

ニューラルネットによる塑性加工のための 温度制御のインテリジェント手法の開発

大阪府立大学 工学部 情報工学科

教授 大松 繁

(平成6年度研究開発助成 AF-94023)

キーワード：ニューラルネットワーク、温度制御、インテリジェント制御

1. 研究の目的と背景

本研究ではニューラルネットワークの特徴である並列・分散・学習の機能を活用し、遺伝的アルゴリズムによるネットワークの進化機能を付加した学習制御系を構成する。また、それらの制御系の設計計算の高速化を図るために、ニューラルネットワークによる学習制御系を設計し、シミュレーションによって提案手法の有効性の考察を行う。さらに、その結果に基づいて、本研究で構成した制御系を実際のプロセス制御の温度制御へ適用することによって、その有効性を実験的に検証する。以上のように、ニューラルネットワークと遺伝的アルゴリズムを基礎としたインテリジェント制御系の設計と実際のプロセス制御問題への適用による提案手法の有用性に関する検討を行い、塑性加工のための精度良い温度制御系を設計することが研究の目的である。

2. 研究方法

本研究は、遺伝的アルゴリズムとニューラルネットワークを併用することによる進化と学習の機能を有するPIDコントローラの設計とその実験的検証を行い、インテリジェントコントローラの設計とその温度制御への応用をとおして、高度自動化の推進に貢献しようとするもので、以下のような研究方法を行った。

2.1 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

PIDコントローラは、図1に示すように、比例(P)、積分(I)、微分(D)の3つの調整パラメータを有する制御系である。PID制御系の設計

に関しては、従来の制御手法と異なり、制御対象の数学モデルが必要でなく、比例(P)、積分(I)、微分(D)動作を適当に調整して、望ましい制御系を設計する手法である。

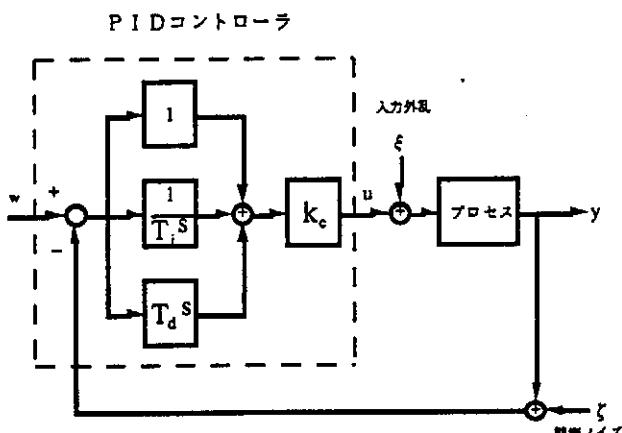


図1 PID制御系

このPIDゲインは、制御対象に関する経験や知識およびマニュアル値などに基づいて、現場のオペレータが調節している。オペレーターの知識や経験によるPIDゲインの調整をニューラルネットワークで行なうのが、ニユーロPID制御系の設計である。熟練したオペレーターと比較して、ニユーロPID制御は突発事故のような急激な環境変化に対して適切な動作を行なうことを期待できないが、平常時には十分な調整機能を有していることが示されている³⁾⁻⁶⁾。以下では、本研究で提案したニユーロPID制御系の設計法について述べる。

2.1.1 ニューロPID制御系の設計法

図1のような連続時間PID制御系を、ディジタル計算機で処理できるように離散時間形式で表現す

ると、操作量 $u(t)$ は

$$u(t) = u(t-1) + K_p(e(t) - e(t-1)) + K_I e(t) + K_D(e(t) - 2e(t-1) + e(t-2)) \quad (1)$$

となる³⁾。ただし、T はサンプリング間隔を示し、 K_p, K_I, K_D は次式で与えられる離散時間表現による P I D ゲインである。

$$K_p = k_c - K_I, K_I = k_c \frac{T}{T_i}, K_D = k_c \frac{T_d}{T}$$

K_p, K_I, K_D をニューラルネットワークで調整するために、オペレータの代わりにニューラルネットワークを用いると、図 2 のような制御系となる。すなわち、ニュートラルネットワークの出力は、 K_p, K_I, K_D であり、その P I D ゲインを用いた制御対象の制御量 $y(t+1)$ を目標値 $r(t+1)$ と比較する。ニューロ P I D コントローラは、誤差 $e(t+1)$ の平方を最小にするように K_p, K_I, K_D を調節する、すなわち、ニューラルネットワークの結合係数を調整する制御系設計法である。ニューラルネットワークは図 6 に示す 3 層の階層型ニューラルネットワークとする。このとき、ニューロ P I D 制御は

