} + \frac{G}{lM} u_1 \quad (12)$$

$$\frac{d^2 l}{dt^2} = -\frac{C+G_m}{m} \frac{dl}{dt} + \frac{G_m}{m} u_2 \quad (13)$$

但し、

- u_1 : 横走行モータ入力電圧 [V]
- u_2 : 巻き上げモータ入力電圧 [V]
- C : 巻き上げ摩擦係数 [kg/sec]
- M : 台車の質量 [kg]
- G : 電圧・トルク係数 [N/V]
- m : 荷の質量 [kg]
- D : 横走行摩擦係数 [kg/sec]
- g : 重力加速度 [m/sec²]

である。

ここで、上式を一般化学習ネットワークで表現するために、離散化をおこなう。

$$\begin{aligned} h_1(t) &= x(t) \quad , \quad h_2(t) = \dot{x}(t) \quad , \quad h_3(t) = \theta(t) \\ h_4(t) &= \dot{\theta}(t) \quad , \quad h_5(t) = l(t) \quad , \quad h_6(t) = \dot{l}(t) \end{aligned}$$

とすると、(11)~(13) 式は、

$$h_1(t) = h_1(t-1) + \Delta t \cdot h_2(t-1) \quad (14)$$

$$h_2(t) = \left(1 - \Delta t \frac{D+G}{M} \right) h_2(t-1)$$

Fig. 2 Nonlinear crane system

$$-\frac{mg}{M}\Delta t \cdot h_3(t-1) + \frac{G}{M}\Delta t \cdot u_1(t-1) \quad (15)$$

$$h_3(t) = h_3(t-1) + \Delta t \cdot h_4(t-1) \quad (16)$$

$$h_4(t) = h_4(t-1) - \frac{D+G}{M}\Delta t \frac{h_2(t-1)}{h_5(t-1)} - \frac{M+m}{M}g\Delta t \frac{h_3(t-1)}{h_5(t-1)} + \frac{G}{M}\Delta t \frac{u_1(t-1)}{h_5(t-1)} \quad (17)$$

$$h_5(t) = h_5(t-1) + \Delta t \cdot h_6(t-1) \quad (18)$$

$$h_6(t) = \left(1 - \frac{C+G_m}{m}\Delta t\right) h_6(t-1) + \frac{G_m}{m}\Delta t \cdot u_2(t-1) \quad (19)$$

となる。

これら6つの式が、一般化学習ネットワーク表現における制御対象のノード内処理関数を表す。Fig. 3に、非線形クレーンシステム及びコントローラを一般化学習ネットワーク表現した場合のフィードバック制御系を示す。コントローラは、 u_1, u_2 を各々2個のコントローラノード(線形処理ノード1個、内部に $\tanh$ 関数を持つ非線形処理ノード1個)で構成している。但し、遅れ時間はすべて1サンプル遅れとした。Fig. 3において、上の6個のノードが制御対象システムノード($N_1, \dots, N_6$)を表し、下の4個のノード($N_7, \dots, N_{10}$)がコントローラノードを示している。信号の流れは、コントローラノードの出力 u_1, u_2 が、システムノードへ入力され、(14)~(19)式のダイナミクスの1サンプリング動作後、システムノード出力がコントローラにフィードバックされる。この時、参照入力 x_{ref}, l_{ref} とシステムノード出力 x, l との偏差がコントローラノードへの入力となる。また、本シミュレーションでは、全状態が観測可能なものとしてシステムを構成した。以下、

$$C = 0.42[\text{kg/sec}], G = 700[\text{N/V}], D = 300[\text{kg/sec}] \\ M = 40[\text{kg}], g = 9.8[\text{m/sec}^2]$$

$$\begin{aligned} \text{台車位置} &: \text{初期値 } x_0 = x(0) = 0[\text{m}] \\ &\quad \text{目標値 } x_{ref} = 1[\text{m}] \\ \text{巻き上げ位置} &: \text{初期値 } l_0 = l(0) = 1[\text{m}] \\ &\quad \text{目標値 } l_{ref} = 0.5[\text{m}] \end{aligned}$$

