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

正 員 大 林 正 直 (九 州 大)
正 員 平 澤 宏 太 郎 (九 州 大)

**Robust Control of a Nonlinear Dynamical System
for Changes of External Inputs Using Second Order Derivative of Universal Learning Network**
Masanao Ohbayashi, Member (Kyushu University), Kotaro Hirasawa, Member (Kyushu University)

Abstract: As the nonlinearity and complexity of a nonlinear system increase, it may be more difficult to construct a controller by the mathematical control theory. In such cases, it is very effective to construct the controller by using Neural Network(NN), because NNs have capabilities of coping with the nonlinearity and complexity of the nonlinear systems. NN controllers are constructed through learning to minimize a criterion function under certain environments of the system. But NN controllers may not work well under a very different environment from the environment at learning stage. In other words, for example, NN controllers are usually made without considering the changes of the environment because NN controllers do not have a means to suppress their influences. So, in case that the environment changes, NN controllers do not work well. In this paper a robust control system design method for the changes of the external inputs to the system is discussed using second order derivatives of Universal Learning Network.

キーワード: ニューラルネットワーク, 学習, 最適化, 外部入力変動, 2次微分, ロバスト制御

1 はじめに

本論文は一般化学習ネットワーク^[6]を活用して, 環境変動に対してロバストな制御系を設計する手法の提案に関する。

すでに筆者等は環境変動にロバストなコントローラを構成する手法とそのシミュレーション結果を, システムの初期状態が学習時より大きく変動する場合は文献[11][12]に, また, システムパラメータが大幅変動する場合は文献[13]に報告している。

上記報告の内, 初期状態の変動に強いシステムはリアブノフの意味での安定領域を広めることを目指したものであり, また, システムパラメータ変動にロバストなシステムはシステムの構造が変動しても変動以前の性能を維持する事を目的としている。これ等はいずれもシステム内部の変動に強いシステムを構築する事を目指している。一方, 本論文で提案する手法は, 参照入力のようなシステムへの外部入力が増加した場合, 従って, 必然的にシステムの内部状態が増加する場合に, 不要な擾乱を与えないロバストなシステムを実現する事をそのねらいとしている。換言すると, 学習ネットワーク内において, 外部入力変動に対して強く応答するノードと応答を抑えるノードを区分してロバスト評価を行い, 総合的に環境変動に強いシステムを構築

している。

ロバストなコントローラを実現するための本論文の基本的なアイデアは, 以下のとおりである。即ち, 外部入力が増加時設定された値から制御時に増加した場合, その増加に対し, 応答を抑えたいノードに及ぼす影響を抑えるための評価項目を通常の評価指標に付加する。この新たな評価項目(以下動揺抑制指標)を加味した全体的評価指標を局所最小化するようにコントローラのパラメータの学習を行なう。このことにより学習時と制御時の条件の違いによるシステムの動揺を抑制する。これは, 学習と異なる状態でのシステムの性能を考慮するという意味で, NNが本来備えている汎化能力(以後:ロバスト性)を強化したものといえる。従って, ポイントは, この新たに評価項目を付加したことで, これを付加しない場合に比較し, ロバスト性が強化されるか否かにある。非線形クレーンシステムを対象とした数値例において, 外部入力として参照入力を考え, 制御時にこれが変化した場合について, 新たな評価項目を付加しない通常のNNコントローラの場合の制御と比較し, 提案法による制御が高いロバスト性を持ち, 大幅な外部入力の増加下でも良好な制御性能が維持できる有効な方法であることを示した。

なお, 一般化学習ネットワークを利用して制御系設計を

行なう場合、制御対象システムとコントローラを同一のネットワークとみなすことが特徴である。即ち、制御対象もコントローラと同様にネットワーク表現する。もし、制御対象が既知であるなら、ネットワーク表現することでそのシステムのダイナミクスを既知情報として容易にネットワーク内に取り込むことができる。未知の場合は、通常のニューラルネットワーク (NN) 同様、対象システムを同定後コントローラ的设计を行なうことになる。

また、ロバスト制御を実現するための基本技術である高次微分に関しては、リカレントニューラルネットワーク (RNN) では評価指標のパラメータに関する微分計算は1次微分 (勾配) までしか行われていない。[Le Cun,etal]^[2], [Buntine]^[5] が2次微分, [Xia-Hu,etal]^[3] が4次微分まで検討しているが、これ等は階層型での非ダイナミクスネットワークシステムについてであり、リカレントシステムについての検討はなされていない。著者等は、リカレント構成の一般化学習ネットワーク (ULN) 上で、高次微分の体系的な計算手法を提案している。ULN のこれらの詳細は、参考文献 [6], [7], [8], [9], [10] を参照されたい。