$$E = \frac{1}{2} e(t+1)^2, \quad e(t) = r(t) - y(t) \quad (2)$$

で定義される E を最小にするように、入力層のニューロン i から中間層のニューロン j への結合係数 W_{ji} および中間層のニューロン j から出力層のニューロン k への結合係数 w_{kj} を調節する。勾配法によると、結合係数 w_{kj} の更新規則 Δw_{kj} は次式となる³⁾。

$$\Delta w_{kj}(t+1) = \eta \delta_j O_j + \alpha \Delta w_{kj}(t) \quad (3)$$

$$\delta_j = e(t+1) \frac{\partial y(t+1)}{\partial u(t)} \frac{\partial f(\text{net}_k)}{\partial \text{net}_k} J_k \quad (4)$$

$$J_k = \frac{\partial u(t)}{\partial O_k(i)} \quad (5)$$

ここで、 η は正数で学習係数、 α は 0 以上 1 未満の実数で慣性係数、 $f(\cdot)$ はシグモイド関数

$f(x) = \frac{1}{1+e^{-x}}$ で与えられるニューロンの出力関数である。また、 net_k はニューロン k への入力の総和、 $\frac{\partial y(t+1)}{\partial u(t)}$ はシステムヤコビアンを示している。

K_p, K_I, K_D は、それぞれ、 $O_k(i), i=1,2,3$ で与え

られる。このとき、(9) 式から J_k は次式となる³⁾

$$J_1 = e(t) - e(t-1), J_2 = e(t), \quad (13)$$

$$J_3 = e(t)(-2e(t-1) + e(t-2)) \quad (14)$$

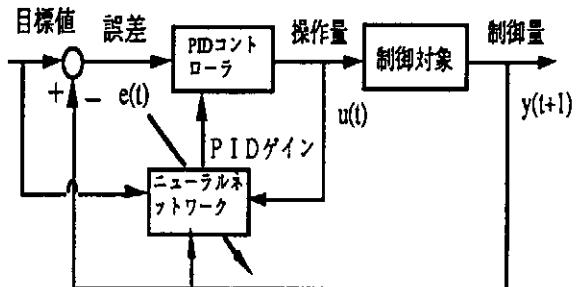


図 2 ニューロ P I D 制御系

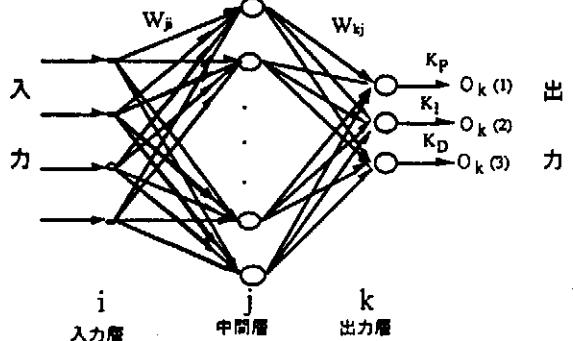


図 3 階層型ニューラルネットワ

さらに、 Δw_{ji} に関しても同様な関係式を得られ、次式が成立する³⁾。

$$\Delta w_{ji}(t+1) = \eta \delta_i O_i + \alpha \Delta w_{ji}(t) \quad (6)$$

$$\delta_i = \sum_k \delta_k w_{kj} O_j (1 - O_j) \quad (7)$$

したがって、(3)-(7)式を解くことによって、P I D ゲインの調整が自動的に行なわれる。しかし、(3)-(7)式を解くためには、(4)式に含まれているシステムヤコビアンを求めることが必要である。これに対するいくつかの方法が提案されているが、基本的には、入力の振動による直接的な計算法とシステムエミュレータを用いた計算法がある。前者に対しては、操作量 $u(t)$ に関する操作量 $y(t+1)$ の微係数の符号 ($u(t)$ の係数の符号) のみ分かれば、(11)式で η の大きさを調節することによって、P I D ゲインをチューニングすることができる。また、後者の場合には、制御対象をニューラルネットワークでモデル化したエミュレータを作成し、そのエミュレータの結合係数を用いて、以下のような近似計算でシステムヤコビ

アンを求めることができる⁴⁾。

$$\frac{\partial y(t+1)}{\partial u(t)} \approx \frac{\partial \hat{y}(t+1)}{\partial u(t)} = \sum_{j=1}^3 w_{kj} O_j (1 - O_j) w_{ji}$$

