

## 一般化学習ネットワークの2次微分を利用した外乱抑制ロバスト制御方式

大林, 正直  
電気電子システム工学専攻

平澤, 宏太郎  
電気電子システム工学専攻

西村, 健一郎  
東ソー株式会社

<https://doi.org/10.15017/1485131>

---

出版情報：九州大学大学院システム情報科学紀要. 2 (1), pp.131-137, 1997-03-26. 九州大学大学院システム情報科学研究所  
バージョン：  
権利関係：

# 一般化学習ネットワークの2次微分を利用した外乱抑制ロバスト制御方式

大林 正直\* · 平澤宏太郎\* · 西村健一郎\*\*

## Robust Control for Disturbances of a Nonlinear System Using Universal Learning Network

Masanao OHBAYASHI, Kotaro HIRASAWA and Kenichirou NISIMURA

(Received December 24, 1996)

**Abstract:** As 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 circumstances. But NN controllers may not work well under very different circumstances from those at learning stage. For example, NN controllers are usually made without considering disturbances because NN controllers do not have a means to suppress their influences. So, in case of existing the disturbances NN controllers do not work well. In this paper a robust control system design method for the disturbances is discussed using second order derivatives of Universal Learning Network.

**Keywords:** Neural networks, Universal learning networks, Learning, Second order derivative, Disturbance, Robust control, Nonlinear system

### 1. はじめに

非線形システムの非線形性や複雑性が増加するにつれて、数学的制御理論を用いてそのようなシステムの制御器を構成することが段々難しくなってくる。このようなシステムの制御系を構成する場合の有力な手段として、ニューラルネットワーク (NN) を用いた方法があげられる。即ち、NNは、システムの非線形性や複雑性に容易に対処できる能力をもつ。また、NNを用いた制御器は、あるシステム環境条件下において、評価指標を最小化する学習を行うことにより得られ、学習時のシステム環境と少々異なる環境条件下における制御においても、ある程度の制御性能を保つ能力、即ち、汎化能力をもつ。しかしながら、この環境変化が大きい場合はもはや、汎化能力では対処できず、制御性能の劣化、さらにはシステムの不安定性をも招く場合も考えられる。

このようなシステム環境の変化として、1) システムの状態初期値の変動、2) システムパラメータ変動、3) システムへの目標値入力変化、4) 外乱入力の有無等が考えられる。これらの1)-3)のシステム環境の変化に対しては、NN 制御器では良好な制御性能が得られない場合についても、良好な制御性能を維持する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方式とその具体例

が既に著者等によりそれぞれ提案されている<sup>9)10),11),12)</sup>。

本論文においては、上記4)のシステムへの外乱入力により、NNコントローラでは、良好な制御性能が得られない場合でも、外乱入力の影響を抑制し、良好な制御性能を維持する一般化学習ネットワーク(Universal Learning Network: ULN)の2次微分を利用した外乱抑制ロバスト制御方式を提案し、その具体的設計例により提案方式がNN制御方式より制御性能において優れていることを示す。

ここで、一般化学習ネットワークの一般化とは、離散形のRecurrent Neural Network(RNN)を、次のような点で拡張、一般化したことを意味している。

**一般化1** RNNが、非線形処理ノードにて1サンプリングの遅れを持つとするのに対し、ULNは、ノード間ブランチに、正、零、負の任意の整数のサンプリング遅れを持つネットワーク構成を可能とする<sup>4)</sup>。

**一般化2** RNNが各ノード間を単一ブランチで接続するのに対し、ULNでは、各ノード間を複数ブランチによる接続を可能とし、かつ、各ブランチに任意の遅れを許す<sup>7)8)</sup>。

**一般化3** RNNが、評価指標のパラメータに対する1次微分計算機能を持つのに対しULNは、評価指標のパラメータに対する高次微分計算機能を持つ<sup>5)6)7)8)</sup>。

ULNにおける学習については、Backward Propagation(B.P.)学習法<sup>4)5)6)</sup>及びForward Propagation(F.P.)