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、非線形処理を行う処理ノードと、処理ノード間を接続する任意の遅れ要素により構成されている。Fig.1 にノード間が単一ブランチの基本的な一般化学習ネットワークの構成を示す。

一般化学習ネットワークの基本方程式は次式で表現される。

$$h_j(t) = O_j(\{h_i(t - D_{ij}) | i \in I\}, \{\lambda_m(t)\}, \{r_n(t)\}) \\ (j \in R)(t \in T)$$

とする。ここで、

- $h_j(t)$: j ノードの t 時刻の出力値 ($j \in R$)
- $\lambda_m(t)$: m パラメータの t 時刻の値 ($m \in M$)
- $r_n(t)$: n 外部入力変数 (参照入力, 外乱等) の t 時刻の値 ($n \in N$)
- O_j : j ノードの非線形関数
- I : j ノードの入力側に接続されるノードの添字の集合
- D_{ij} : i ノードから j ノードへの遅れ時間

Fig.1 Structure of ULN

- R : ノードの添字の集合
- M : パラメータの添字の集合
- N : 外部入力変数の添字の集合
- T : サンプル時刻の集合

ネットワークの評価指標 E を、

$$E = E(\{h_r(s)\}, \{\lambda_m(s)\}, \{r_n(s)\}) \quad (2)$$

とする。

ここで、

- $r \in R_o$ R_o : 評価に関するノードの添字の集合
- $m \in M_o$ M_o : 評価に関するパラメータの添字の集合
- $n \in N_o$ N_o : 評価に関する外部入力変数 (参照入力) の添字の集合
- $s \in S_o$ S_o : 評価サンプル時刻の集合

以下、一般化学習ネットワークによる制御の基本となる、フォワードプロパゲーションを利用した評価指標 E のパラメータに対する1次,2次微分の計算方式を与える [8],[10]。

3 高次微分の計算

3.1 1次微分の計算

t_0 を指定したサンプル時刻とすると評価指標 E の1次微分 $\frac{\partial^\dagger E}{\partial \lambda_1(t_0)}$ は次のように計算できる。

E が $h_r(s)$ と $\lambda_1(t_0)$ の関数とすると、(2) 式より

$$\frac{\partial^\dagger E}{\partial \lambda_1(t_0)} = \sum_{r \in R_o} \sum_{s \in S_o} \left(\frac{\partial E}{\partial h_r(s)} \frac{\partial^\dagger h_r(s)}{\partial \lambda_1(t_0)} \right) + \frac{\partial E}{\partial \lambda_1(t_0)} \quad (1)$$

となる。

(3) 式の $\frac{\partial^\dagger E}{\partial \lambda_1(t_0)}$, $\frac{\partial^\dagger h_r(s)}{\partial \lambda_1(t_0)}$ は Werbos の提案したオーダード微分 [1] であり、他の変数を固定し、 $\lambda_1(t_0)$ のみを微小変動させた場合の E , $h_r(s)$ の変動分を表している。

(3) 式の $\frac{\partial^\dagger h_r(s)}{\partial \lambda_1(t_0)}$ は (1) 式より

$$\frac{\partial^\dagger h_k(t)}{\partial \lambda_1(t_0)} = \sum_{j \in J} \left(\frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} \frac{\partial^\dagger h_j(t - D_{jk})}{\partial \lambda_1(t_0)} \right) + \frac{\partial h_k(t)}{\partial \lambda_1(t_0)} \quad (4)$$

となる。但し、

J : k ノードの入力側に接続されたノードの添字の集合。

ここで、 $P_1(k, t, \lambda_1(t_0)) = \frac{\partial^\dagger h_k(t)}{\partial \lambda_1(t_0)}$ とおくと、(4) 式より、(5) 式の P_1 に関するフォワードプロパゲーションの繰り返し式が求まり、(3)(5)(6) 式より $\frac{\partial^\dagger E}{\partial \lambda_1(t_0)}$ が計算できる。

$$\begin{aligned}
& P_1(k, t, \lambda_1(t_0)) \\
&= \sum_{j \in J} \left[\frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} P_1(j, t - D_{jk}, \lambda_1(t_0)) \right] \\
&+ \frac{\partial h_k(t)}{\partial \lambda_1(t_0)}
\end{aligned} \tag{5}$$

$$\begin{aligned}
& (k \in R) \\
& (t \in T)
\end{aligned}$$

$$\begin{aligned}
& P_1(j, t < t_0, \lambda_1(t_0)) = 0 \\
& (j \in R)
\end{aligned} \tag{6}$$

