

ニューラルネットワークを用いた2層タンクシステムの制御

笠原 雅人*, 栗島 一徳**

The Control of Two-Layer Tank System using Neural Network

Masato KASAHARA*, Ittoku KURISHIMA**

The controlled object of this study is a two-layer tank system. The neural network's view was used a technique for carrying out system identification. And, model predictive control is used the control technique. The validity and adaptability of these control schemes were examined.

キーワード：2層タンクシステム, ニューラルネットワーク, モデル予測制御

Keywords: two-layer tank system, neural network, model predictive control

1. はじめに

ニューラルネットワーク (NN とも称する) とは, 脳機能に見られるいくつかの特性を計算機上のシミュレーションによって表現することを目指した数学モデルである. 脳神経回路網を人工的・工学的にモデル化したもので, 非線形特性と学習能力を持つシステムである. この学習能力を活かしてニューラルネットワークは様々な分野での応用が期待されている. 脳の学習機構をソフト的に模倣する手段の一つであり, ニューロン同士の結合により構成される. 本研究ではニューラルネットワークを用いてシステム同定し, 実際のシステムを制御することに応用する. ニューラルネットワークはその構造から階層型と相互結合型とに大別される. Fig.1 に示すような入力層, 中間層, 出力層の3層からなる階層型ニューラルネットワークを本研究では用いた. ニューラルネットワークは各層をつなぐ線に対して重み付けがなされる. そして, ○の部分で入力された信号は足し合わされ, ある関数 (本研究では双曲線関数 $\tanh(\cdot)$) を通して出力される.

ニューラルネットワークは人間の脳のメカニズムを模したもののだが, 脳のシステムを再現すること自体が目的でなく, あくまで問題解決の一つの手段として存在している.

本研究ではニューラルネットワークを用いてシステム同定し, 構築したモデルを用いて, 2層タンクシステムの液面制御を行うことが目的である.

2. システム同定

システム同定とは, システムの入出力データから対象と




Fig. 1. 階層型ニューラルネットワーク

するシステムの数学モデルを構築することをいう. ニューラルネットワークをシステム同定に用いる場合, 非線形システムに対して, 従来なら線形モデルでシステムを記述していたところを, 非線形で記述できるという利点を持っている. 本研究ではシステム同定によく用いられる ARX モデルと同じ, 過去の入出力を回帰ベクトルとする NNARX モデルを用いて同定を行った. 以下に2つのモデルについて説明する.

〈2・1〉 ARX モデル システムが次の入力と出力の差分方程式で与えられるとする.

$$y(t) + a_1y(t-1) + \dots + a_{n_a}y(t-n_a) = b_1u(t-1) + \dots + b_{n_b}u(t-n_b) + w(t) \dots (1)$$

ここで $w(t)$ は白色雑音, n_a は過去の出力の数, n_b は過去の入力の数を表す. また

$$\theta = [a_1, \dots, a_{n_a}, b_1, \dots, b_{n_b}]^T \dots (2)$$

$$\begin{aligned} \varphi(t) &= [\varphi_1(t), \dots, \varphi_k(t), \dots, \varphi_{n_a+n_b}(t)] \\ &= [u(t-1), \dots, u(t-n_b), \\ &\quad y(t-1), \dots, y(t-n_a)] \dots (3) \end{aligned}$$

とすると上式は次の様に表される.

$$y(t) = \theta^T \varphi(t) + w(t) \quad (4)$$

ここで,

* 小山工業高等専門学校 電子制御工学科 (Dept. of Electronic Control Engineering), E-mail: kasahara@oyama-ct.ac.jp

