

論文

ニューラルネットワークによる倒立振り子制御における PID ゲインのセルフチューニング†

森田 譲*・前田 保憲*・日隈 崇文*

本論文では、ニューラルネットワークを利用し、倒立振り子制御における PID ゲインのセルフチューニングを行い、評価関数の最小となる PID ゲインが存在することを明らかにした。実システムの制御対象として無駄時間を含む 1 重倒立振り子を考える。この制御系は 1 入力 2 出力系を構成し、台車、倒立振り子および角度補償器と位置補償器を含めた系を伝達関数で表し、これに時系列処理を行いニューラルネットワークで同定する。このニューロエミュレータは PID ゲインをチューニングする際に必要なシステムヤコビアンを計算するとき用いる。つぎに実システムモデルに対して、別のニューラルネットワークを用いて、倒立しているが不安定な PID ゲインの初期値からセルフチューニングを開始する。この結果チューニングで得られた PID ゲインを用いて実験を行い、測定された振り子の角度および台車の位置の情報とも整定時間が短くなり、かつシミュレーション結果とよく一致することを示した。

キーワード：ニューラルネットワーク、セルフチューニング、PID 制御、倒立振り子

1 はじめに

PID 制御における比例、積分、および微分の各ゲインは経験的に求められることが多く、その最適値も試行錯誤的に決められている[1]。このため PID ゲインを自動的に求めるセルフチューニング PID 制御系の設計についての研究が行われてきた[2]、[3]。ニューラルネットワーク (以下 NN と略記する) を利用して時系列処理を行い、セルフチューニングを行う研究は文献[4]～[6]で報告されているが、いずれもシミュレーション結果が述べられている。

本論文では、実システムの制御対象として無駄時間を含む 1 重倒立振り子を考える。この倒立振り子に対して、古典制御理論を用いて得られた解析結果を用い[7]、そこで得られた伝達関数より入出力値を求め、台車、倒立振り子および補償部を含めたプラント部に対して時系列処理を行いニューロエミュレータを構築し、PID ゲインをチューニングする際に必要なシステムヤコビアンを求める。次に実システムモデルに対して、NN を用いセルフチューニングを行う。チューニングで得られた PID ゲインを用いて実機での実験を行い、シミュレーション結果と比較する。

NN における時系列処理は大きな研究課題の一つであり、フィードバック結合を含む再帰型 NN を時系列

処理に適用した例が報告されている[8]。また自己フィードバックをもつ複素ニューロンを用いて、時系列処理について検討がなされているが[9]、ここでは最も一般的なパーセプトロンモデルを用い時系列処理を行い、バックプロパゲーション則でシステム同定および PID ゲインチューニングを行っている。ここでは文献[6]で用いている手法を発展させ、1 入力 2 出力の制御系を構成する実システムの倒立振り子制御に適用し、評価関数の最小となる PID ゲインパラメータの存在を明らかにし、実験結果と比較検討する。

2 プラントのシステム同定

2.1 制御システム

倒立の近傍において、振り子の振れ角 θ が十分小さいとすると、 $\sin\theta \approx \theta$ 、 $\cos\theta \approx 1$ なる線形近似をおこない、さらに振り子の質量が台車の質量に比べて十分小さいと仮定すると、図 1 のようなブロック線図で表すことができる (付録参照)。ここでは、PID コントロール部と台車、倒立振り子、および角度補償器と位置補償器をまとめてプラントとした 2 つのブロックで表している。各ブロックは伝達関数で表現される。プラントの応答信号として、振り子の角度の情報と台車の位置の情報が




図 1 制御系のブロック線図

† Self-Tuning of PID Gains by Neural Networks for an Inverted Pendulum Control System
Yuzuru MORITA, Yasunori MAEDA and Takafumi HINOKUMA