平成8年12月24日受付

\* 電気電子システム工学専攻

\*\* 東ソー株式会社

学習法<sup>7)8)</sup>が既に提案されている。

なお、ネットワークシステムにおいて、評価関数のパラメータ等に関する高次微分の応用研究は、[Le Cun,etal]<sup>2)</sup>が2次微分について、[Xia-Hu,etal]<sup>3)</sup>が4次微分まで検討している例があるが、これ等は階層型での非ダイナミカルネットワークシステムについての検討であり、リカレントシステムについての検討はなされていない。

また、通常使用される時不変のパラメータを学習する場合に必要な高次微分の計算量は、B.P.方式に比較し、F.P.方式が有利であるため<sup>7)8)</sup>、本論文では、F.P.方式を利用した外乱入力に対するロバスト制御方式について考察する。

## 2. 一般化学習ネットワークの基本構成

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。




Fig.1 Structure of ULN

一般化学習ネットワークの基本方程式:

$$h_j(t) = O_j(\{h_i(t - D_{ij}) | i \in I\}, \{\lambda_m(t)\}, \{r_{m'}(t)\}) \quad (1)$$

$h_j(t)$  :  $j$  ノードの  $t$  時刻の出力値

$\lambda_m(t)$  :  $m$  パラメータ変数の  $t$  時刻の値

$r_{m'}(t)$  :  $m'$  外部入力変数(外乱, 参照入力等)の  $t$  時刻の値

$I$  :  $j$  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

ネットワークの評価指標  $E$  を,

$$E = E(\{h_r(s)\}, \{\lambda_m(s)\}, \{r_{m'}(s)\}) \quad (2)$$

とする。ここで、

$r \in R_0, R_0$  : 評価に関するノードの添字の集合

$m \in M_0, M_0$  : 評価に関するパラメータ変数の添字の集合

$m' \in M'_0, M'_0$  : 評価に関する外部入力変数(外乱)の添字の集合

$s \in S_0, S_0$  : 評価サンプル時刻の集合

## 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

$$\frac{\partial^\dagger E}{\partial \lambda_1(t_0)} = \sum_{r \in R_0} \sum_{s \in S_0} \left( \frac{\partial E}{\partial h_r(s)} \frac{\partial^\dagger h_r(s)}{\partial \lambda_1(t_0)} \right) + \frac{\partial E}{\partial \lambda_1(t_0)} \quad (3)$$

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<sup>1)</sup>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、一般に、

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

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。

$$P_1(k, t, \lambda_1(t_0))$$

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

$k \in R, t \in T$

$$P_1(j, t_0 - 1, \lambda_1(t_0)) = 0 \quad j \in R \quad (6)$$

$R$  : ノードの添え字の集合

$T$  : 時刻の集合

### 3.2 2次微分の計算

(3)式を  $\lambda_2(t_0)$  で微分すると、

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

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

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

により求めることができる。

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

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

$$k \in R, \quad t \in T$$

$$P_2(j, t_0 - 1, \lambda_1(t_0), \lambda_2(t_0)) = 0 \quad (10)$$

$j \in R$   
(9)式の  $\frac{\partial^{\dagger} \left( \frac{\partial h_k(t)}{\partial h_j(t-D_{jk})} \right)}{\partial \lambda_2(t_0)}$ ,  $\frac{\partial^{\dagger} \left( \frac{\partial h_k(t)}{\partial \lambda_1(t_0)} \right)}{\partial \lambda_2(t_0)}$  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

### 4.1 動揺抑制指標

システムを制御するための評価指標  $E$  ((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。

$$L = E + E_H \quad (11)$$

$$E_H = CH \sum_{s \in S_L} \sum_{r \in R_s} \left( \sum_{m' \in I_p} \frac{\partial^{\dagger} h_r(s)}{\partial r_{m'}(t_1)} \Delta r_{m'}(t_1) \right)^2 \quad (12)$$