** 小山工業高等専門学校 電子制御工学科 卒業生 (Dept. of Electric and Control Engineering)




Fig. 2. ARX モデル

$$A(q^{-1}) = 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \dots\dots\dots (5)$$

$$B(q^{-1}) = b_1q^{-1} + \dots + b_{n_b}q^{-n_b} \dots\dots\dots (6)$$

とおけば、次式が得られる。

$$A(q^{-1})y(t) = B(q^{-1})u(t) + w(t)$$

この様に記述されるモデルを ARX(Auto-Regressive-model with eXogenous-input:外因性入力を持つ自己回帰モデル) という。ARX モデルの場合、時刻 $t - 1$ までに測定された入出力データから計算される 1 段先の予測値 $\hat{y}(t)$ は次式で与えられる。

$$\hat{y}(t) = \theta^T \varphi(t) \quad (7)$$

〈2・2〉 NNARX モデル NNARX モデルの構造を Fig.3 に示す。このモデルは回帰ベクトルが、ARX (Auto-Regressive eXogeneous) モデルと同じ過去の入力と出力であるため、NNARX (Neural Network ARX) モデルと呼ばれている。ここで u はシステムの入力、 y はシステムの出力、 \hat{y} は出力の予測値を表す。このモデルから求める一段先予測値 $\hat{y}(t)$ は次式となる。

$$\hat{y}(t) = \sum_{j=1}^N W_j \tanh \left[\sum_{k=1}^{n_a+n_b} w_{jk} \varphi_k(t) + w_{j0} \right] + W_0 \dots\dots\dots (8)$$

ここで、

$$W_1 = \begin{bmatrix} w_{11} & \dots & w_{1n_b} \\ w_{N1} & \dots & w_{Nn_b} \\ w_{1,n_b+1} & \dots & w_{1,n_b+n_a} & w_{10} \\ w_{N,n_b+1} & \dots & w_{N,n_b+n_a} & w_{N0} \end{bmatrix} \dots (9)$$

$$W_2 = [W_1 \quad \dots \quad W_N \quad W_0] \dots\dots\dots (10)$$

として、 N は中間層の数を表し、 $\varphi(t)$ をデータベクトル、 W_1 は $N \times (n_a + n_b + 1)$ 行列、 W_2 は $1 \times (N + 1)$ 行列で、重み行列と呼ぶ。

この重みを次の評価関数が最小となるように決定することがニューラルネットワークを用いた場合の同定問題である。

$$V_N(\theta, Z^N) = \frac{1}{2N} \sum_{t=1}^N [y(t) - \hat{y}(t|\theta)]^2 \dots\dots\dots (11)$$

この式は実際の出力 $y(t)$ とモデルからの予測値 $\hat{y}(t)$ の差の自乗平均が最小となるような重みを求めることを意味する。ここで θ は重みを表し、 Z は入出力 $u(t), y(t)$ を表す。




Fig. 3. NNARX モデル

3. モデル予測制御

〈3・1〉 モデル予測制御の概念 制御対象の数学モデルが存在すれば、そのモデルに基づいて未来の出力の変化を予測でき、出力と目標値が一致するような操作量が求められる。モデル予測制御は各サンプリング間にモデルから未来の出力を予測し、最適な操作量を求め、それを制御対象に入力する制御のことをいう。最適な操作量を求めるための評価基準として、つぎの評価関数が与えられる。

$$J = \sum_{i=N_1}^{N_2} [r(t+i) - \hat{y}(t+i)]^2 + \rho \sum_{i=1}^{N_u} [\Delta u(t+i-1)]^2 \dots\dots\dots (12)$$

ここで出力を予測する区間 N_1, N_2 をそれぞれ最小予測区間、最大予測区間といい、操作量の決定区間 N_u を制御区間と呼ぶ。また $\Delta u(t+i-1)$ は操作量の増分、 ρ は操作量の増分に対する重み係数を表す。(2) 式は N_1 から N_2 までの未来の出力 $\hat{y}(t+i)$ と目標値 $r(t+i)$ との差の二乗和と、現在から N_u までの操作量の増分の二乗和が最小となるような現在の操作量 $u(t)$ を求めることを意味する。ここで、モデル予測制御の実際の手順について説明する。