* 佐賀大学文化教育学部

Faculty of Culture and Education, Saga University




図2 学習用指令パルス

出力される。位置指令信号 $r(t)$ に対して、角度に関する情報 $\theta_t(t)$ はネガティブフィードバックされ、位置に関する情報 $x_t(t)$ はポジティブフィードバックされる。角度と位置の情報ともに、補償器からの出力値をとっているのが通常の単位と異なり電圧で表している。これは制御対象であるプラントに対する NN の学習過程を単純化することになる。また $\theta_t(t)$ および $x_t(t)$ は 2.2 で述べるニューロエミュレータを構成する際の教師信号として使われる。位置指令、角度および位置の情報の偏差 $e(t)$ が PID コントローラに入り、その出力を $u(t)$ とする。

プラントを NN で同定するための指令信号 $r(t)$ として、図 2 のようなパルス信号を用いる。振幅は ± 1 [V] に変化させ、倒立振り子の対称性を学習できるようにした。ここでは、3. で行うチューニングの場合のコントローラと異なり、次の伝達関数を持つ PID コントローラを考える。

$$P \frac{1+Ds}{1+T_Ns} \frac{1+Is}{Is} \quad (1)$$

ここで、 P は比例ゲイン、 D は微分時定数、 T_N はノイズカット時定数、 I は積分時定数であり、 $P=0.5$ 、 $D=0.082$ [s]、 $T_N=0.02$ [s]、 $I=0.033$ [s] なる値を用いた。この縦続型 PID コントローラはオペアンプを用いたアナログ回路で容易に実現できること、 P ゲインの調節だけで制御性能を改善できること、および高周波ノイズをカットできるという特徴がある。図 1 において、PID コントローラおよびプラントの伝達関数を差分方程式になおし、サンプリング時間 1 [ms] で離散化し、時系列処理を行う。

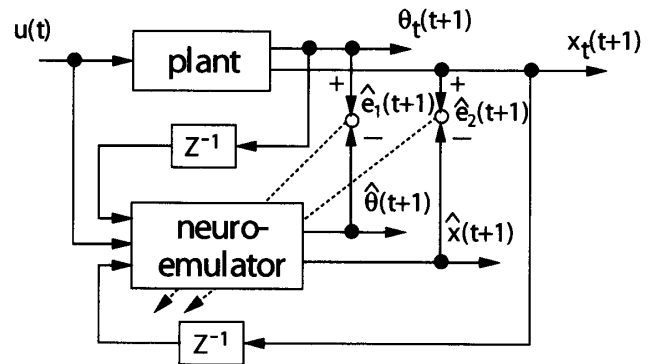


図3 ニューロエミュレータの構成

2.2 ニューロエミュレータ

図 3 にプラントを同定するニューロエミュレータの構成を示している。学習を行う NN として 3 層構造のパーセプトロンモデルを用いる。

図 3 に示すように、入力層は 3 ユニットとし、中間層を 20、30、40、50 ユニットにとり、学習効果について検討した。出力層は角度と位置に対応して 2 ユニットとする。入力層は線形の入出力関数を持ち、中間層は制御対象がプラス・マイナスの値をとることから、奇関数的要素を持つ

$$f_1(x) = \tanh(x/2)$$

なる関数を用いる [10]。出力層は出力関数がすべて実数値をとることから、次の関数を用いる。

$$f_2(x) = x \quad (3)$$

図 3 において、ニューロエミュレータからの出力をそれぞれ $\hat{\theta}(t+1)$ 、 $\hat{x}(t+1)$ とし、プラントからの教師信号を $\theta_t(t+1)$ 、 $x_t(t+1)$ とすると、その推定誤差 e_k ($k=1, 2$) は次式で与えられる。

$$\left. \begin{aligned} e_1(t+1) &= \theta_t(t+1) - \hat{\theta}(t+1) \\ e_2(t+1) &= x_t(t+1) - \hat{x}(t+1) \end{aligned} \right\} \quad (4)$$

このとき平均自乗誤差を表す評価関数は次式となる。

$$E(t+1) = \frac{1}{2} \sum_{k=1}^2 e_k(t+1)^2 \quad (5)$$

NN の学習はバックプロパゲーション則により行い、(5) 式で与えられる評価関数を最小化するものとする。

2.3 ニューラルネットワーク

いま入力層 (i 層)、中間層 (j 層)、出力層 (k 層) の NN について考える。入力層の i 番目のユニットの出力信号を $O_i(t)$ とすると中間層の j 番目のユニットの