3.2 2次微分の計算

(3) 式を $\lambda_2(t_0)$ で微分すると,

$$\begin{aligned}
& \frac{\partial^2 E}{\partial \lambda_1(t_0) \partial \lambda_2(t_0)} \\
&= \sum_{r \in R_s} \sum_{s \in S_o} \left[\frac{\partial^2 \left(\frac{\partial E}{\partial h_r(s)} \right)}{\partial \lambda_2(t_0)} \frac{\partial^2 h_r(s)}{\partial \lambda_1(t_0)} \right. \\
&+ \left. \frac{\partial E}{\partial h_r(s)} \frac{\partial^2 h_r(s)}{\partial \lambda_1(t_0) \partial \lambda_2(t_0)} \right] + \frac{\partial^2 \left(\frac{\partial E}{\partial \lambda_1(t_0)} \right)}{\partial \lambda_2(t_0)}
\end{aligned} \tag{7}$$

となる。従って、 $\frac{\partial^2 h_r(s)}{\partial \lambda_1(t_0)}$, $\frac{\partial^2 h_r(s)}{\partial \lambda_1(t_0) \partial \lambda_2(t_0)}$ が求まると、(7) 式より $\frac{\partial^2 E}{\partial \lambda_1(t_0) \partial \lambda_2(t_0)}$ が計算できる。 $\frac{\partial^2 h_r(s)}{\partial \lambda_1(t_0)}$ は (4) 式より、又、 $\frac{\partial^2 h_r(s)}{\partial \lambda_1(t_0) \partial \lambda_2(t_0)}$ は (4) 式を $\lambda_2(t_0)$ で微分して、

$$\begin{aligned}
& \frac{\partial^2 h_k(t)}{\partial \lambda_1(t_0) \partial \lambda_2(t_0)} \\
&= \sum_{j \in J} \left[\frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} \right)}{\partial \lambda_2(t_0)} \frac{\partial^2 h_j(t - D_{jk})}{\partial \lambda_1(t_0)} \right. \\
&+ \left. \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} \frac{\partial^2 h_j(t - D_{jk})}{\partial \lambda_1(t_0) \partial \lambda_2(t_0)} \right] \\
&+ \frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial \lambda_1(t_0)} \right)}{\partial \lambda_2(t_0)}
\end{aligned} \tag{8}$$

により求めることができる。

今、 $P_1(k, t, \lambda_1(t_0)) = \frac{\partial^2 h_k(t)}{\partial \lambda_1(t_0)}$, $P_2(k, t, \lambda_1(t_0), \lambda_2(t_0)) = \frac{\partial^2 h_k(t)}{\partial \lambda_1(t_0) \partial \lambda_2(t_0)}$ とおくと、(9) 式の P_2 に関する漸化式が得られる。

$$\begin{aligned}
& P_2(k, t, \lambda_1(t_0), \lambda_2(t_0)) \\
&= \sum_{j \in J} \left[\frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} \right)}{\partial \lambda_2(t_0)} P_1(j, t - D_{jk}, \lambda_1(t_0)) \right. \\
&+ \left. \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} P_2(j, t - D_{jk}, \lambda_1(t_0), \lambda_2(t_0)) \right] \\
&+ \frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial \lambda_1(t_0)} \right)}{\partial \lambda_2(t_0)}
\end{aligned} \tag{9}$$

$$\begin{aligned}
& (k \in R) \\
& (t \in T)
\end{aligned}$$

$$\begin{aligned}
& P_2(j, t < t_0, \lambda_1(t_0), \lambda_2(t_0)) = 0 \\
& (j \in R)
\end{aligned} \tag{10}$$

(9) 式の $\frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} \right)}{\partial \lambda_2(t_0)}$, $\frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial \lambda_1(t_0)} \right)}{\partial \lambda_2(t_0)}$ はそれぞれ、 $E = \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})}$, $E = \frac{\partial h_k(t)}{\partial \lambda_1(t_0)}$ とおき、1 次微分の計算により求めることができる。