という条件の下で、シミュレーションを行なった。

また、システムダイナミクスの評価指標を以下のように設定した。

$$E = \frac{1}{2} \left[\sum_{s \in T_0} \{Q_1(x_{ref} - x(s))^2\} + Q_2 \dot{x}(t_f)^2 + \sum_{s \in T_0} \{Q_3 \theta(s)^2 + Q_4 \dot{\theta}(s)^2\} + \sum_{s \in T_0} \{Q_5(l_{ref} - l(s))^2\} + Q_6 \dot{l}(t_f)^2 + \sum_{s \in T_0} \{R_1 u_1(s)^2 + R_2 u_2(s)^2\} \right] \quad (20)$$

$$Q_1 = Q_2 = Q_3 = Q_4 = Q_5 = Q_6 = 1.0$$

$$R_1 = R_2 = 0.001$$

t_f : 制御最終時刻 (= 7.5[sec])

T_0 : サンプリング時刻の集合 (= 2500)

この評価指標は、最小のエネルギーで台車と荷を目標位置に移動させ、停止させるためのものである。

本シミュレーションでは、ファジィ変数 $a_q(l)$ として荷の質量 m を考える。制御系設計の目的は、システムパラメータである荷の質量 m が変動した場合においてもシステムが安定で、かつ、(20)式の評価指標最小化を達成するコントローラの設計をおこなうことである。

Fig. 3 Expression of a recurrent type feedback control system of a nonlinear crane system using ULN

シミュレーションは、以下の4方式についてそれぞれ Fig. 3の学習制御系を構成し、荷の質量 m を変化させて制御性能についての比較検討を行なった。

- i) 通常評価方式 (1点評価): システムパラメータを1点に固定した通常評価指標最小化方式
- ii) 通常評価方式 (多点評価): システムパラメータを多点で評価する最小化方式
- iii) ロバスト制御方式 (従来方式): システムパラメータを1点に固定した通常の評価指標とシステムパラメータが微小変動する場合の感度を同時に最小化する方式
- iv) ロバスト制御方式 (提案方式): システムパラメータを多点で評価する指標とシステムパラメータ感度を多点で評価する指標を同時に最小化する方式。

[i] 通常評価方式（1点評価）を用いたシミュレーション

評価指標 E のみを用いて、通常の学習を行った。荷の質量は $m = 2$ と固定し、学習回数は 5000 回とした。学習後、得られたコントローラを用いて、荷の質量を 6, 10[kg] と変更し、それぞれ制御を行なった。

荷の質量を変えることにより、 x, θ に大きな変動は生じなかったが (Fig.4, Fig.5), 特に l の変動は大きくなり、システムに不安定性が増した (Fig.6)。この要因は $m = 2$ のときの評価指標 E を最小にしようと最適化を行っている点にある。学習ネットワークには汎化能力があり、異なる入力に対してもある程度の性能は確保できる。しかし、通常の学習ではどの程度汎化能力が得られるかは、未知である。また、評価指標の値を極端に減少させようすると過学習が起きる可能性もあり、ロバストなコントローラの設計は非常に困難である。

Fig. 4 Results of usual criterion method x

Fig. 5 Results of usual criterion method θ

[ii] 通常評価方式（多点評価）を用いたシミュレーション

Fig. 6 Results of usual criterion method l

評価指標を以下のように設定した。

$$E_R = \sum_{m \in L} \mu_E(m) E(m) \quad (21)$$

$$L = \{2, 6, 10\}$$

これは、(2) 式において、 $k_1 = 0$ とした場合である

また、メンバシップ関数は次の 2 種類を用いた。

[case1]

$$\mu_E(m) = 1$$

[case2]

$$\mu_E(m) = \exp\left(-\frac{(m-2)^2}{40}\right)$$

意味的には、[case1] は各点で均一の重み付けをして最適化を行う場合であり、クレーンシステムで使用される荷の質量の使用頻度が等しい場合を想定している。また、[case2] では、質量 2kg の荷の使用頻度が最も多く、質量が大きくなるにつれその頻度が小さくなる場合を想定している。