内部状態 $I_j(t)$ は次式で与えられる。

$$I_j(t) = \sum_i W_{ji}(t) O_i(t) \quad (6)$$

ここで、 W_{ji} は入力層 i 番目ユニットと中間層 j 番目ユニットとの結合係数である重みを表す。同様に、添え字 j を k に、添え字 i を j に変えることにより中間層と出力層の間にも (6) 式と同じ関係が成り立つ。

(5) 式で与えられる評価関数の時刻 t での内部状態に関する導関数は、(3) 式を用いると次式のようにになる。

$$\begin{aligned} \delta_k(t) &= -\frac{\partial E(t)}{\partial I_k(t)} = -\frac{\partial E(t)}{\partial \hat{e}_k(t)} \frac{\partial \hat{e}_k(t)}{\partial \hat{y}_k(t)} \frac{\partial \hat{y}_k(t)}{\partial I_k(t)} \\ &= \hat{e}_k(t) f'_2(I_k(t)) = \hat{e}_k(t) \end{aligned} \quad (7)$$

ここで、 $\hat{y}_k(t)$ は $k=1$ のときは $\hat{\theta}(t)$ を、 $k=2$ のときは $\hat{x}(t)$ を表す。出力層での重みの修正量は学習係数を η とすると、次式で計算することができる。

$$\begin{aligned} \Delta W_{kj}(t) &= -\eta \frac{\partial E(t)}{\partial W_{kj}(t)} = -\eta \frac{\partial E(t)}{\partial I_k(t)} \frac{\partial I_k(t)}{\partial W_{kj}(t)} \\ &= \eta \delta_k(t) O_j(t) \end{aligned} \quad (8)$$

次に、中間層での重みの修正量を計算するために、中間層での内部状態に関する導関数を求める。

$$\begin{aligned} \delta_j(t) &= -\frac{\partial E(t)}{\partial I_j(t)} = -\sum_k \frac{\partial E(t)}{\partial I_k(t)} \frac{\partial I_k(t)}{\partial O_j(t)} \frac{\partial O_j(t)}{\partial I_j(t)} \\ &= \sum_k \delta_k(t) W_{kj}(t) f'_1(I_j(t)) \\ &= \frac{1}{2} \sum_k \delta_k(t) W_{kj}(t) \{1 - O_j^2(t)\} \end{aligned} \quad (9)$$

従って、中間層での重みの修正量は $\Delta W_{ji}(t)$ は次式となる。

$$\begin{aligned} \Delta W_{ji}(t) &= -\eta \frac{\partial E(t)}{\partial W_{ji}(t)} = -\eta \frac{\partial E(t)}{\partial I_j(t)} \frac{\partial I_j(t)}{\partial W_{ji}(t)} \\ &= \eta \delta_j(t) O_i(t) \end{aligned} \quad (10)$$

ここで、慣性項係数を α とすると、重みの修正量は次式となる。

$$\Delta W_{pq}(t) = \eta \delta_p(t) O_q(t) + \alpha \Delta W_{pq}(t-1) \quad (11)$$

ここで、 $\Delta W_{pq}(t-1)$ は 1 時刻前の重みの修正量、 $(p, q) = (k, j), (j, i)$ である。3 で行うセルフチューニングの際にプラントのシステムヤコビアンが必要となる。システムヤコビアンは求め方としてはプラントの入力に摂動を与え、その出力変動分から計算されていた。

その後、システムヤコビアンが解析的に計算する手法が提案された [11]。ここでもそれと同じ手法で計算することにする。制御入力 $u(t)$ が入力されるニューロンを i_1 とすると、システムヤコビアンは次式で計算される。

$$\frac{\partial \hat{y}_k(t+1)}{\partial u(t)} = \frac{1}{2} \sum_j W_{kj} (1 - O_j^2) W_{ji} \quad (12)$$