4 ロバスト制御方式

文献 [12] の初期値変動に対するロバスト制御の場合は、初期時刻における変動のみを扱ったが、本論文では、外部入力変動として制御全時刻における変動を取り扱う。

4.1 動揺抑制指標

システムの制御目標の式表現である評価指標 E ((2) 式) に 外部入力変動によるシステムの動揺を抑制するための評価指標 E_H を付加し、システム全体の新たな評価指標 L を次式とする。

$$L = E + E_H \tag{11}$$

$$E_H = \sum_{s \in S_L} \sum_{r \in R_s} C_r \sum_{n \in I_p} \left(\frac{\partial^2 h_r(s)}{\partial r_n} \Delta r_n \right)^2 \tag{12}$$

ここで、

$$\begin{aligned}
R_s &: \text{動揺抑制ノードの添字の集合} \\
I_p &: \text{変動外部入力変数の添字の集合} \\
S_L &: \text{出力変動抑制評価時刻の集合} \\
r_n &: \text{外部入力} \\
C_r > 0 &: r \text{ ノードに対する重み係数}
\end{aligned}$$

従って、 $\frac{\partial^2 h_r(s)}{\partial r_n} \Delta r_n$ は r_n の変動による s 時刻における r ノードの出力 $h_r(s)$ の変動を示している。(12) 式はそれらの 2 乗和である。

従って、(11) 式の指標の局所最小化は r_n の変動が発生しても、その変動のシステム全体への影響を抑えようとすると、本来の評価の局所最小化を図る事となっている。

評価指標 L 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、 L がネットワークのノード出力及びノード出力の外部入力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、 L を局所最小とする制御系は構成できない。即ち、外部入力の変動に鈍感な、即ち、ロバストな制御系を構成するには、制御対象をノー

ド表現した場合のノード出力及びコントローラのノード出力がパラメータに関して微分可能である必要がある。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、また制御対象をノード表現した場合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 L の局所最小化による学習は次節の如く計算できる。

4.2 学習アルゴリズム

一般化学習ネットワークの局所最適化のための学習とは、(11) 式が局所最小となるパラメータ λ_m を求めることである。(以降パラメータは時不変とする。)

(11) 式を局所最小化するパラメータ λ_m の最適化のための学習は、勾配法を用いて下記の式にて行う。

$$\lambda_m \leftarrow \lambda_m - \gamma \frac{\partial L}{\partial \lambda_m} \quad (13)$$

$$\text{但し, } \frac{\partial L}{\partial \lambda_m} = \frac{\partial E}{\partial \lambda_m} + \frac{\partial E_H}{\partial \lambda_m}$$

$\gamma > 0$: 勾配法の学習係数

なお、 $\frac{\partial E}{\partial \lambda_m}$, $\frac{\partial E_H}{\partial \lambda_m}$ の計算は、3 節の 1 次、2 次微分を活用して計算することができる。

$\frac{\partial E}{\partial \lambda_m}$ の計算

$\frac{\partial E}{\partial \lambda_m}$ は $\lambda_1(t_0) = \lambda_m$ とおき、(3)(5)(6) 式より計算できる。

$\frac{\partial E_H}{\partial \lambda_m}$ の計算

(12) 式より、

$$\begin{aligned} \frac{\partial E_H}{\partial \lambda_m} &= 2 \sum_{s \in S_L} \sum_{r \in R_s} C_r \left[\sum_{n \in I_p} \left(\frac{\partial h_r(s)}{\partial r_n} \Delta r_n \right) \right. \\ &\quad \left. \times \sum_{n \in I_p} \left(\frac{\partial^2 h_r(s)}{\partial r_n \partial \lambda_m} \Delta r_n \right) \right] \end{aligned} \quad (14)$$

となるので、 $\frac{\partial h_r(s)}{\partial r_n}$, $\frac{\partial^2 h_r(s)}{\partial r_n \partial \lambda_m}$ を求めることにより $\frac{\partial E_H}{\partial \lambda_m}$ を計算できる。

$\frac{\partial h_r(s)}{\partial r_n}$ の計算

3 節の 1 次微分において、 $E = h_r(s)$, $\lambda_1(t_0) = r_n$ とおけば、次式が得られる。

$$\frac{\partial h_r(s)}{\partial r_n} = P_1(r, s, r_n) \quad (15)$$

$$\begin{aligned} P_1(k, t, r_n) &= \sum_{j \in J} \left[\frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} P_1(j, t - D_{jk}, r_n) \right] \\ &\quad + \frac{\partial h_k(t)}{\partial r_n} \end{aligned} \quad (16)$$