- (1) 過去の入力と出力より未来の出力 $\hat{y}(t+1), \dots, \hat{y}(t+N_2)$ を予測する。
- (2) N_u 回操作量を変化させることで、 N_2 ステップで、出力の予測値が目標値にできるだけ近づくように現在の操作量 $u(t)$ を決定する。
- (3) 決定した操作量により次ステップでの出力 $y(t+1)$ が得られる。ここで出力 $y(t+1)$ は時刻 t で予測した $\hat{y}(t+1)$ とモデルの不完全さや外乱によって異なる場合がある。そこで現時刻を $t+1$ とみなし、1~3 を繰り返す。

本システムは Fig.4 に示すように、同定によって得られた NNARX モデルを各サンプリング間で線形化し、得られた線形モデルのパラメータを用いて、一般化予測制御 (GPC:Generalized Predictive Control) を行っている。

〈3・2〉 線形化 まずはじめに線形化について説明する。NNARX モデルは (8) 式で表される。また、回帰ベクトルは (3) 式で与えられる。時刻 $t = \tau$ で、現在の回帰




Fig. 4. 本システムのブロック図




Fig. 5. 2層タンクシステム

ベクトル $\varphi(\tau)$ の近傍で (8) 式を線形化することで, (13) 式が得られる.

$$\begin{aligned} \tilde{y}(t) = & -a_1\tilde{y}(t-1) - \dots - a_n\tilde{y}(t-n_a) \\ & + b_0\tilde{u}(t-1) + \dots + b_{n_b}\tilde{u}(t-n_b) \dots \dots (13) \end{aligned}$$

ただし,

$$\begin{aligned} a_i = & - \left. \frac{\partial y(t)}{\partial y(t-i)} \right|_{\varphi(t)=\varphi(\tau)} \\ b_i = & \left. \frac{\partial y(t)}{\partial u(t-i)} \right|_{\varphi(t)=\varphi(\tau)} \dots \dots \dots (14) \end{aligned}$$

また,

$$\begin{aligned} \tilde{y}(t-i) = & y(t-i) - y(\tau-i) \\ \tilde{u}(t-i) = & u(t-i) - u(\tau-i) \dots \dots \dots (15) \end{aligned}$$

である. ここで $\varphi_i(t)$ についての出力 $y(t)$ の偏微分は

$$\begin{aligned} \frac{\partial y(t)}{\partial \varphi_i(t)} = & \sum_{j=1}^N W_j w_{jk} \\ & \times \left(1 - \tanh^2 \left[\sum_{k=1}^{n_a+n_b} w_{jk} \varphi_k(t) + w_{j0} \right] \right) \dots \dots (16) \end{aligned}$$

で与えられる. また (13) 式から現在の回帰ベクトル $\varphi(\tau)$ を含む項を切り離すと線形化モデルは

$$A(q^{-1})y(t) = B(q^{-1})u(t-1) + \zeta(\tau) \quad (17)$$

となる. ただし, バイアス項 $\zeta(\tau)$ は

$$\begin{aligned} \zeta(\tau) = & y(\tau) + a_1y(\tau-1) + \dots + a_{n_a}y(\tau-n_a) \\ & - b_0u(\tau-1) - \dots - b_{n_b}u(\tau-n_b) (18) \end{aligned}$$

で, 多項式 $A(q^{-1}), B(q^{-1})$ は

$$A(q^{-1}) = 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \dots \dots (19)$$

$$B(q^{-1}) = b_0 + b_1q^{-1} + \dots + b_{n_b}q^{-n_b} \dots \dots (20)$$

である.

4. 同定結果

Fig.5 に示すような, 2層タンクシステムを制御対象とする.