2.4 システム同定

図 2 で示される指令信号を用いて NN の学習を行う。中間層の数を 20、30、40、50 と変えたとき、(5) 式で与えられる評価関数の収束の様子を図 4 に示している。ここで 1 万個のデータを学習するのを 1 エポックとしている。サンプリング時間を 1 [ms] にとっているので 10 秒間のデータを学習していることになる。500 エポックまでは収束が悪いが、それを越えると急激に収束している様子が分かる。また中間層の数を増やすほど収束が良くなっている。中間層の数が 20 の場合を除いて、いずれも 3000 エポック以上学習すると一定値に収束している。中間層の数が 50 のとき、3000 エポック学習すると誤差が 3 程度となる。1 万個のデータでの学習であるから 1 個あたりの誤差は 0.0003 であるから十分な学習が行われたと考えることができる。中間層の数が 40 と 50 の場合を比較した場合、学習時間に大差がなく、かつ 50 のときのほうが誤差が少ないので、ここでは中間層の数が 50 で 4000 エポック学習したときの結果をシステム同定とした。このとき使用した学習係数は 0.0008 で、慣性項係数は 0.0006 である。NN の学習結果を確認するために、パルス指令の振幅を 1.2 [V] とし、パルス幅を 5 秒に変えたときのエミュレータの出力結果をプラントの出力信号である教師信号と比較して、図 5 と図 6 に示している。図 5 は角度の時間応答であり、図 6 は位置の時間応答である。いずれも 10 秒間のデー




図 4 プラントの学習曲線




図5 角度の時間応答

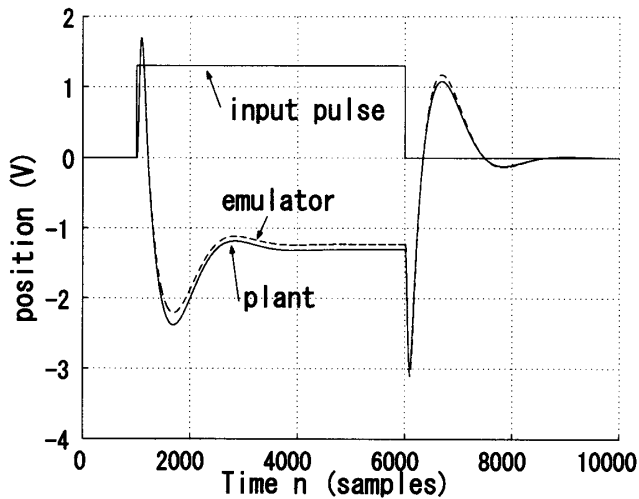


図6 位置の時間応答

タである。パルス振幅が1.2[V]と大きくなったにも関わらず良い結果となっている。また無駄時間（付録参照）は14.5[ms]と小さな値であり、この10秒間のデータの中ではその影響は小さいと考えられる。

3 セルフチューニングシステム

3.1 PID コントローラ

図7にPID制御パラメータをセルフチューニングする構成図を示している。同定の際に用いたコントローラと異なり、(13)式で与えられるPIDコントローラのパラメータをチューニングする。これは(16)式で与えられるこのPIDコントローラの出カパラメータとネットワーク出力層のニューロンとの対応が容易であるためである。

$$u(t) = k \left\{ e(t) + \frac{1}{T_i} \int_0^t e(\tau) d\tau + T_d \frac{de(t)}{dt} \right\} \quad (13)$$

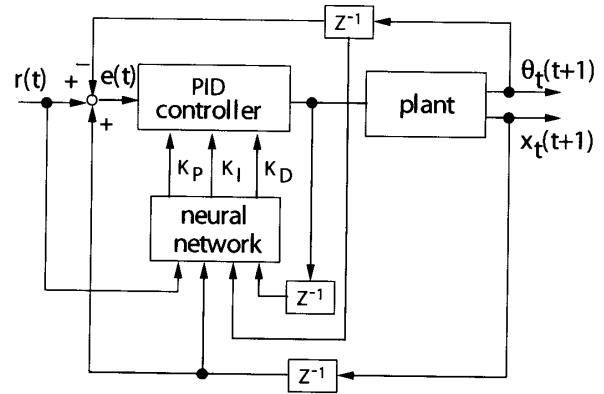


図7 セルフチューニングシステム

ここで、 k は比例ゲイン、 T_i は積分時間、 T_d は微分時間である。また、 $e(t)$ は次式で与えられる。

$$e(t) = r(t) - \theta_t(t) + x_t(t) \quad (14)$$

(13)式で与えられるPID演算式をデジタルコントローラで演算する場合、サンプリング時間ごとのデータを用いることになる。このため(13)式をサンプリング時間 T で離散化する。ここで、