ここに、 w_{kj} はエミュレータにおける中間層のニューロン j から出力層のニューロン k への結合係数、 w_{ji} はエミュレータにおける操作量 $u(t)$ から中間層のニューロン j への結合係数を示す。

図4は、第2の方法を用いた場合のセルフチューニングPID型ニューロコントローラのブロック図である。図4で、NN2はエミュレータを、NN1はセルフチューニングPIDコントローラを示している。以下では、エミュレータの作成法について述べる。最も簡単な構成法は、図5に示すように、ニューロエミレータの出力が制御量に近くなるように、ニューラルネットワークを学習する方法である。この方法は、ニューラルネットワークにプラトンの入出力特性を実現させようとするものであり、制御対象の入出力特性が複雑な場合には、ニューラルネットワークの学習に長時間を要することが多い。そこで、制御量を予測するのに要する学習時間を短縮化するために、ニューラルネットワークの入力として、操作量の現在値のほかに、操作量および歴史値の過去の値を用いる方法がある。ただし、 p と q は、それぞれ、操作量と制御量の遅れ次数を示している。

この場合、 p と q の概略値が既知であるならば、それらの値を p と q の初期値として設定し、ニューラルネットワークが収束するように、少しずつ変更するのが得策である。これらの値が未知の場合には、 p と q の値をかなり大きく選ぶことが必要である。このとき、ニューラルネットワークの規模が増大し、局所最小解へニューラルネットがトラップされたり、学習に長時間を要することが多い。図5と異なったエミュレータの構成法として、図6の方法がある。これは、数学モデルによって制御対象の主要な動特性を表現し、数学モデルで表現できない部分を、ニューラルネットワークで補正しようとする方法である。図6の数学モデルとしては、時系列モデル、線形モデル、非線形モデルなどが用いられる。実在の制御対象は、未知パラメーターを含む非線形システム

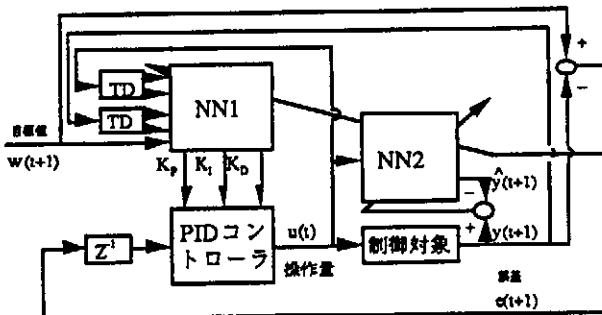


図4 ニューロPIDコントローラの
ブロック図

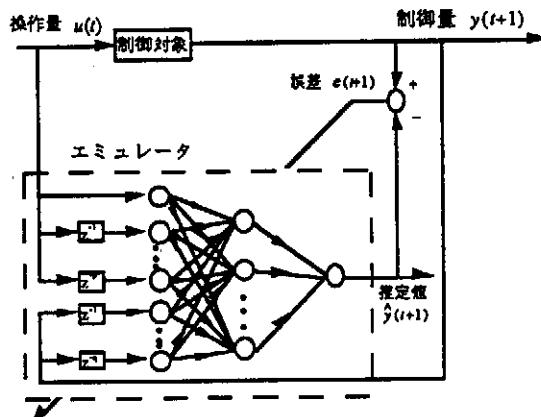


図5 エミュレータの構成法

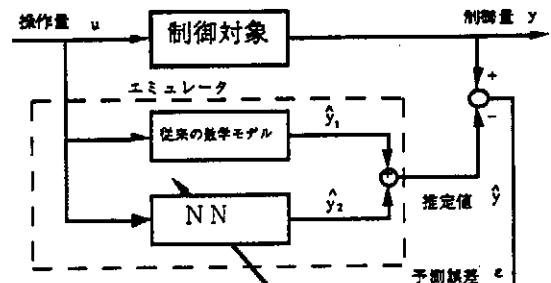


図6 数式モデル併用エミュレータ

ムであり、正確な数学モデルを決定することが困難な場合が多い。したがって、制御対象の大雑把な動特性を与える数学モデルを仮定し、この数学モデルで予測できない部分をニューラルネットワークで補正するのが、図6の数学モデル併用によるエミュレータの構成法である。