ここで、

- $R_s$  : 動揺抑制ノードの添字の集合
- $I_p$  : 変動外部入力変数の添字の集合
- $S_L$  : 出力変動抑制評価時刻の集合
- $r_{m'}(t)$  : 時刻  $t$  における外部入力
- $CH > 0$  : 重み係数

従って、 $\frac{\partial^{\dagger} h_r(s)}{\partial r_{m'}(t_1)} \Delta r_{m'}(t_1)$  は  $t_1$  時刻の  $r_{m'}(t)$  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)式の指標の最小化は  $t_1$  時刻に  $r_{m'}(t)$  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るとともに、本来の評価の最小化を図る事となっている。

### 4.2 学習アルゴリズム

一般化学習ネットワークの最適化のための学習とは、(11)式が最小となるパラメータ変数  $\lambda_m$  を求めることである。以降、パラメータ変数を時不変とした場合の学習アルゴリズムについて記す。

(11)式を最小化するパラメータ変数  $\lambda_m$  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。

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

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

$\gamma > 0$  : 勾配法の学習係数

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

#### [I] $\frac{\partial^{\dagger} E}{\partial \lambda_m}$ の計算

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

#### [II] $\frac{\partial^{\dagger} E_H}{\partial \lambda_m}$ の計算

(12)式より、

$$\begin{aligned} & \frac{\partial^{\dagger} E_H}{\partial \lambda_m} \\ &= 2 CH \sum_{s \in S_L} \sum_{r \in R_s} \left[ \left( \sum_{m' \in I_p} \frac{\partial^{\dagger} h_r(s)}{\partial r_{m'}(t_1)} \Delta r_{m'}(t_1) \right) \right. \\ & \left. \times \left( \sum_{m' \in I_p} \frac{\partial^{\dagger 2} h_r(s)}{\partial r_{m'}(t_1) \partial \lambda_m} \Delta r_{m'}(t_1) \right) \right] \end{aligned} \quad (14)$$

となるので、 $\frac{\partial^{\dagger} h_r(s)}{\partial r_{m'}(t_1)}$ ,  $\frac{\partial^{\dagger 2} h_r(s)}{\partial r_{m'}(t_1) \partial \lambda_m}$  を求めることにより

$\frac{\partial \dagger E_H}{\partial \lambda_m}$  を計算できる。

<  $\frac{\partial \dagger h_r(s)}{\partial r_{m'}(t_1)}$  の計算 >

3節の1次微分において、 $E = h_r(s)$ ,

$\lambda_1(t_0) = r_{m'}(t_1)$ , とおけば, 次式が得られる。

$$\frac{\partial \dagger h_r(s)}{\partial r_{m'}(t_1)} = P_1(r, s, r_{m'}(t_1)) \quad (15)$$

$$\begin{aligned} P_1(k, t, r_{m'}(t_1)) &= \sum_{j \in J} \left[ \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} P_1(j, t - D_{jk}, r_{m'}(t_1)) \right] \\ &+ \frac{\partial h_k(t)}{\partial r_{m'}(t_1)} \end{aligned} \quad (16)$$

<  $\frac{\partial \dagger^2 h_r(s)}{\partial r_{m'}(t_1) \partial \lambda_m}$  の計算 >