$$K_P = k, \quad K_I = k \frac{T}{T_i}, \quad K_D = k \frac{T_d}{T} \quad (15)$$

とおくと、離散時間速度形PIDコントローラが得られる。

$$u(t) = u(t-1) + K_P \{ e(t) - e(t-1) \} + K_I e(t) + K_D \{ e(t) - 2e(t-1) + e(t-2) \} \quad (16)$$

プラントのところは、図3と同じ構成にして、システムヤコビアンを計算する。

3.2 セルフチューニング用 NN

図7に示すように、システム同定を行ったときと同じ3層構造 (i' 層、 j' 層、 k' 層)のNNを考える。入力層は4ユニットとし、各ユニットには指令信号と角度、位置の情報、およびPIDコントローラからの出力値が入力される。中間層のユニット数は30とし、その出力関数として、システム同定を行ったNNの場合と異なり、次式で与えられるシグモイド関数を用いる。

$$f_s(x) = \frac{1}{1 + e^{-x}} \quad (17)$$

出力層 (k' 層)は3ユニットにとる。各ユニットの出力は K_P 、 K_I 、 K_D に対応しており、文献[6]で述べられているように非負の実数値をとることから、(17)式を積分した次の関数を用いる。

$$f_4(x) = \ln(1 + e^x) \quad (18)$$

ここでも2.2で述べたように、(14)式で与えられる偏差入力 u の自乗誤差である評価関数を最小にするようにチューニングを行う。この評価関数の内部状態に関する導関数は次式で与えられる。

$$\begin{aligned} \delta_{k'}(t+1) &= -\frac{\partial E}{\partial I_{k'}} = -\sum_{k=1}^2 \frac{\partial E}{\partial \hat{y}_k} \frac{\partial \hat{y}_k}{\partial u} \frac{\partial u}{\partial O_{k'}} \frac{\partial O_{k'}}{\partial I_{k'}} \\ &= e(t+1) \sum_{k=1}^2 \frac{\partial \hat{y}_k}{\partial u} \frac{\partial u}{\partial O_{k'}} f_3(I_{k'}(t+1)) \end{aligned} \quad (19)$$

ここで、 $\partial \hat{y}_k / \partial u$ は(12)式で与えられるシステムヤコビアンであり、 $\partial u / \partial O_{k'}$ はNNの出力 $O_{k'}$ に関する制御入力 $u(t)$ の勾配であり、(16)式より次式となる。

$$\frac{\partial u(t)}{\partial O_{k'}} = \begin{cases} e(t) - e(t-1) & ; k'=1 \\ e(t) & ; k'=2 \\ e(t) - 2e(t-1) + e(t-2) & ; k'=3 \end{cases} \quad (20)$$

出力層、および中間層での結合荷重の修正量は2.3と同じ方法で計算できる。この計算では学習係数を0.01、慣性項係数を0.006としている。

3.3 セルフチューニング

チューニングに用いた指令信号は、振幅1.2[V]、パルス幅4秒の矩形パルスである。図8に比例、積分および微分のPIDゲインをセルフチューニングした場合の評価関数の値を示している。倒立振子は非常に不安定な制御系であり、任意の初期値からのチューニングでは発散したり、極小値に収束したり困難が予想される[12]。そこで、MatlabのSimulinkを用いて図1のモデルを作成し、振子が倒立するPIDパラメータを縦続型PIDの(1)式の値を参考にして求めた。これらの中




図8 セルフチューニング曲線

から、倒立可能であるが最適でないことを実験で確認した次の値を初期値とし、チューニングを開始する。ここでは初期値として、A: (K_P, K_I, K_D) = (0.4, 9.0, 0.005)、B: (0.9, 6.0, 0.01)、C: (0.7, 11.0, 0.05)の3通りの場合について計算した。Aの場合108エポック、Bの場合は157エポック、Cの場合200エポックで評価関数が最小となっており、この最小となる点をチューニング値とする。表1には各初期値に対してチューニングされたPIDゲインの値を示している。