3. ニューロPIDの温度制御への応用

本研究では、プロセス制御系を考察の対象とするために、制御方式としてはPIDコントローラを探用し、PIDゲインのセルフチューニング法の提案

とその改良を行った。高速で汎化能力の大きいニューラルネットワークを用いたセルフチューニングPIDコントローラの設計とその応用に関して、申請者はすでに幾つかの方式を提案してきたが、本研究ではニューラルネットワークが有している並列・分散・学習の機能のなかで並列・分散の機能を活用した知的制御系の設計を行い、さらに遺伝的アルゴリズムによる進化機能を付加した学習制御系を構成した。具体的には、これまでに構成してきたニューローネットワークの学習の高速化と制御系に含まれる種々のアルゴリズムの並列処理化を行い、汎化能力を向上させるための分散表現を試み、実際の温度制御系における温度制御実験を行った。

本研究で開発したニューローネットワークPIDコントローラを、実際のプロセス制御、とくに、恒温槽および加熱炉の温度制御および塩素生成プラントの圧力制御問題へ適用し、その有効性について実験的な検討を行った。その結果、恒温槽の温度制御制御に関しては、図7のような装置で実験を行った。

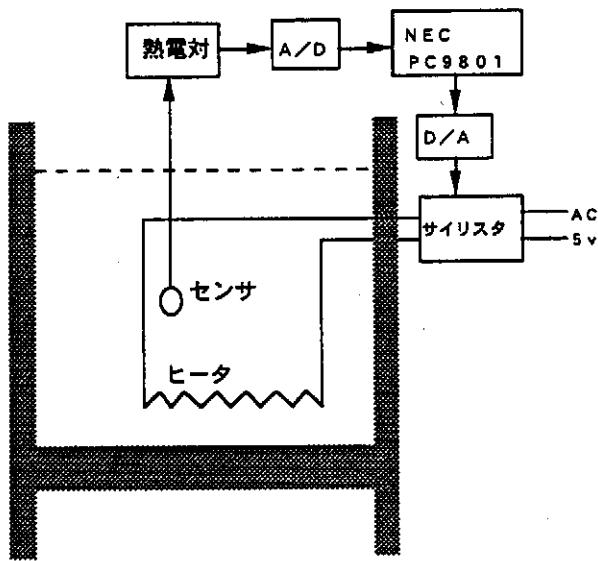
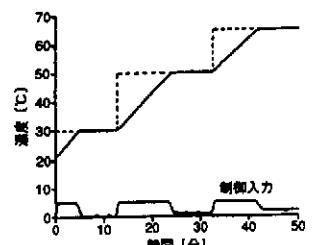


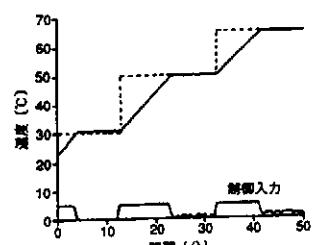
図7 恒温槽温度制御装置の概要

この実験によると、図8に示すように、提案手法が様々な制御手法よりも、優れによる制御結果を示すことが明らかにされた。ただし、比較手法としては、セルフチューニング制御法、従来の Ziegler-Nichols 法による PID 制御法について考察した。

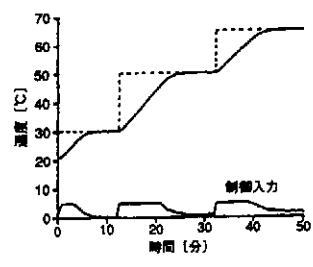
これに対する実験結果を図10に示す。この実験結果からも、提案手法の有効性が実験的に検証された。



(a)



(b)



(c)

図8 恒温槽温度制御実験結果：(a) 提案手法 (b) セルフチューニング制御法 (c) Z-NPID 制御法

つぎに、図9に示すような加熱炉の温度制御系について考察した。これは、プラスチック射出成型器用の温度制御システムである。

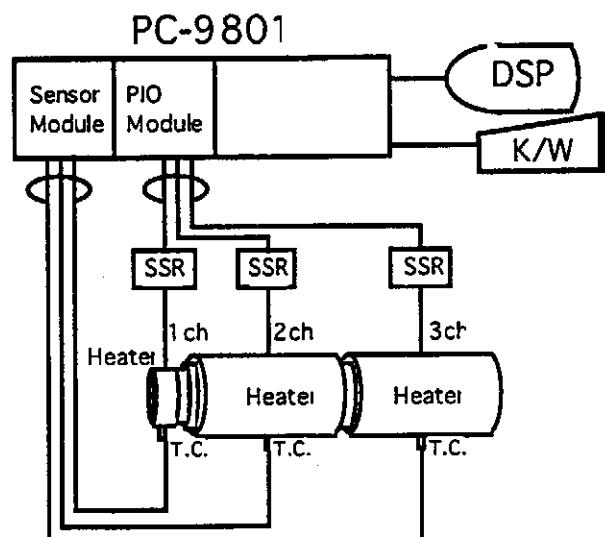


図9 加熱炉の温度制御系

図9の場合に対する温度制御結果を図10に示す。

図10(a)は提案手法の結果であり、同(b), (c)は、それぞれ、セルフチューニング制御法およびZ-N手法による結果である。これらの結果から提案手法の優位性が分かる。