Fig.7, Fig. 8 に学習後、 $m = 6, 10$ と変化させたときのダイナミクスの計算結果を示す。

通常評価方式（多点評価）を用いた場合の学習は、1点評価の学習より安定性が増していることがわかる。

[iii] ロバスト制御方式（従来方式）によるシミュレーション

次に、1点評価の感度を考慮したロバスト制御方式により学習を行う。但し、文献5) では評価指標をあらかじめ変動幅が大きい $l, \dot{l}$ の変動量を減少させるべく、 $l, \dot{l}$ のノード出力に対するパラメータ感度を評価に設定している。本論文では、評価指標を以下のように設定した。また、荷の質量 m は 2 に固定し、学習回数は 5000 回とした。

$$E_R = E(m) + k_1 \left(\frac{\partial^\dagger E}{\partial m} \right)^2, \quad k_1 = 1 \quad (22)$$

学習により得られた制御系を用いて m を変化させて制御を行った。その結果を Fig.9 に示す。 m を大きくするにつれて通常評価方式（1点評価、多点評価）における結果 Fig.6,

Fig. 7 Results of plural point criterion method (case1)

Fig. 8 Results of plural point criterion method (case2)

Fig. 9 Results of old robust control method

Fig.7,8 と比較し、速応性が若干悪くなっているが、行き過ぎ量が少なく、安定性は格段に良くなっているのが分かる。

[iv] ロバスト制御方式（提案方式）を用いたシミュレーション]

評価指標を以下のように設定した。

$$E_R = \sum_{m \in L} \left[\mu_E(m) E(m) + k_1 \mu_S(\bar{m}) \left(\frac{\partial^\dagger E}{\partial m} \right)^2 \right] \quad (23)$$

$$L = \{2, 6, 10\}$$

学習は、計算効率の向上という点から、対象クレーンシステムの特徴を利用した。(11)~(13)式で表されるクレーンシステムは、Fig.3を見てもわかるように、巻き上げ系は独立した線形システムとみなすことができる。したがって、コントローラの初期値を乱数で与えるのではなく、まず、巻き上げ系のシステムのみで、ある程度学習を行い、得られたコントローラのパラメータを巻き上げ用コントローラパラメータの初期値とした。また、台車用コントローラパラメータの初期値は、通常評価方式（1点評価）の学習で得られたコントローラの値を用いた。

以上の方法を用いて、2000回の学習を行なった。

また、メンバシップ関数は前節と同じく次の2種類を用いた。

[case1]

$$\mu_E(m) = \mu_S(m) = 1$$

[case2]

$$\mu_E(m) = \mu_S(m) = \exp \left(-\frac{(m-2)^2}{40} \right)$$

Fig.10 および Fig.11 に学習後のダイナミクス計算結果を示す。通常評価方式及び従来方式の Fig.6,7,8,9 と Fig.10, Fig.11 を比較すると、安定性は、Fig.10 が優れ、Fig.11, 9, 7, 8, 6 の順となっている。

Fig.12に学習後、質量 m を [2, 10] の範囲で変化させた時の評価指標 E のグラフを示す。

[case 1] と [case 2] を比較すると、 $m = 2$ では E の値は [case 2] の方が小さいが、 $m = 10$ では [case 1] の方が小さくなっている。これにより、メンバシップ関数による重みづけの目標を達成していることがわかる。

5. 考 察

Fig.13 に前節までに行ったシミュレーションにおいて、学習後、 m を [2, 10] の範囲で変化させた時の評価指標 E の計算結果を示す。ただし、ロバスト制御（提案方式）と通常評価方式（多点評価）については [case 1] のみとする。

Fig.13において、ロバスト制御方式（従来方式）は、 $m = 2$ で最適化をおこなっているにもかかわらず、 E の値が大きい。これはこれ以上学習すると後述するように過学習になるためである。従って、ロバスト制御方式（従来方式）は、以下の比較の対象としなかった。