表1 チューニングされたPIDゲイン

	K_P	K_I	K_D
A	0.797	15.20	0.000835
B	0.865	15.75	0.000933
C	0.930	16.43	0.000991




図9 セルフチューニング曲線: K_P




図10 セルフチューニング曲線: K_I



図11 セルフチューニング曲線： K_D 

図12 比例ゲインの時間変化




図13 積分ゲインの時間変化

B 場合の比例、積分、微分の各PIDゲインのチューニングの際の変化の様子を図9、図10、図11に示している。図12および図13には、Aの場合でチューニングさ


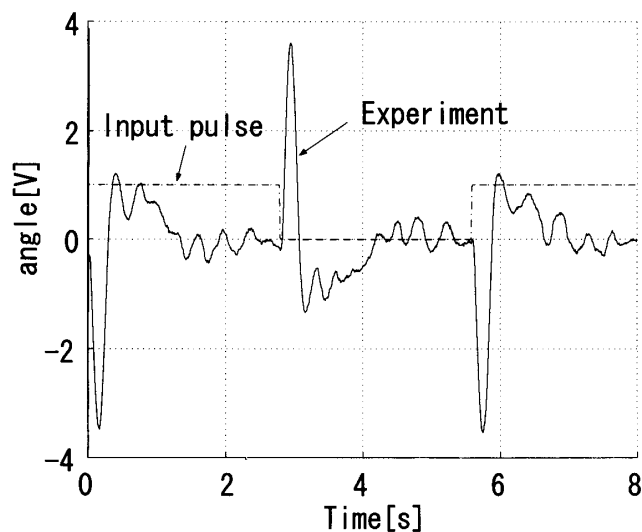


図14 角度に対する実験値(上)とシミュレーション結果(下)との比較

れた点での比例ゲイン K_P と K_I の時間変化を示している。パルスの立ち上がり、立ち下がりのところで値が急激に変化しているが、値の大きさはあまり変化していないことがわかる。図14と図15の下図にはチューニング前とチューニング後のPIDゲインを用いた角度と位置の時間応答を示している。これらの図からもチューニングがなされていることを確認することができる。

4 実験結果

振子の台車を移動させる駆動機構として、摩擦の非常に小さなX-Yレコーダを使用した。記録ペンのところに角度測定用ポテンショメータを取り付け、その上部に長さ75[cm]、一辺1.3[cm]の角柱を装着し、Y軸を固定しX方向のみ可動させる。このとき台車の可動範囲は38[cm]である。X-Yレコーダは既製品であり、駆動機構が不明であり、また測定が困難である。したがって、ボード線図から得られた伝達関数をもとにX




図15 位置に対する実験値 (上) とシミュレーション結果 (下) との比較

-Y レコーダをモデル化した (付録参照)。位置の情報は X-Y レコーダ内部のポテンショメータの出力信号を用いた。信号発生器からの振幅 1 [V] の矩形パルスと、角度および位置のポテンショメータ出力がパーソナルコンピュータに取り込まれ、コンピュータで処理された制御信号が X-Y レコーダの X 端子に印加される。このとき使われた PID パラメータはチューニングされた表 1 の B の場合の値を使用した。各ゲインは図 12、図 13 で示された値と同様に時間的に大きな変化はないので、一定とした値を用いた。図 14 と図 15 の上図に角度と位置の時間応答の測定値を指令パルスとともに示している。図 14 と図 15 の下図は Matlab の Simulink を用いたシミュレーション結果である。破線はチューニング前の応答信号であり、実線はチューニングされた値での応答を示している。チューニング後には整定時間が 1.5 秒程度に改善されていることがわかる。また信号発生器からの急峻なパルスのため、その立ち上がりたち下がりでは、図ではサンプリングされているため

に表示されていないが、スパイク上の電圧が存在するために、実験データでは立ち上がりたち下がりでの振幅がシミュレーション値より大きくでている。また他の部分では急峻なパルスが印加されるために実験値に細かな機械振動が発生しているが、実験結果とシミュレーション結果はよく一致していることがわかる。