4. 結論

ニューラルネットワークを用いたPIDゲインのチューニングと実際の制御系に適用した。ニューラルネットワークは、線形システムのみならず非線形システムに対しても、ほぼ同様な方法で制御系の設計が行なわれ、未知の環境にもある程度適応可能である。とくに、非線形要素を数多く含むプロセス制御への応用では、制御中に制御対象のパラメータ変動を生じることがある。この場合、ロバスト制御によって、パラメータ変動に伴う悪影響を減少させることも考えられるが、制御性能の劣化を免れない。しかし、ニューロPID制御では、常時エミュレータの更新を行なっており、そのエミュレータを用いてPIDゲインの調整を行なっている。したがって、プロセス制御におけるパラメータ変動に対しても、オペレータによる制御結果と同等であるか、それよりも良好な制御結果を得ることができる⁶⁾。文献6)ではバッチプロセスの温度制御に対して、ここで述べた手法を適用し、その有効性を実験的に検証している。しかし、ニューラルネットワーク学習の高速化およびニューラルネットワークの構造などに関しては、専門家の経験と勘が重要であり、これらの情報なくしては、優れたニューロPID制御系の設計は困難であろう。

謝辞

申請者は、研究途中で勤務先を代わることになり、研究費の不足で大変苦労していた折に、本研究を遂行することが出来たのも、天田金属加工機械技術財団から多額の研究助成金を頂いたためであり、ここに同財団に深く感謝する次第である。

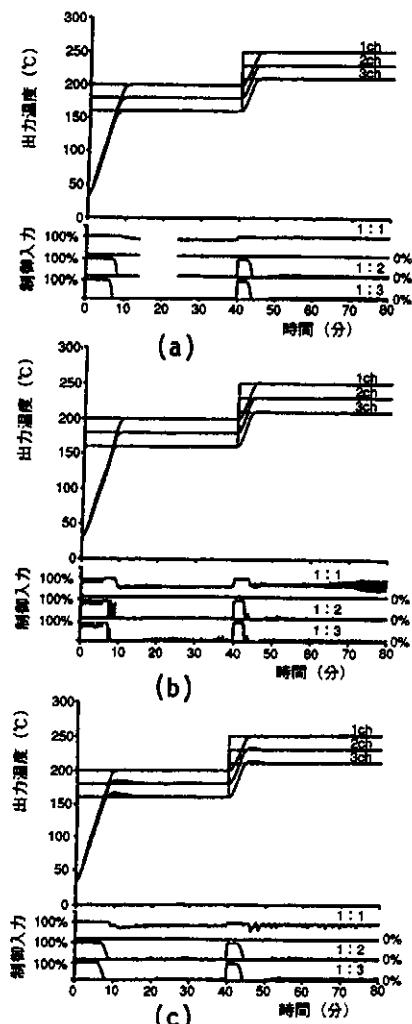


図10 加熱炉の温度制御実験結果：(a) 提案手法
(b) セルフチューニング制御法 (c) Z-NPID 制御法

参考文献

- 1) 須田信英：PID制御則について；システム／制御／情報、Vol.42, No.1, pp.2-6, 1998.
- 2) 北森俊行：I-PD制御方式の原理と設計法；システム／制御／情報、Vol.42, No.1, pp.7-17, 1998.
- 3) S. Omatsu, K. Marzuki, and Y. Rubiyah : Neuro-Control and Its Applications ; Springer, 1996.
- 4) 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；電気学会論文誌C分冊、Vol.116C, No.11, pp.1197-1201, 1997.
- 5) 松村茂憲、大松繁、桶笠博正：PID型ニューロコントローラによる電気自動車実験装置のトルク制御；電気学会論文誌C分冊、Vol.113C, No.10, pp.841 -848, 1993.
- 6) 岩佐健司、森住界、大松繁、服部洋文：ニューラルネットワークによる電解槽内圧力の安定化制御；電気学会論文誌C分冊、Vol.115C, No.11, pp.1224-1231, 1995.