$\frac{\partial^2 h_r(s)}{\partial r_n \partial \lambda_m}$ の計算

3 節の 2 次微分において、 $E = h_r(s)$, $\lambda_1(t_0) = r_n$, $\lambda_2(t_0) = \lambda_m$ とおけば、次式が得られる。

$$\frac{\partial^2 h_r(s)}{\partial r_n \partial \lambda_m} = P_2(r, s, r_n, \lambda_m) \quad (17)$$

$$\begin{aligned} P_2(k, t, r_n, \lambda_m) &= \sum_{j \in J} \left[\frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} \right)}{\partial \lambda_m} P_1(j, t - D_{jk}, r_n) \right. \\ &\quad \left. + \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} P_2(j, t - D_{jk}, r_n, \lambda_m) \right] \\ &\quad + \frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial r_n} \right)}{\partial \lambda_m} \end{aligned} \quad (18)$$

なお、(18) 式における P_1 の係数 $\frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} \right)}{\partial \lambda_m}$ および $\frac{\partial^2 \left(\frac{\partial h_k(t)}{\partial r_n} \right)}{\partial \lambda_m}$ は、それぞれ $E = \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})}$, $E = \frac{\partial h_k(t)}{\partial r_n}$ とおくことにより、(3)(5)(6) 式にて容易に計算できる。

ここで、提案法における学習アルゴリズムをまとめると次のようになる。

step1: 学習パラメータ λ_m の初期値、対象システムおよびコントローラのノード出力の初期時刻での値を与える。また、外部入力変数 (参照入力) $r_n(t)$ を制御全時刻について与える。

step2: (1) 式のダイナミックスを全ノードについて計算する。

step3: $P_1(k, t, r_n)$, $P_2(k, t, r_n, \lambda_m)$
- (16)(18) 式 - を計算する。

step4: (13) 式を計算する。

(step2 ~ step4 の計算が一回の学習計算に対応し、これを必要回数繰り返すことになる。)

5 数値例

本論文では、ニューラルネットワークと同様、制御対象の数式表現が複雑なため従来の非線形制御理論では取り扱うことが困難な場合を考慮の対象としているが、本数値例では、提案の動揺抑制評価項目 ((11) 式第 2 項) の有効性すなわちロバスト性が、従来のニューラルネットワーク制御系 (すなわち、後述の通常の評価指標のみの場合) がもつロバスト性よりさらに強化されるか否かを検証できれば十分であるため、システムが既知である下記の非線形クリーンシステムを対象とする。

5.1 対象システム

Fig.2 にて示される非線形クレーンシステムを対象とする。台車の位置、荷の振れ角、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、次式にて記述できる。

$$\begin{aligned}\frac{d^2x}{dt^2} &= -\frac{mg}{M}\theta - \frac{D+G}{M}\frac{dx}{dt} + \frac{G}{M}u_1 \\ \frac{d^2\theta}{dt^2} &= -\frac{M+m}{lM}g\theta - \frac{D+G}{lM}\frac{dx}{dt} + \frac{G}{lM}u_1 \\ \frac{d^2l}{dt^2} &= -\frac{C+G_m}{m}\frac{dl}{dt} + \frac{G_m}{m}u_2\end{aligned}\quad (19)$$

但し、 u_1, u_2 は横走行モータ、巻き上げモータの入力電圧で、

C : 巻き上げ摩擦係数 [kg/sec] M : 台車の質量 [kg]
 D : 横走行摩擦係数 [kg/sec] m : 荷の質量 [kg]
 G, G_m : 台車系、巻き上げ系の電圧・トルク変換係数 [N/V] g : 重力加速度 [m/sec²]

である。

Fig.2 Structure of nonlinear crane control system

ここで、

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

とし、(19) 式を離散表現すると、

$$\begin{aligned}h_1(t) &= a_{11}h_1(t) + a_{21}h_2(t) \\ h_2(t) &= a_{22}h_2(t) + a_{32}h_3(t) + b_1u_1(t) \\ h_3(t) &= a_{33}h_3(t) + a_{43}h_4(t) \\ h_4(t) &= a_{24}\frac{h_2(t)}{h_5(t)} + a_{34}\frac{h_3(t)}{h_5(t)} \\ &\quad + a_{44}h_4(t) + \frac{b_1}{h_5(t)}u_1(t) \\ h_5(t) &= a_{55}h_5(t) + a_{65}h_6(t) \\ h_6(t) &= a_{66}h_6(t) + b_2u_2(t) \\ \text{但し、} \hat{t} &= t-1\end{aligned}\quad (20)$$