5 むすび

この論文では、角度補償器と位置補償器をもつ 1 入力 2 出力の制御系を構成する実システムの倒立振子に対し、時系列処理を行いニューロエミュレータを構築した。これを用いて任意の初期値をもつ離散時間速度型 PID パラメータのセルフチューニングを行い、評価関数の最小となるチューニング点の存在を明らかにした。このとき初期値としては不安定であるが倒立可能な任意の PID ゲインをもちいた。つぎにチューニングされた PID ゲインを用いて実験を行い、振子の角度および台車の位置の時間応答が改善され、かつシミュレーション結果とよい一致を示した。

ここで用いた一連の手順をオンラインで実現することなどについて、今後検討していく予定である。

本研究にあたり、ご指導いただいた神谷嘉則 元佐賀大学教授に感謝いたします。

参考文献

- [1] 須田信英：PID 制御，朝倉書店 (1992)
- [2] Y. Nishikawa, N. Sannomiya, T. Ohta, & H. Tanaka : A Method for Auto-Tuning of PID Control; *Automatica*, Vol. 20, No. 3, p.321 (1984).
- [3] 山本透・大松繁：セルフチューニング PID 制御系の一設計；計測自動制御学会論，Vol. 25, No. 10, pp.1069-1075 (1989).
- [4] 岩佐健司・森住昇・大松繁・服部洋文：セルフチューニング PID 制御による塩素生成プラントの圧力制御；電学論 C, Vol. 114, No. 11, pp.1060-1066 (1994).
- [5] 岩佐健司・森住昇・大松繁・服部洋文：ニューラルネットワークによる電解層内圧力の安定化制御；電学論 C, Vol. 115, No. 11, pp.1224-1231 (1995).
- [6] 青山武郎・大松繁：ニューラルネットワークによるセルフチューニング PID 制御系の設計；電学論 C, Vol. 116, No. 11, pp.1197-1201 (1996).
- [7] 神谷嘉則・西村洋信・佐藤真也：倒立振子の制御 (教材研究)；日本産業技術教育学会第 39 回全国大会講演要旨集, No. 427, p.115 (1996).
- [8] 西正明・降矢順司・中村維男：ディレー素子内包型バックプロパゲーションニューラルネットワーク (BPD) の一構成；信学論 (D-II), Vol. J78-D-II, No. 10, pp.1522-1530 (1995).
- [9] 木ノ内誠・萩原将文：複素ニューロンによる時系列の学習；電学論 C, Vol. 116, No. 7, pp.748-754 (1996).

- [10] 馬目聡・荒 實・鈴木穎二：ニューラルネットワークによる倒立振り制御；平成7年電気学会全国大会講演予稿集，663，pp.3-214/3-215 (1996)。
- [11] 山口智・板倉秀清：ニューラルネットワークによる順モデルを用いた冗長マニピュレータの逆キネマティクス問題の解法；電学論C，Vol. 116，No. 3，pp.367-373 (1996)。
- [12] 馬場則夫・小島史男・小澤誠一：ニューラルネットの基礎と応用；共立出版，pp.17-25 (1994)。
(2003年4月15日 受付)
(2004年1月27日 採録)

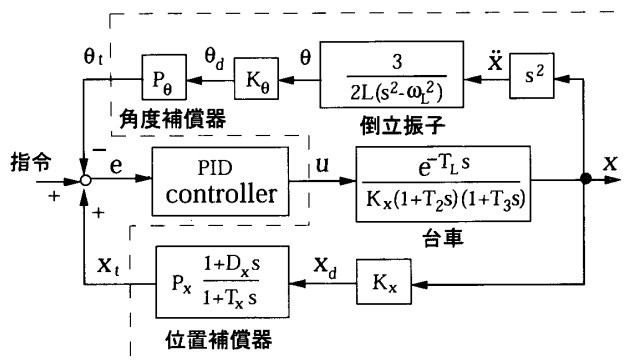


図 A1：倒立振り制御系のブロック線図

付録 A

倒立振り安定化制御において、振子が重力 g によって倒れようとするとき、振子が倒れようとする方向に台車を動かす。X-Y レコーダの中央で振子を倒立させるため、台車を積極的に外側に動かし振子の傾きを中央に向ける必要がある。よって、位置情報をポジティブフィードバックし、さらに性能を高めるために比例微分補償を用いている。また振り角度は比例補償しネガティブフィードバックする(図 A1 参照)。図 A1 において、点線で囲んだ部分をプラント部とし、PID コントローラ部との二つのブロックで表現したのが図1である。各パラメータの値は次のようになる。


