流動床式ごみ焼却炉のニューロ制御*

木 通 秀 樹^{*1,*2}, 波 入 裕 司^{*1}, 吉 田 和 夫^{*3}

Application of Neurocontrol to Fluidized Bed Incinerators

Hideki KIDOHSHI, Yuuji NAMIIRI and Kazuo YOSHIDA

Fluidized bed incinerators can burn waste in a short time by stirring waste and fluidized sands. However, recently refuse shows various temperament and high calorie output. Changes in quality and quantity of waste cause fluctuations in combustion, and burning in fluidized bed incinerators is sometimes incomplete when much waste is supplied at one time. Furthermore, since these combustion systems are nonlinear and multi-variable, it is difficult to form mathematical models and to control them through an ordinary control algorithm. Therefore we adopted a neural network controller which can express characters as nonlinear and multi-variable. The proposed neural network controller learns so as to reduce disturbances, such as changes of waste type, adaptively in a stability area, together with controlling by an ordinary controller. We call this neural network control system RANC (robust adaptive neurocontroller). The method was applied to a real plant. The manipulated variable is amount of secondary air to the freeboard and the controlled variable is the concentration of O_2 . O_2 is used as an index of stable combustion. The usefulness was verified since this method was able to reduce the fluctuation of O_2 concentration and CO concentration.

Key Words: Neural Network, Neurocontroller, Fluidized Bed Incinerator, Disturbance, Adaptive, Nonlinearity

1. ま え が き

流動床式ごみ焼却炉は、投入されたごみと流動砂とのかくはんにより、短時間に乾燥・熱分解を行なうことができるという特徴を利用して、近年増加するごみに対して効果を発揮している⁽¹⁾。

しかし、最近の都市ごみは性状が多様化し、高カロリー化する傾向があり、炉に供給されるごみは質・量共に変動しやすくなっている。そのため、流動床炉では燃焼が早い半面、ごみ供給量や質の変化がそのまま燃焼の変動につながって、不完全燃焼を起こしやすくなるという問題が生じる。さらに、流動床炉は非線形多変数システムであるため、従来技術のみで低公害化を行なうことは、難しくなっている⁽²⁾⁽³⁾。

そこで、非線形多変数特性と学習性を持つニューラルネットワーク（以下ニューロ）によって制御を行なう方法について検討した。これまでは、ニューロを用いた制御は学習に多くの時間を要し、収束に対する信頼性がないことから、適応制御のようにオンラインで学習することが難しかった。また、ごみ変動のような持続的外乱を積極的に打

ち消す方法についても、十分には検討されていなかった。

本研究ではこのような問題に対応するために、ごみ変動のような外乱に対して効果を発揮するニューロコントローラについて検討した。そして、排ガス酸素濃度の変化が小さくなるように、二次空気量制御を行なった結果、炉内の燃焼状態がより安定になることを実機試験において確認したので報告する。

2. 流動床式ごみ焼却炉の概要

2.1 焼却炉システムの概要 流動床式ごみ焼却炉の概念図を図1に示す。

ごみ燃焼過程は、大きく分けて一次燃焼と二次燃焼に分けることができる。一次燃焼はごみ投入から乾燥・熱分解によるガス化を起す過程で、主に炉床表面で起る。炉床部では砂中の散気管から押し込まれる一次空気によって、熱せられた砂が流動し、ごみはこの砂に囲まれることによって燃焼する。さらに、このごみの発熱によって砂の温度を保持する構造になっている。この過程で、ごみの多くはガス化されてCO、CO₂等になる。この際、完全燃焼せずに残ったCOをフリーボード部で燃焼する過程が二次燃焼である。二次燃焼はフリーボード部に空気を送ることによって行われ、COのみならずNO_xやSO_x、ダイオキシンの低減を目的とする。

* 原稿受付 1994年10月17日。

*¹ 石川島播磨重工業(株) (〒135 東京都江東区豊洲3-1-15)。*² 慶應義塾大学大学院 (〒223 横浜市港北区日吉3-14-1)。*³ 正員、慶應義塾大学理工学部。