となる。ここで、 $a_{11} \sim b_2$ は、システム定数を含む定数を簡略表現したものである。

これら6つの式が、ULN 表現における制御対象のノード内処理関数となる。 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) で制御系を実現する場合の ULN で構成したフィードバック制御系を Fig.3 に示す。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、(20) 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ている。

Fig.3 A feedback control system of a nonlinear crane system using a layered controller

5.2 評価指標

数値例として、 $M = 40[\text{kg}], m = 2[\text{kg}], D = 300[\text{kg/sec}], G = 700[\text{N/V}], g = 9.8[\text{m/sec}^2], G_m = 0.98[\text{N/V}], C = 0.42[\text{kg/sec}]$ を使い、クレーンの横走行の目標位置 (x_{ref}) を 1m、荷の巻き上げ目標位置 (l_{ref}) を 0.5m とする。また、学習時の荷の巻き上げ位置の初期値は 1.0m とし、他の初期値は 0 とする。本数値例では外部入力変動として、全制御時刻における参照入力の変動 $r_n = l_{ref}$ を考える。

ここで、 l の目標値が変わることは、(19) 式において、 l の軌道が学習時と異なると θ の動特性が影響を受け、更にこれにより、台車位置 x が影響を受ける、即ち、制御対象システム全体の動特性が変化することを示している。この動特性の変化は、制御系に大きく影響し、これが学習によって構成された制御系の性能の劣化やシステムの不安定性の原因となる。本シミュレーションの目的は、この l_{ref} を種々変化させ、動揺抑制評価を考慮しない従来の設計法と、考慮する提案のロバスト設計法の制御性能を比較することにある。

ここで、システムの所期の目標、及び、巻き上げ位置の変動によるシステムの動揺抑制を達成するための評価指標

E, E_H をそれぞれ、次のように設定する。

$$E = \frac{1}{2} \left[\sum_{s \in S_o} \{Q_{11}(x_{ref} - h_1(s))^2\} + Q_{12}(h_2(|T|))^2 \right. \\ + \sum_{s \in S_o} \{Q_{13}(h_3(s))^2 + Q_{14}(h_4(s))^2\} \\ + \sum_{s \in S_o} \{Q_{15}(l_{ref} - h_5(s))^2\} + Q_{16}(h_6(|T|))^2 \\ \left. + \sum_{s \in S_o} \{R_1(h_8(s))^2 + R_2(h_{10}(s))^2\} \right] \quad (21)$$

$$E_H = \sum_{s \in S_L} \sum_{r \in R_s} C_r \left(\frac{\partial^\dagger h_r(s)}{\partial l_{ref}} \Delta l_{ref} \right)^2 \quad (22)$$

Table 1 Simulation conditions

S_L	: 全てのサンプリング時間
R_s	: $x, \dot{x}, \theta, \text{ and } \dot{\theta}$
$ T $	: 最終時刻 (= 7.5[sec])
Q_{11}	: 0.5
Q_{15}	: 10.0
Q_{others}	: 1.0
$R_1 \sim R_2$	: 0.1
Δl_{ref}	: 1
学習回数	: 4000

これらの値を用いて評価指標 E のみを用いた場合の従来法 (以下 $case_E$) と本論文提案の評価指標 $L = E + E_H$ を用いた場合の提案法 (以下 $case_L$) のそれぞれについて学習を行った。

5.3 シミュレーション結果

(11) 式の第1項と第2項のトレードオフを決定する重み係数 C_r は試行錯誤にて $C_1 = C_2 = 10.0, C_3 = C_4 = 0.5, C_5 = C_6 = 0.0$ とした (Fig.4, ~, Fig.9)。

重み C_r の違いの効果をみるためのシミュレーションでは, $C_1 = C_2 = 0.5, C_1 = C_2 = 10.0$ と $C_1 = C_2 = 20.0$ (C_3, C_4, C_5, C_6 は変更しない) の3ケースとした (Fig.10)。

(1) 学習結果

Fig.4 に, $case_E, case_L$ のそれぞれについて, 乱数で与えるネットワークの重みの初期値を3通り変えて学習を行なったときの評価指標の値を示す。 $case_L$ の場合については, 評価値 L と L の一部である E の両方について示した。 $case_E, case_L$ 両方の E を比較すると $case_L$ の E の方が若干値が大きくなっている。これはロバスト制御実現のため評価指標 (11) 式の第2項も同時に最小化するためである。なお, 学習重みの初期値を変えて学習を行なっても評価値はほぼ同じ値に収束した。