台車の伝達関数は $e^{-T_L s} / \{ (K_x) (1+T_2s) (1+T_3s) \}$ で与えられる。ここで、 K_x は X-Y レコーダの X 軸感度で $0.5[V/cm]$ 、 T_L は無駄時間で $14.5[ms]$ 、 T_2 、 T_3 は一次遅れ時定数で、それぞれ $133[ms]$ 、 $22.1[ms]$ である。倒立振り部と角度補償部の伝達関数は $P_\theta K_\theta (3/2L)$

* $s^2 / (s^2 - \omega_L^2)$ となる。ここで、 P_θ は角度補償比例ゲインで $P_\theta = 22$ とした。 K_θ は角度ポテンショメータの感度で、 $5.75[V/rad]$ である。 L は振子の長さで $0.75[m]$ 、 ω_L は振子の角速度で $4.46[rad/s]$ である。位置補償部の伝達関数は $P_x K_x (1+D_x s) / (1+T_x s)$ で与えられる。ここで、 P_x 、 D_x 、 T_x はそれぞれ位置補償の比例ゲイン、微分時定数およびノイズカット時定数である。各値はそれぞれ、 $P_x = 1.0$ 、 $D_x = 677[ms]$ 、 $T_x = 226[ms]$ にとる。

[問い合わせ]

森田 譲
〒840-8502 佐賀市本庄町1
佐賀大学文化教育学部
TEL：0952-28-8371
FAX：0952-28-8219
E-mail：moritay@cc.saga-u.ac.jp

著者略歴



もりた じゅん
森田 譲 [正会員]

1968年 九州工業大学大学院工学研究科修士課程修了、同年 佐賀大学理工学部助手、1985年 同講師、1987年 同教育学部助教授、1992年 同教授、1996年 文化教育学部教授となり現在に至る。工学博士。プラズマ中の電子プラズマ波の励振に関する研究を行った後、ファジィ制御、ニューラルネットワークに関する研究に従事。電気学会、計測自動制御学会、システム制御情報学会、日本産業技術教育学会などの会員。



まえだ やしり
前田 保憲 [非会員]

1998年 佐賀大学大学院教育学研究科修士課程修了、現在熊本市立京陵中学校教諭。在学中はニューラルネットワークに関する研究に従事。



ひのくま たかふみ
日隈 崇文 [非会員]

2000年 佐賀大学大学院教育学研究科修士課程修了、現在山鹿市立山鹿中学校教諭。在学中はニューラルネットワークに関する研究に従事。

Self-Tuning of PID Gains by Neural Networks for an Inverted Pendulum Control System

by

Yuzuru MORITA, Yasunori MAEDA and Takafumi HINOKUMA

Abstract :

This paper presents a self-tuning system of PID gain parameters for an inverted pendulum control system using three-layer neural networks. The inverted pendulum system which has one input and two output system is expressed as the plant by the transfer functions, which are used to identify the plant with a neural network based on the back-propagation for temporal sequences and then the system Jacobian of the plant is derived. The system Jacobian of the plant is used in the self-tuning process of the PID controller. The PID parameters are determined so as to minimize the error function, in which another three-layer neural network is used in the tuning process. Experimental results of the angle of the pendulum and the position of the cart which are controlled by the tuned parameters are compared with simulation results. It is shown that they are good agreement.

keywords : neural networks, self-tuning, PID control, inverted pendulum

Contact Address : **Yuzuru MORITA**

Faculty of Culture and Education, Saga University; 1 Honjyo-machi, Saga city, Saga 850-8502, Japan

TEL : 0952-28-8371

FAX : 0952-28-8219

E-mail : moritay@cc.saga-u.ac.jp