3節の2次微分において、 $E = h_r(s)$ ,

$\lambda_1(t_0) = r_{m'}(t_1)$ ,  $\lambda_2(t_0) = \lambda_m$  とおけば, 次式が得られる。

$$\frac{\partial \dagger^2 h_r(s)}{\partial r_{m'}(t_1) \partial \lambda_m} = P_2(r, s, r_{m'}(t_1), \lambda_m) \quad (17)$$

$$\begin{aligned} P_2(k, t, r_{m'}(t_1), \lambda_m) &= \sum_{j \in J} \left[ \frac{\partial \dagger \left( \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} \right)}{\partial \lambda_m} P_1(j, t - D_{jk}, r_{m'}(t_1)) \right] \\ &+ \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} P_2(j, t - D_{jk}, r_{m'}(t_1), \lambda_m) \\ &+ \frac{\partial \dagger \left( \frac{\partial h_k(t)}{\partial r_{m'}(t_1)} \right)}{\partial \lambda_m} \end{aligned} \quad (18)$$

なお, (18)式における $P_1$ の係数 $\frac{\partial \dagger \left( \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})} \right)}{\partial \lambda_m}$  および $\frac{\partial \dagger \left( \frac{\partial h_k(t)}{\partial r_{m'}(t_1)} \right)}{\partial \lambda_m}$  は, それぞれ $E = \frac{\partial h_k(t)}{\partial h_j(t - D_{jk})}$   $E = \frac{\partial h_k(t)}{\partial r_{m'}(t_1)}$  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 $\lambda_m$ 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(外乱) $r_{m'}(t)$ を制御全時刻について与える。

**step2:** (1)式のダイナミクスを全ノード, 全制御時間について計算する。

**step3:**  $P_1(k, t, r_{m'}(t_1))$ ,  $P_2(k, t, r_{m'}(t_1), \lambda_m)$  - (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. 数値実験

### 5.1 対象システムとそのULN表現

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 $x, \theta, l$ 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。

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

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]  
 $G, G_m$  : 台车系, 巻き上げ系の電圧・トルク変換係数[N/V]     $g$  : 重力加速度[m/sec<sup>2</sup>]




Fig.2 Structure of a nonlinear crane 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,

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

但し,  $\hat{t} = t - 1$  となる。  $u_1, u_2$  を各々2個の制御ノード(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 U.L.N. 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。)

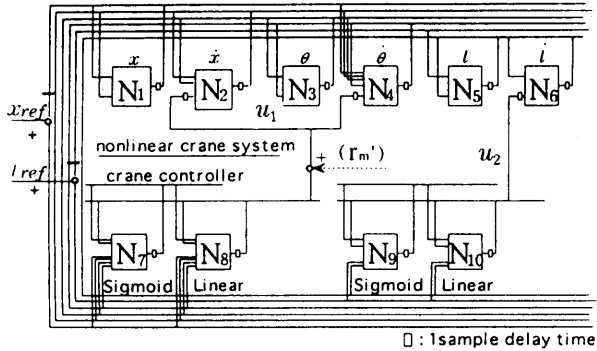


Fig.3 Control model of a nonlinear crane system using ULN

5.2 数値例と学習条件

数値例として、 $M = 40[kg], D = 300[kg/sec], G = 700 [N/V], m = 2[kg], g = 9.8[m/sec^2], G_m = 0.98[N/V], C = 0.42 [kg/sec]$  を使い、クレーンの横走行の目標位置 ( $x_{ref}$ ) を 1[m], 荷の巻き上げ目標位置 ( $l_{ref}$ ) を 0.5[m], 学習時のシステム出力の初期値を  $h_5(0) = 1.0, h_i(0) = 0.0 (i = 1, 2, 3, 4, 6)$  とし、評価指標  $E$  は次式とする。

$$E = \frac{1}{2} \left[ \sum_{s \in S_o} \{Q_{11}(x_{ref} - h_1(s))^2\} + Q_{12}(h_2(t_f))^2 + \sum_{s \in S_o} \{Q_{13}(h_3(s))^2 + Q_{14}(h_4(s))^2\} + \sum_{s \in S_o} \{Q_{15}(l_{ref} - h_5(s))^2\} + Q_{16}(h_6(t_f))^2 + \sum_{s \in S_o} \{R_1(h_7(s))^2 + R_2(h_9(s))^2\} \right] \quad (21)$$