図1 流動床式ごみ焼却炉の概念図

2.2 二次空気制御系概要 二次空気とは二次燃焼に用いるための燃焼用空気で、フリーボード部に供給する。

安定な燃焼の指標としては炉出口酸素濃度を用いる。それは、酸素濃度が少ない場合は不完全燃焼しやすく、COが発生しやすくなり、酸素濃度が高いとNO_xが発生しやすくなるという傾向をもつためである。

そこで、従来はこの酸素濃度が一定になるように、PIコントローラで二次空気のフィードバック制御を行なうと同時に、炉内圧の変動をごみの変動と捕えて、炉内圧が移動平均値にオフセットを乗せた値よりも大きくなった場合に補助的な空気量を出すようにしてきた。

2.3 システムのモデル化 ごみ投入から、炉出口酸素濃度が検出されるまでのプロセスモデルを図2に示す。

ΔW	熱分解有機物量	(g)
Q	熱分解ガス量	(m ³)
V	二次空気量	(m ³ /h)
T	温度	(K)
Z	炉内圧	(mmAg)
Y	炉出口酸素濃度	(%)
F	混合度	(-)
P	ガス化率	(m ³ /g)
T_a, T_i	時定数	(sec)
τ	むだ時間	(sec)

f_1, f_2 は下図3, 4に示す非線形特性を持つ⁽¹⁾⁽⁵⁾。

$\nu_1, \eta_1, \eta_2, \eta_3, \lambda_1, \lambda_2, \beta$ はそれぞれ工学値への換算係数を示す。

図2 システムのモデル図

図3 温度による有機物のガス化率の変化

図4 二次空気流入速度と炉内ガス混合度の関係

図5 RANCの構造

3. RANC (Robust Adaptive Neuro Controller)

3.1 RANCの構造と概要 RANCは、流動床式ごみ焼却炉のような、外乱の影響を大きく受けるプラント制御において、オンライン学習を行う実用的ニューロコントローラである。

適用するニューロコントローラの構造を図5に示す。通常はPID等のフィードバックコントローラで制御され、その間にニューロコントローラを学習することによって徐々に補正していく。これにより、フィードバックコントローラだけでは実現できない性能の向上を行う。一般に、この場合のニューロコントローラは、目標値とプラント出力の差を用いただけでは、良好な学習ができないことが多い。この対策として、フィードバック誤差学習法⁽⁴⁾などのような工夫が行われてきたが、十分な性能は得られていなかった。

そこでRANCでは、良好な学習が行えるように、フォワードモデルを用いて、ニューロコントローラ学習用の誤差信号を生成し、これを用いてニューロコントローラを学習するようにした。基本的にはフィードバック誤差学習法と順逆モデル法^{(6)~(10)}を組み合わせたものになる。

3.2 設計手順 本節では各部の概略と設計手順について示す。

3.2.1 従来のフィードバックコントローラの設計 基本的に要求される性能は、系を安定化することなので、制御対象を線形近似したモデルを用いて、状態フィードバックコントローラを設計してもよいし、PIDコントローラでもよい。しかし、オンラインでフォワードモデルの学習を行うので、フィードバックコントローラ出力と、他の計測データとの相関が十分小さくなるようにし、フォワードモデルの学習が適切に行えるようにしなければならない。

3.2.2 フォワードモデルの学習 順逆モデルの手順と同様、本手法においても、まず初めにこのフォワードモデルの学習を行う。

ニューロコントローラを学習するためには、プラント入出力間の感度（ヤコビアン）を求めなければならない。こ

図6 フォワードモデルの学習

の感度は3層の階層構造を持つニューロフォワードモデル内の誤差逆伝搬法（BackPropagation）によって求めることができる。フォワードモデルの構造と学習方法を図6に示す。ここで、操作量を u 、計測値を x とし、 o を各ニューロンの出力、 z を各ニューロンの内部状態、重みを w （添え字は h が入力層ニューロン、 i は中間層ニューロン、 j が出力層ニューロンの各番号を示す）とする。ここで、内部状態は入力ニューロン数を H とすると次式で表される。

$$z_i = \sum_{h=1}^{H-1} w_{hi} \cdot o_h + w_{Hi} \dots \dots \dots (1)$$

まず、このフォワードモデルに、プラント入出力の関係を図6のように誤差逆伝搬法を用いて学習させる。

ここで、入力状態量を使っても、出力の自己回帰であっても良いが、自己回帰の場合は m は n より十分大きくなければならない。図中の破線は、 $(k-1)$ 時点でのフォワードモデル出力と、現在 (k) 時点の状態量との誤差を用いて重みを更新することを示す。