システム同定を行うに先立ち, 制御対象の入出力データ




Fig. 6. 入出力データ (上:入力データ, 下:出力データ)

の測定を行った. 入力信号には白色雑音をもとに式 (21) の信号を設定した. 白色雑音はすべての周波数成分を含んでいるので同定用の信号に適しているが, 制御対象がプロセス系なので入力に対して反応に時間がかかってしまう. 積極的に周波数が変わる白色雑音の一瞬だけの入力では, 反応が悪くなるために一つ前の入力信号を確率 α で保持した. 入力信号を式 (21) で設定したのはこのような理由からである. 今回は $\alpha = 0.5$ とした.

$$u(t) = \begin{cases} \text{確率 } \alpha & \text{で } u(t-1) \\ \text{確率 } 1-\alpha & \text{で } e(t) : \text{白色雑音} \end{cases} \quad (21)$$

サンプリング時間 3 [s], データ点数 2000 点, 入力バルブの開放度の範囲を 40 ~ 90 [%] としシステムの入出力データを測定した. 得られた入出力データより NNARX モデルを用いて 2層タンクシステムの同定を行った.

5. 入出力データの測定

2層タンクシステムより得られた入出力データを Fig. 6 に示す.

得られた入出力データの後半 1000 点を用いて制御対象のモデルを構築し, 前半 1000 点を用いて構築したモデルの妥当性を検証する. このように前半を検証用に, 後半を構築用に用いた理由は, システム同定をする際に入出力データの定常性が仮定できないような部分が存在する場合は, その部分を取り除いたほうが賢明とされているからである. 今回は, 構築用と検証用どちらもデータ点数が 1000 点確保できるように前半と後半を入れ替えた.

〈5・1〉 NNARX モデルによる同定 NNARX モデルを用い, 回帰ベクトルを $u_1(t-1), u_1(t-2), u_2(t-1), u_2(t-2), y_1(t-1), y_1(t-2), y_2(t-1), y_2(t-2)$ の 8 つとし, 中間層の数は 3 つとして 2層タンクシステムの




Fig. 7. NNARX モデルの妥当性の検証




Fig. 8. NNARX モデルの相関関数

同定を行った。推定されたモデルは以下のようになった。

$$W_1 = \begin{bmatrix} 0.052 & -0.019 & 0.000 & 0.001 & -0.000 \\ 0.009 & -0.003 & 0.000 & 0.000 & 0.000 \\ 7.650 & 9.422 & 0.017 & -11.33 & 1.131 \\ -0.002 & -0.048 & 0.015 & -0.394 & \\ 0.000 & 0.008 & -0.002 & 0.011 & \\ 6.572 & 7.766 & 4.372 & -3.649 & \end{bmatrix} \cdot (22)$$

$$W_2 = \begin{bmatrix} 14.50 & 92.56 & -0.0258 & 4.341 \\ -14.91 & 90.47 & 0.0175 & -6.588 \end{bmatrix} (23)$$

また、このモデルから予測される出力と実際の出力とを比較した。その結果を Fig.7 に示す。

さらに、誤差の自己相関関数、誤差と入力との相互相関関数を Fig.8 に示す。

Fig.7 より、実際の出力と予測値はほぼ重なっており、予測誤差がほとんどないことが分かる。2つのグラフの縦軸を比べてみると、誤差は出力の $\frac{1}{10}$ 程度と小さいことが見てわかる。Fig.8 の上図より、 y_1 、 y_2 の誤差の自己相関関数はラグが0で1の値をとるが、それ以外は信頼区間に収まり、デルタ関数の形になるので誤差に周期性が無い(不確定信号である)ことがわかる。Fig.8 の中図と下図より相互相関関数は、ほとんどが信頼区間に収まっていることが確認できるが、負のラグで信頼区間から外れているところが見られる。これは出力フィードバックがかかるときに出現することがあるのだが、このシステムは階層型ニューラルネットワークであり、フィードバックはかかっていないのでこの理由は不適合である。他に考えられる原因として、入出力データの測定の際に入力信号の白色雑音をバルブの反応を理由に、確率 α で保持したがためにそうなったのではないかと考えられる。しかし、これは信頼区間から外れていてもごく小さく、他は信頼区間に収まっていることを確