Fig. 10 Results of proposed robust control method (case1)

Fig. 11 Results of proposed robust control method (case2)

Fig. 12 Comparison between [case 1] and [case 2]

Fig.13より $m = 2$ の近傍では,

通常評価方式 (1点評価) < 通常評価方式 (多点評価)
< ロバスト制御方式 (提案方式)

の順に E の値が小さくなっているのに対し, $m = 10$ の近傍では,

ロバスト制御方式 (提案方式) < 通常評価方式 (多点評価)
< 通常評価方式 (1点評価)

の順に E の値が小さくなっている. また, このグラフでは傾きが E に対する m の感度となっているが, 評価指標を感度を減少させるよう設定したものの方が傾きは小さくなっていることがわかる.

以上より, 評価指標設定の際の目的が達成できていることがわかる.

Fig. 13 Values of criterion E when m changes (1)

(a): 通常評価方式 (1点評価)
(b): 多点評価方式 (多点評価)
(c): ロバスト制御方式 (従来方式)
(d): ロバスト制御方式 (提案方式)

● ロバスト制御方式 (従来方式) について

ロバスト制御方式 (従来方式) は学習が十分でないことより, ロバスト制御方式 (従来方式) のみさらに 2000 回の学習を行った. 学習後, m を [2,10] の範囲で変化させた時の評価指標 E の計算結果をあらためて Fig.14 に示す.

ロバスト制御方式 (従来方式) について, Fig.13 と Fig.14 を比較してみると, Fig.14 では, Fig.13 より $m = 2$ の近傍で E の値, 及び感度は減少しているが, m が 2 より少し大きくなると, E の値が急激に増加している. これは, $m = 2$ の 1 点で評価指標を減少させようとしているために起る, いわゆる過学習現象である. この例からもわかるように, 1 点で最適化を行う場合は適切な学習回数で学習を終了させる必要がある. また, 本手法のように多点で最適化を行えば, 過学習が起る可能性はかなり低くなる.

● 速応性と行き過ぎ量 (オーバーシュート) について

Fig. 14 Values of criterion E when m changes (2)

ロバスト制御方式（提案方式）と通常評価方式（多点評価）による学習を比較した場合の結果を1についてのみ Fig.15 に示す。Fig.15 を見てもわかるように、ロバスト制御方式（提案方式）の方が速応性は悪化したが、行き過ぎ量は減少している。

以上より、評価指標の違い、即ち評価指標 (2) 式の第2項の有無が Fig.15 の多点評価方式 (b) と提案手法 (d) の結果の違いとなっていることがわかる。

6. おわりに

学習ネットワークのシステム環境変数が、ある値を基準とした微小変動ではなく有限な範囲で変動しても制御性能を保証するロバスト制御の一手法を提案した。具体的には有限範囲の複数点で評価指標のシステム環境に対する感度を計算し、これにメンバーシップ関数で与えられた重み付けを行なった評価指標を新たに付加する事によりロバスト性を実現している。

また、提案法の有効性をダイナミクスが既知である非線形クレーンシステムを例題として示したが、定式化の過程からわかるように、制御対象のダイナミクスが既知で微分可能な任意のシステムに対して本手法は適用可能である。しかしながら、ダイナミクスが未知である場合はまず対象システムをニューラルネットワーク等を用いて同定することになる。その場合、同定システムにおいて、参照入力、外乱等の物理的意味を保存する変数の変動に対してはファジィ変数としてその変動を考慮でき、本提案法が適用可能であるが、同定システム内部のパラメータは物理的意味を持たないため、上記のような個別の意味付けができない。このような場合、システム内部パラメータ全部の変動に対する感度を最小化するというように内部パラメータ全てを同時に扱う方式が考えられる。

最後に、1. はじめにでも述べたように、本論文では、システム環境変数のうちシステムパラメータをファジィ変数とし

Fig. 15 Comparison between results of plural criterion method (b) and results of proposed method (d) [case 1]

て取り扱い上記定式化を行なったが、外乱等についてもほぼ同様の枠組で定式化が可能である。すなわち、本論文におけるファジィ変数として外乱を考慮すれば外乱に対してロバストな制御系が設計できる。