Fig.5 に, $case_L$ についての学習終了時の制御結果を示す。学習時 重みの初期値を3とおり変えて行っても制御結果は,

ほぼ一致している。以後, シミュレーション結果は, 1つのケースについて示す。

Fig.6 に $case_E$ と $case_L$ の学習時の制御結果を示す。評価指標の値 ($case_E$ のほうが小さい) から推測されたように, 台車位置 (x) の応答は $case_E$ の方が速応性がよく, 定常誤差も小さい。但し, 荷の振れ角 (θ) は $case_E$ の方がより振動的である。

Fig.4 Values of criterion function E, L in the case of three random initial values of learning parameters

Fig.5 Control results at learning stage in the case of three different random initial values of λ_m

Fig.6 Control results of both $case_E$ and $case_L$ at learning stage with $l_{ref} = 0.5$

(2) ロバスト性

学習により得られた制御系 (Fig.3 参照) を用いて, 外部入力である荷の巻き上げ目標位置 (l_{ref}) を種々変化させて制御を行い, ロバスト性の検証を行なった。この時の制御結果について $case_E$ と $case_L$ を比較する。

Fig.7 ~ Fig.9 は, l_{ref} を, 1.5, 3, 6 と学習時の値 0.5 から徐々に変動幅を大きくしていった時の制御結果である. 変動幅を大きくするにつれて通常の制御を行う $case_E$ の場合は, 徐々に台車の位置 (x), 荷の振れ角 (θ) の変動幅が大きくなり, $l_{ref} = 6$ になると, 大きく振動し, 制御できない状態に至っていることが分かる. 一方, $case_L$ の方は, 変動幅が大きくなっても, x, θ 両者とも, それほど変動していない. これらの結果より動揺抑制評価指標 E_H の効果が大きく, 提案法が有効であることが分かる.

Fig.7 Control results of both $case_E$ and $case_L$ at control stage with $l_{ref} = 1.5$

Fig.8 Control results of both $case_E$ and $case_L$ at control stage with $l_{ref} = 3.0$

Fig.9 Control results of both $case_E$ and $case_L$ at control stage with $l_{ref} = 6.0$

(3) 重み C_r の違いの効果

Fig.10 は, $case_L$ について, 台車の位置及び速度 $\dot{x}$ に対応する動揺抑制評価重み C_1, C_2 のみを, それぞれ 0.5, 10.0, 20.0 と変え, 他はこれまでと同じ条件で学習を行い, やはり, $l_{ref} = 6$ と変動させて制御を行ったときのそれぞれの制御結果である. 重みを大きくするにつれて変動がより強く抑制されることとなっている.

Fig.10 Control results of three cases of $case_L$ at control stage with $l_{ref} = 6.0$

注: 本数値例におけるクレーンシステムの非線形性について

著者らは, 参考文献 [14] において, 本論文のシミュレーションで用いている非線形クレーンシステムを対象システムとし, 線形コントローラを用いた制御シミュレーションを行なっている. ここでは, 台車の移動距離を, 本シミュレーションと同じく 1.0[m] とした場合, 荷の巻き上げ移動距離が 1.2[m] を越えると, 非線形性が強くなり制御系は不安定になった. この点を考慮すると, 本論文におけるシミュレーションにおける学習時の台車の移動距離 1.0[m], 荷の巻き上げ移動距離 0.5[m] は線形コントローラで制御可能な範囲といえる. 従って, 学習時点では, 線形の動作範囲を制御するコントローラを設計していることになる. しかしながら, 本来の目的であるロバスト性の検証では, 荷の移動距離を Fig.7 では, 0.5[m], Fig.8 では, 2.0 [m], Fig. 9 では, 4.0[m] と線形の動作範囲をはるかに越えた, 即ち, 非線形の強い動作範囲でのロバスト性の検証を行ない, 良好な制御結果を得ている. 従って, 提案の方法は, 線形の動作範囲での学習にもかかわらず, 非線形の強い動作範囲に対しても高いロバスト性を保証するコントローラの設計法であると言える.

6 おわりに

システムの初期状態の変動時には リアプノフの意味での安定領域を拡大し, また, システムの構造変動であるシステムパラメータ変動に際しては 変動前の性能維持を目指すロバストな制御方式をすでに提案した.