制御対象特性の複雑さにもよるが、通常は対象がフィードバック制御されている状態で学習を行う。この時の評価関数は式（2）で表わされる。

$$E = \frac{1}{2} \sum_{j=0}^n \left\{ \left(\frac{d^j x}{dt^j} \right)_k - (o_j)_{k-1} \right\}^2 \dots \dots \dots (2)$$

また、式（2）の評価関数を用いて毎サンプル学習を行って、十分な収束が得られない場合は、式（3）のように時間積分値を用いる。

$$E = \sum_{i=1}^L \left[\frac{1}{2} \sum_{j=0}^n \left\{ \left(\frac{d^j x}{dt^j} \right)_{k-i+1} - (o_j)_{k-i} \right\}^2 \right] \dots \dots \dots (3)$$

ここで、 L は積分時間のサンプル数を示す。

3.2.3 ニューロコントローラの学習 フォワードモデルが十分精度良くプラント出力を近似できるようになったら、ニューロコントローラの学習を行う。

まず初めに、図7[1]のようにフォワードモデルの計算を行う。この計算を行うことで、フォワードモデルの中間層ニューロンのしきい値特性に、感度の非線形性が設定される。具体的にはこの非線形性は、しきい値関数 g を式

(4) のようなシグモイド関数に設定すると、その微分である式 (5) として表される。 a は正の定数とする。

$$o_i = g(z_i) = \frac{2}{1 + e^{-az_i}} - 1 \quad \dots\dots\dots (4)$$

$$g'(z_i) = \partial\{g(z_i)\} / \partial z_i \quad \dots\dots\dots (5)$$

フォワードモデル出力は、実際のプラント出力と区別するために、図中の記号で表している。これは、持続的外乱が存在する場合、フォワードモデルは実際のプラント出力を精度良く推定していないからである。

次に、ニューロコントローラ学習の評価関数を式 (6) のように設定し、図 7 [2] のようにフォワードモデルに対して誤差信号を設定する。このようにしてニューロコントローラ学習用の誤差信号を生成する。

$$V = \frac{1}{2} \left\{ \left(\frac{d^n r}{dt^n} - \frac{d^n x}{dt^n} \right)^2 + \dots + (r - x)^2 \right\} \quad \dots\dots\dots (6)$$

感度 $\partial(d^j x / dt^j) / \partial u$ は、操作量入力から $\widetilde{d^j x / dt^j}$ 出力までの経路について、次式のように誤差逆伝搬法を行うことによって得られる。

$$\begin{aligned} \frac{\partial \left(\frac{d^j x}{dt^j} \right)}{\partial u} &= \frac{\partial o_i}{\partial z_i} \sum_j \left(\frac{\partial z_i}{\partial o_i} \frac{\partial o_i}{\partial z_i} \frac{\partial z_i}{\partial u} \right) \\ &= \sum_i (w_{ij} \cdot g'(z_i) \cdot w_{ji}) \quad \dots\dots\dots (7) \end{aligned}$$

ここで、しきい値関数は式 (4) で与えられているので式 (7) は式 (8) のようになる。

$$\frac{\partial \left(\frac{d^j x}{dt^j} \right)}{\partial u} = \sum_i \left(w_{ij} \cdot \frac{(1 - o_i^2)}{4a} \cdot w_{ji} \right) \quad \dots\dots\dots (8)$$

ニューロコントローラの教師となるべき値と、現在のニューロコントローラの出力の誤差を Δu とおくと、 Δu は次式のように得られる。 η は十分小さな正の定数とする。

$$\begin{aligned} \Delta u &= -\eta \frac{\partial V}{\partial u} = -\eta \sum_{j=0}^n \frac{\partial V}{\partial \left(\frac{d^j x}{dt^j} \right)} \frac{\partial \left(\frac{d^j x}{dt^j} \right)}{\partial u} \\ &= \eta \sum_{j=0}^n \left\{ \left(\frac{d^j r}{dt^j} - \frac{d^j x}{dt^j} \right) \cdot \sum_i \left(w_{ij} \cdot \frac{(1 - o_i^2)}{4a} \cdot w_{ji} \right) \right\} \quad \dots\dots (9) \end{aligned}$$