参 考 文 献

- 1) 平澤, 大林, 藤田, 古賀: 一般化学習ネットワーク理論, 電気学会論文誌 C 分冊, 116 巻, 7 号, 1996.
- 2) 平澤, 大林, 古賀: フォワードプロパゲーション一般化学習ネットワーク理論, 電気学会論文誌 C 分冊, 116 巻, 6 号, 1996.
- 3) 坂和, 石井, 西崎: ソフト最適化, 朝倉書店, 1995.
- 4) 五味裕章, 川人光男: 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, システム制御情報学会誌, Vol.4, No.1, 37-47, 1991
- 5) 大林, 平澤: 一般化学習ネットワークの 2 次微分を用いた非線形ダイナミカルシステムの初期値変動に対するロバスト制御方式, 電気学会論文誌 D 分冊, 117 巻, 3 号, pp.289-297, 1997.
- 6) M.Ohbayashi, K.Hirasawa, M.Hashimoto, J.Murata: Robust Control for System Parameter Perturbation Using Second Order Derivatives of Universal Learning Network, Transaction of the Society of Instrument and Control Engineers (SICE), Vol.33, No.4, pp.289-295, 1997.
- 7) 大林, 平澤: 一般化学習ネットワークの 2 次微分を用いた非線形ダイナミカルシステムの外部入力変動に対するロバスト制御方式, 電気学会論文誌 D 分冊, 第 118 巻, 3 号, pp.300-307, 1998
- 8) 平澤, 大林, 古賀: 一般化学習ネットワークの安定性理論, 電気学会論文誌 C 分冊, 第 116 巻, 8 号, pp.973-982, 1996.
- 9) 于, 大林, 平澤: 一般化学習ネットワークの安定性の解析手法について, 第 15 回計測自動制御学会九州支部学術講演会予稿集, pp.325-327, 1996.
- 10) P.Werbos: Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences, Ph.D. dissertation, Harvard University, 1974.

[著 者 紹 介]

大 林 正 直 (正会員)

1975 年九州工業大学工学部電気工学科卒業。77 年九州大学大学院工学研究科修士課程電気工学専攻修了。同年 (株) 日立製作所入社大みか工場勤務。89 年九州大学工学部助手。97 年同助教授。98 年山口大学助教授。現在に至る。電気学会, システム制御情報学会, IEEE, INNS の各会員。博士 (工学)。

平 澤 宏 太 郎 (正会員)

1966 年九州大学大学院工学研究科修士課程電気工学専攻修了。同年 (株) 日立製作所入社日立研究所勤務。89 年同研究所副所長。91 年同大みか工場主管技師長。92 年九州大学工学部教授。96 年同大学院システム情報科学研究科教授。現在に至る。電気学会, 情報処理学会, IEEE の各会員 (工学博士)。

利 光 克 之 (正会員)

1995 年九州大学工学部電気工学科卒業。97 年九州大学大学院総合理工学研究科エネルギー変換工学専攻修了。同年松下電器産業株式会社入社。現在に至る。

村 田 純 一 (正会員)

1986 年 3 月九州大学大学院工学研究科博士後期課程電気工学専攻修了。同年 4 月九州大学工学部助手。88 年 4 月同助教授。96 年 4 月同大学院システム情報科学研究科助教授。現在に至る。電気学会, システム制御情報学会の会員。システムのモデル化, 学習, 自己組織化システムに関する研究に従事 (工学博士)。

胡 敬 炉 (正会員)

1986 年中国中山大学大学院修士修了。同年 7 月同大学電子工学科助手。88 年 11 月同講師。93 年 10 月渡日。97 年九州工業大学情報工学研究科博士後期課程修了。同年 4 月九州大学ベンチャービジネスラボラトリ非常勤研究員を経て、同年 8 月同大学システム情報科学研究科助手。現在に至る。学習ネットワーク理論、システム同定とその応用に関する研究に従事。電気学会の会員 (情報工学博士)。