本論文では上記の基本的な考え方を踏襲しつつ, システムへの外部入力変動した場合, 外部入力変動に応じて学習ネットワーク内の適切なノード出力を的確にตอบสนองさせ, 且つ, ロバストにすべきノード出力を抑制する手法を提案した.

また, 提案のロバスト制御系設計法が大幅な外部入力変動に対しても良好な制御性能を維持する有効な手法であることを数値例により示した.

なお, 本論文における数値例では, 非線形クレーンシステムというシステムのダイナミクスが既知のシステムを用いて提案法の有効性を示したが, 未知のシステムに対する本提案法の有効性については別途報告する.

本論文も含め, これまでの論文では, ある一つの環境変

動に対してロバストな制御系の設計法を提案してきた。しかしながら、実際の場合、複数の環境の変動が同時に発生しうることを考慮すると、どのような種類の環境変動にも耐えうる統一的なロバスト制御系設計法の開発が今後の課題である。

(平成 9 年 4 月 23 日受付, 平成 10 年 1 月 13 日再受付)

文 献

- (1) P.Werboos: Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences, Ph.D. dissertation, Harvard University (1974).
- (2) Yann Le Cun, John S.Denker, Sara A. Solla: Optimal Brain Damage, Advances in Neural Information Processing Systems 2, pp598-605 (1989).
- (3) Xiao-Hu Yu: Efficient Estimation of Dynamically Optimal Learning Rate Using Higher Order Derivatives, Proc of 1996 IEEE International Conference on Neural Networks, pp.1251-1256 (1996).
- (4) Hunt K.J., D.Sbarbaro, R.Zbikowski, P.J.Gawthrop, "Neural networks for control systems - A survey," Automatica, Vol.28, No.6, pp.1083-1112 (1992).
- (5) W.L. Buntine, A.S. Weigend: Computing Second Derivatives in Feed-Forward Networks: A review, IEEE Trans. on Neural Networks, Vol.5, No.3, May (1994).
- (6) 平澤, 大林, 藤田, 古賀: 一般化学学習ネットワーク理論, 電気学会論文誌, Vol.116-C, No.7, pp794-801 (1996).
- (7) 平澤, 大林, 古賀, 村田, 楠見: 一般化学学習ネットワークの高次微分の計算理論, 電気学会論文誌, Vol.115-C, No.12, pp.1499-1506 (1995).
- (8) 平澤, 大林, 古賀: フォワードプロパゲーション一般化学学習ネットワーク理論, 電気学会論文誌, Vol.116-C, No.6, pp.692-698 (1996).
- (9) K.Hirasawa, M.Ohbayashi, J.Murata: Universal Learning Network and Computation of its Higher Order Derivatives, Proc. of 1995 IEEE International Conference on Neural Networks, Vol.3, pp1273-1277 (1995).
- (10) K.Hirasawa, M.Ohbayashi, M.Koga, M.Harada: Forward Propagation Universal Learning Network, Proc. of 1996 IEEE International Conference on Neural Networks, pp353-358 (1996).

- (11) 大林, 平澤: 一般化学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, Vol.117-D, No.3, pp.289-297(1997).
- (12) M.Ohbayashi, K.Hirasawa, J.Murata, M.Harada: Robust Learning Control using Universal Learning Network, Proc. of 1996 IEEE International Conference on Neural Networks, pp.2208-2213 (1996).
- (13) 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, No4 (1997).
- (14) 大林, 平澤, 村田, 梶原, 相良: パラメータ変動を伴うシステムのロバスト極配置制御とその非線形システムへの応用, 電気学会論文誌, Vol.115-C, No.8, pp984-991(1995).

大林 正直 (正員) 昭和26年10月22日生.50年3月九州工

業大学工学部電気工学科卒業.52年3月九州大学大学院工学研究科修士課程電気工学専攻修了.52年4月(株)日立製作所入社大みか工場勤務.平成1年4月九州大学工学部助手.平成9年7月同助教授.現在に至る.博士(工学).計測自動制御学会, システム制御情報学会の各会員.

平澤宏太郎 (正員) 昭和17年1月26日生.39年3月九州

大学工学部電気工学科卒業.41年3月九州大学大学院工学研究科電気工学専攻修了.41年4月(株)日立製作所入社日立研究所勤務.平成1年8月同所副所長.平成3年8月大みか工場主管技師長.平成4年12月九州大学工学部教授.平成8年4月九州大学大学院システム情報科学研究科教授.現在に至る.計測自動制御学会, 情報処理学会, 米国IEEEの各会員.工学博士.