次に、図 7 [3] のように、ニューロコントローラの学習を行う。小さな初期重みから学習を始め、学習を進めて徐々に出力を大きくしていく。

式 (9) から、式 (6) の評価関数を極小にするためのニューロコントローラの重みの学習則は、式 (10) のように表される。

図7 ニューロコントローラの誤差生成と学習および操作量の生成

$$\frac{dw}{dt} = -\eta \frac{\partial V}{\partial w} = -\eta \sum_{j=0}^n \frac{\partial V}{\partial \left(\frac{d^j x}{dt^j} \right)} \frac{\partial \left(\frac{d^j x}{dt^j} \right)}{\partial u} \cdot \left(\frac{\partial u}{\partial w} \right)$$

$$= \Delta u \left(\frac{\partial u}{\partial w} \right) \dots\dots\dots (10)$$

フォワードモデルを用いて、式(9)のように得られた Δu を式(10)に代入し、 $\partial u / \partial w$ は誤差逆伝搬学習法に基づいて学習を行う。

そして最後に、図7[4]のように学習したニューロコントローラの出力を行う。

この[1]～[4]の操作は、1サンプル間に行う。

また、ニューロコントローラの構造は中間層を持つ階層構造のニューラルネットワークとしてもよいし、RBFN⁽¹⁾などを用いてもよい。

4. 実験

4.1 実験の概要 実験で用いた流動床式ごみ焼却プラントの規模と仕様を示す。

処理能力	: 20.0 t/18h
計画ごみ質	: 2000 kcal/kg
流動化方式	: 水平吹出散気管方式
炉床寸法	: 1.8 m ²

実験に関する機器構成を図8に示す。

プラントからの計測データは、酸素濃度、炉内温度、炉内圧であり、これらのデータをA/D変換することによって、コントローラとなるパソコンに取り込む。ニューロの計算はパソコン上のDSP(Digital Signal Processor)で行われ、二次空気付加量を計算し、D/A変換することによって出力する。制御周期は2秒とした。

4.2 ニューロ制御概要 ニューロの構成はニューロコントローラが3層、フォワードモデルが3層の計6層のネットワークである。ネットワーク構成を図9に示す。

ニューロコントローラの構成は、入力層9個、中間層7個、出力層1個で、入力層へは酸素濃度、炉内圧、炉内温度とオフセットが入力される。オフセット入力以外は、それぞれ1サンプル前の過去のデータを、酸素濃度と炉内圧については2サンプル前の過去のデータを同時に入力する。中間層と出力層ニューロンはシグモイド関数を用い、入力層ニューロンは線形な出力特性を持つ。

フォワードモデルは、入力層6個、中間層6個、出力層1個である。入力データは、従来のコントローラ出力、ニューロコントローラ出力、酸素濃度と、酸素濃度差分の

図8 機器構成

図9 ニューラルネットワークの構成

予測値を用いた。RANCにおいては、予測精度よりも操作量が入力される第4層1番目のニューロンから、出力層ニューロンまでの感度特性を表現する経路の学習に重点を置いており、この部分の結合係数が十分適切な値になることが望ましい。そこで、操作量と独立性の低いデータは入力しないようにするため、操作量の過去のデータは入力しない。また、酸素濃度データは十分低周波であり、一階微分値よりも高い次数の成分が小さかったため、ここでは式(6)の第(n-2)項目までを0として省略した。また、ごみの安定供給が困難な場合は、ごみが炉内にない状態が発生するために、一定供給されている一次空気だけで酸素濃度は上昇してしまう。つまり、酸素濃度のベース値は二次空気によって最適に制御することができない。そこで、式(6)の第n項を0とした。この結果、フォワードモデルの出力は酸素濃度の一階微分の予測値だけとなった。ここでは、この微分値を差分値によって代用した。