認できるので、同定できていると判断し、このモデルを採用した。同定精度の評価として、誤差の二乗平均は 0.1559 と非常に小さいので同定精度は良いといえる。

6. 制御実験

〈6・1〉 **タイムスケジュール** 制御実験を行うにあたって比較・観察しやすいように、Fig.9 に示すタイムスケジュールを組んだ。

Fig.9 より、まずタンク1の目標値を変更させて、タンク1側の目標値追従特性を測定する。その後、タンク1の目標値を元に戻し、定常状態となつてからタンク2の目標値を変更させて、タンク2側の目標値追従特性を測定する。その後、タンク2の目標値を元に戻す。

次にタンク1の外乱バルブを開き、タンク1側の外乱抑制特性を測定する。その後外乱バルブを閉じ、定常状態となつてから、タンク2の外乱バルブを開き、タンク2側の外乱抑制特性を測定する。

sample 500 → 1500… 目標値追従特性(タンク1)
sample 2000 → 3000… 目標値追従特性(タンク2)
sample 3500 → 4200… 外乱抑制特性(タンク1)
sample 4700 → 5400… 外乱抑制特性(タンク2)

以上のように進めた。上記の sample でそれぞれ切り出し、経過を比較する。

〈6・2〉 **液面制御** システム同定によって得られた NNARX モデルを用いて2層タンクシステムの制御を行った。今回の実験では、前に述べた最適な操作量を決めるための評価関数(12)式の操作量の増分に対する重み係数 ρ を変化させた。

重み係数は $\rho = \begin{bmatrix} 5 & a \\ a & 5 \end{bmatrix}$ という形である。 $a = 0.001 \rightarrow 0.01 \rightarrow 0.1 \rightarrow 1$ と変化させて実験を行った。

目標値追従特性は目標値を 30 [%] → 50 [%] に変更した。外乱抑制特性では、外乱バルブの開放度はどちらも 50 [%] とした。また、図9を見て明らかのように、片方のタンクの水位の変化に、もう一方のタンクが影響されてしまう干渉が見られた。今回は干渉をなるべく抑え、制御実験に差し支えないよう2つのタンクを結ぶ管(Fig.5 参照)のバルブ開放度を 50 [%] とした。

最小予測区間 $N_1 = 1$ 、最大予測区間 $N_2 = 2$ とし、制御区間 N_u に関しては、コンピュータへの負担を減らすために最小が望ましく、本研究では $N_u = 1$ として制御実験を行った。

7. 実験結果

〈7・1〉 **目標値追従特性** $a = 0.001 \rightarrow 0.01 \rightarrow 0.1 \rightarrow 1$ と変化させたときのタンク1側の目標値追従特性を Fig.10、Fig.11 に示す。上図より干渉の度合い、立ち上がり時間、整定時間を調べた。結果を表1に示す。




Fig. 9. タイムスケジュール




Fig. 10. 目標値追従特性(タンク1) $a=0.001$




Fig. 12. 外乱抑制特性(タンク1) $a=0.001$




Fig. 11. 目標値追従特性(タンク1) $a=1$




Fig. 13. 外乱抑制特性(タンク1) $a=1$

Table 1. 目標値追従特性(タンク1)

	出力 y_2 の最大値 [%]	立ち上がり時間 [s]	整定時間 [s]	
			y_1	y_2
$a = 0.001$	40.545	78	852	1170
$a = 0.01$	39.826	87	627	1005
$a = 0.1$	40.374	78	894	1029
$a = 1$	39.061	81	702	972

Table 2. 外乱抑制特性(タンク1)



	出力の最大値 [%]		目標値復帰時間 [s]	
	y_1	y_2	y_1	y_2
$a = 0.001$	44.932	37.355	252	192
$a = 0.01$	44.083	37.018	252	192
$a = 0.1$	42.441	36.565	246	207
$a = 1$	43.964	37.129	258	216