(21)式において、 $S_o$ : 制御全時刻,  $t_f$ : 制御最終時刻 = 7.5[sec],  $Q_{11} \sim Q_{16} = 1.0, R_1 \sim R_2 = 0.001$  とした。

(12)式において、 $CH = 120, S_L$ : 制御全時刻,  $R_s$ : 全システムノード,  $\Delta r_{m'} = 0.5$  は、制御器出力  $u_1(t)$  への加法的ステップ状外乱(Fig.3 参照)を設定し、評価指標  $E$  の最小化学習(case\_E),  $L$  の最小化学習(case\_L) をそれぞれ 5000回行って制御器を構成した。

5.3 数値実験及び結果

先の学習により得られた制御系Fig.3において、Fig.4 に示す disturbance A, disturbance B の2ケースの外乱を実際に  $u_1$  に付加し、それぞれについて制御を行った。




Fig.4 Additional disturbances to  $u_1$

Fig.5 は外乱がない場合の制御結果で、case\_E, case\_L の両制御系の結果に差はない。Fig.6 ~ Fig.9 は外乱Aを付加し、その大きさを種々変化させた場合の制御結果である。Fig.10 ~ Fig.13 は外乱Bを付加し、その大きさを種々変化させた場合の制御結果である。これらの結果より次のことがいえる。

- 外乱の種類・大きさによらず外乱抑制評価  $E_H$  の効果 (case\_L) は大きい
- case\_L の学習では、外乱の位置とその一定の大きさ (=0.5) を条件として与えた(但し、学習時には外乱は発生しない) が、時間的に変化する外乱に対しても有効

6. 結 び

一般化学習ネットワークの2次微分を利用した外乱に対するロバスト制御方式を提案し、通常の NN制御系と比較し、提案法の有効性を示した。本提案法は、外乱の発生場所さえ特定できれば制御系の設計は可能であり、また、数値例から提案法が、外乱の種類・大きさによらず有効であること、さらに、数値例では、1箇所の外乱を設定したが、提案法が、複数場所で同時に発生する外乱に対処できることを考慮すれば、本提案法は、実現が容易で、かつ、実際的な外乱抑制ロバスト制御方式と考えることができる。




Fig.5 Control results without a disturbance




Fig.6 Positions of the crane stand in case of  $case_E$  with the disturbance A




Fig.7 Positions of the crane stand in case of  $case_L$  with the disturbance A




Fig.8 Angles between the rope and vertical line in case of  $case_E$  with the disturbance A




Fig.9 Angles between the rope and vertical line in case of  $case_L$  with the disturbance A




Fig.10 Positions of the crane stand in case of  $case_E$  with the disturbance B




Fig.11 Positions of the crane stand in case of  $case_L$  with the disturbance B

参 考 文 献

- 1) P.Werbo: 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) 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, Vol.116-C, No.7, pp794-801 (1996).
- 5) 平澤, 大林, 古賀, 村田, 楠見: 一般化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).
- 6) 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).
- 7) 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, Vol.116-C, No.6, pp.692-698 (1996).
- 8) 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).
- 9) 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, Vol.117-D, No.3 (1997).
- 10) 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).
- 11) M.Ohbayashi, K.Hirasawa, J.Murata, M.Harada: Robust Control using Second Order Derivatives of Universal Learning Network, - for system parameter perturbation -, Proc. of 1996 IEEE International Conference on Systems, Man, and Cybernetics, pp.1184-1189 (1996).
- 12) M.Ohbayashi, K.Hirasawa: Robust Control for External Input Perturbation using Second Order Derivative of Universal Learning Network, Proc. of 11th Korea Automatic Control Conference, pp.111-114 (1996).




Fig.12 Angles between the rope and vertical line in case of  $case_E$  with the disturbance B




Fig.13 Angles between the rope and vertical line in case of  $case_L$  with the disturbance B