このように、本プラントでは学習の簡単化を行うことができ、比較的短時間での学習が可能になった。

学習方法は誤差逆伝搬法を用い、収束を速めるために慣性項を加えて学習を行った。また、酸素濃度は0～16%を-0.6～0.6に正規化して用いた。

5. 実験結果および考察

5.1 各計測値の関係 従来制御による実験結果を図10に、ニューロ制御による実験結果を図11に示す。図の矢印は、ごみの量もしくは質が急激に増加した状態を示している。このような場合は酸素濃度が数十秒遅れて急激に減少し、CO濃度が増加することが図10から分かる。そのため、二次空気は酸素濃度が減少する前に増やす必要がある。図11ではニューロ制御が、放射温度、炉内圧、酸素濃度とニューロ内部で生成した各量の時間遅れを組み合わせ、従来制御よりも早く二次空気を投入することで、酸素濃度の減少を抑え、COがほとんど発生していないことがわかる。ここで、ニューロ出力は±2000m³/hを±100%で示している。

5.2 ニューロ制御と従来の制御のCO濃度の比較

図10 従来制御による実験結果

図11 ニューロ制御による実験結果

図12 従来制御による100分間の実験結果

図13 ニューロ制御による100分間の実験結果

CO濃度はダイオキシン発生の目安となる量である。このCO濃度を、酸素濃度を一定にするという燃焼制御によって、どの程度抑制できるかをここでは示す。

実験の結果、図12, 13に示されるような100分間のCO濃度が得られた。ここで、この二つのデータは計測している200分の間に、ごみの性質があまり変化していない状態で、従来の制御とニューロ制御を続けて100分ずつ行なったときの実験結果である。

図12は従来制御による実験結果である。ごみ質や量の急変に対して適切に対応することができず、CO濃度が2000ppmを超えてしまうことがある。

これに対し、図13のニューロ制御では、ごみの大量投入もしくは急激なごみの量や質の上昇が起きたときに、従来制御よりも早く空気を投入することを学習した結果、COの増加を平均で1/5に抑えることができています。

6.まとめ

プラント特性を学習したニューラルネットを持つRAN Cを用いることで、フィードバック誤差学習法などの従来の方法より学習の収束性を高め、さらに従来のフィードバックコントローラに対し、ニューロが補正信号として働くようにすることで信頼性を高めた。これにより、適応的なニューロ制御の実プラントへの適用が可能になった。さらに、フォワードモデルを単純化することで、短時間に学習することができるようになった。

また、ごみ変動による外乱を積極的に打ち消すために、炉内圧や炉内放射温度をフィードフォワード信号として用い、フィードバック成分だけでなく、フィードフォワード成分を学習によって適切に調整した。その結果、フィードバック主体でフィードフォワード成分を試行錯誤的に決定する従来の制御よりも性能を上げることができた。

このようにして、流動床式ごみ焼却炉の実機において、酸素濃度変化をより減少させることが可能になり、CO濃度を1/5に低減させる良好な結果を得ることができた。

しかし、本試験では、全体的にごみが少なかったために、ごみの入りが悪いときなどは、二次空気が下限値であっても、一次空気だけで酸素過多になる傾向があり、酸素過多のときに発生しやすいNO_xについては抑制効果が見られなかった。NO_xの低減を図るためには、一次空気も同時に制御する必要があると考えられる。これは今後の課題である。

参考文献

- (1) 井上, 他, 石川島播磨技報, 30, 1, (1990), 34.
- (2) 横山, 他, 全国都市清掃研究発表会論文集, (1993), 199.
- (3) 田中, 他, ファジーシステムシンポジウム, (1992), 361.
- (4) 五味, 川人, システム制御情報学会誌, 4, 1, (1991), 37.
- (5) 山畑, 他, 全国都市清掃研究発表会論文集, (1992), 138.
- (6) Jordan, M. I., Proc. IEEE/INNS Int. Joint Conf. on Neural Networks, Washington, DC, (1990), 217.
- (7) Kawato, M., et al., IEEE Control System Magazine, 8, 3, (1988), 8.
- (8) 長門・吉田, 機論, 59, 559, (1993), 872.
- (9) 藤井・浦・黒田・能勢, 日本造船学会論文集, 16, (1991), 477.
- (10) Narendra, K.S., Parthasarathy, K., IEEE Trans. on Neural Networks, 1, (1990), 4.
- (11) Moody, J., Darken, J., Neural Computasion, 1, (1989), 281.