〈7・2〉 外乱抑制特性 $a = 0.001 \rightarrow 0.01 \rightarrow 0.1 \rightarrow 1$ と変化させたときのタンク1側の外乱抑制特性を Fig.12, Fig.13に示す。上図より出力の最大値, 目標値復帰時間を調べた。結果を Table2に示す。

〈7・3〉 考察 今回の研究では, (12) 式の操作量の増分に対する重み係数 ρ を変化させて実験を行った。実

験結果より a の値を大きくすると, 目標値追従特性では速応性, 収束性が良くなる。また, a の値を大きくすると外乱抑制特性では, 速応性はわずかに損なわれるものの, 偏差が少なくなることがわかった。よってこのシステムは比較的目標値追従特性に強いシステムではないかと考えられる。

今回の実験により以上のような結果を得られたのは, 重

Fig. 14. 目標値追従特性 (タンク 1) $a=10$ Fig. 15. 外乱抑制特性 (タンク 2) $a=10$

み係数 ρ の各成分の役割にあると考えた。11 成分はタンク 1 に対するバルブ 1 の重み, 12 成分はタンク 1 に対するバルブ 2 の重み, 21 成分はタンク 2 に対するバルブ 1 の重み, 22 成分はタンク 2 に対するバルブ 2 の重みを表していると考えた。この考えを踏まえて $a = 10$ として, どのような結果が得られるか実験を行った。結果を以下に示す。

Fig.14 より, タンク 1 の目標値追従特性なのにも関わらず, バルブ 2 の開放度が大きくなっている。これはバルブ 2 がタンク 1 の液面を目標値に合わせようとして, このような動作をしたと考えられる。やがて水位は上昇し, 水が溢れそうになったためバルブを手動で閉めた。最後の水位の減少はそれによるものである。Fig.15 より, タンク 2 に外乱を入れる前の定常状態にする時点で水位の発散が見られた。

今回の研究では, 重み係数 ρ のそれぞれの成分を同じ値に設定して実験を行ったが, この考えを元に重み係数 ρ の各成分を異なる値に設定して実験を行えば, 干渉や各特性の動作の改善が期待できる。

8. 結 論

2 層タンクシステムから入出力データを測定し, そのデータからニューラルネットワークを用いてシステム同定を行

うことができた。システム同定から構築されたモデルの妥当性を検証し, 実際に 2 層タンクシステムの制御を行うことができた。システム同定の際に, 入出力データのモデル構築用に過渡応答の部分が含まれているとき, 含まれていないときの誤差の状態や同定精度がどのように変化するかを確認できた。

実験を繰り返して気がついたことが, タンク 1 とタンク 2 は同じ水量であることをモニターしているにもかかわらず, 2 つのタンクを目視して比較してみると, 明らかに水量に差が見られるということがあった。このような差が存在しても, 制御特性は劣化してはならないと考えた。

2 層タンクシステムの制御を行い, すべての結果において干渉が見られた。これを解消することに関しては, まだ策が見つかっておらず今後の課題の 1 つである。

今回は行えなかった回帰ベクトルの数と中間層の数を変更させて得られたモデルを用いて, 実験を行うことで干渉と各特性の動作を改善するの一つの手かもしれない。

参考文献

- [1] M.Norgaard et al., "Neural Networks for Modelling and Control of Dynamic Systems", Springer, (2000)
- [2] 足立修一, "MATLAB による制御のためのシステム同定", 東京電機大学出版局, (1997)
- [3] 菅井講介, "ニューラルネットワークを用いたモデル予測制御", 小山工業高等専門学校平成 18 年度卒業論文, (2007)
- [4] 石井大介, "ニューラルネットを用いたプロセス系の制御", 小山工業高等専門学校平成 22 年度卒業論文, (2010)

【受理年月日 2012年 9月28日】