自動調整関数を用いた逐次学習型ニューラルネットによる 無人搬送車の操舵制御[†]

船 曳 繁 之*・味 野 真 生*

A Steering Control of Automated Guided Vehicles by Successive Learning Neural Network Using Auto-Tuning Function

Shigeyuki FUNABIKI* and Michio MINO*

The authors proposed the application of fuzzy reasoning to the steering control of automated guided vehicles (AGVs) and achieved the stable control results. Furthermore, we proposed the steering control of AGVs by neural network using the teaching signal of the fuzzy control results. Since it is necessary in this control method to obtain the stable control results by other control methods in advance, it is not practical.

In this paper, a steering control strategy of AGVs is proposed with the successive learning neural network using the auto-tuning function (AT function). The coefficients of the proposed AT function and the initial values of the teaching signal are discussed by the computer simulation. The right and left turning experiments using the AGV built as a trial are implemented and the validity of the AT function is discussed. The excellent traveling control of the AGV is obtained in some trials. Then, the learning of the neural network is almost terminated and after then the excellent traveling lasts. Thus, the proposed AT function is proved to be very available for the successive learning of neural network.

Key Words: automated guided vehicles, steering control, neural network, successive learning, auto-tuning

1. はじめに

産業分野ではFA(Factory Automation)化が進み、工場内で材料や製品などを各工程間で効率よく運搬する無人搬送車(Automated Guided Vehicle: AGV)^{1),2)}が広く利用され、AGVの果たす役割が大きくなってきた。しかし、従来から用いられているPI制御は、調整方法、調整時間などの問題から必ずしも満足できる制御とはいえずなくなっている。すでに筆者らは、感覚的な制御が可能なファジィ制御の適用を提案し、安定度の高い操舵制御を実現している³⁾。しかし、ファジィ制御においてもスケールリングファクタの調整やルールの検討などから、PI

制御と同様に調整の難しさもある。また筆者らは、ファジィ制御による操舵結果を教師信号とするニューラルネットを用いたAGVの操舵制御法を提案した⁴⁾。この制御法は教師信号として、あらかじめほかの制御法によって良好な操舵制御結果を得ておく必要があり、実用的な制御法とはいえない。

そこで本論文では、リアルタイムに学習が可能な逐次学習型ニューラルネットを用いたAGVの操舵制御法を提案している⁵⁾。提案した制御法では、ニューラルネットは数回の試行により学習し、その結果良好な操舵制御を実現する。試行を繰り返しながらリアルタイムで学習を行う場合のPI制御の考えに基づいた教師信号について説明し、学習進度に応じて学習を調整する自動調整関数(AT関数)を提案している。まず、シミュレーションにより提案したAT関数定数と教師信号の初期値について検討し、適切な値を求める。そして、製作したAGVを用いた左右旋回コースでの実験により、この制御法の有効

[†] 電気学会産業応用部門全国大会で発表(1994・8)

* 岡山大学工学部 岡山市津島中3-1-1

* Faculty of Engineering, Okayama University, Okayama

(Received November 21, 1994)

(Revised May 18, 1995)

性を検討する。さらに、教師信号中の定数を調整することにより、良好な学習が行われ、実用上十分な操舵制御が実現できることを明らかにしている。

2. AGV システム

Fig. 1 に AGV の概略図を示す。本 AGV は、幅 50 mm のガイド磁気テープ(以下、コース)を検出するガイドセンサを車体前部に設置し、前輪 1 輪を操舵輪、後輪 2 輪を駆動輪とする 3 輪型である。ガイドセンサは、±50 mm の検出範囲をもち、±100 mm を超えると検出範囲外信号によりコースからの離脱を検知する。Table 1 に本 AGV の車体仕様を示す。

Fig. 2 に AGV の制御ブロック図を示す。ガイドセンサからの信号である偏差(コースからのズレ)を用い、ステアリング操作量をコントローラ内のニューラルネットにより決定し、ステアリングモータへ出力する。そして、ステアリング操作量とポテンショメータからの信号であるステアリング操舵角 θ との差が減少するように、ステアリングモータを位置制御する。

3. ニューラルネットによる操舵制御法

3.1 ニューラルネットの構成

ここで用いるニューラルネットは、Fig. 3 に示す入力層、中間層、出力層の 3 層からなる階層型で、入力層ユニット数は 2 個、中間層ユニット数は 3 個、出力層ユニット数は 1 個である。入力変数がニューラルネットに入力されると、フォワードプロパゲーションにより出力層からステアリング操作量を出力する。また、バックプロパ

ゲーションにより次式で示す教師信号 $T(n)$ とニューラルネットの出力 $e(n)$ との二乗誤差 $E(n)$ が小さくなるよう、各ニューロン間の結合係数を逐次修正する。

$$E(n) = \frac{\{T(n) - e(n)\}^2}{2} \quad (1)$$

なお、ニューラルネットのユニットの伝達関数には次式のシグモイド関数を用いている。

$$f(x) = M \left\{ \frac{2}{1 + \exp(-Ax)} - 1 \right\} \quad (2)$$

ここで、 M 、 A はシグモイド関数の定数である。ニューラルネットの修正にはモーメント法を用いており、学習係数は 0.75、安定化係数は 0.8 としている。ニューラルネットはサンプリング時間(制御周期)ごとにバックプロパゲーションにより学習を行い、そしてフォワードプロパゲーションによりステアリング操作量を出力する。

ニューラルネットの二つの入力に偏差と偏差の和を用いるが、偏差よりも偏差の和のほうが大きな値となる。このため、ニューラルネットの出力が偏差よりも偏差の和のほうに影響を受けやすくなり、安定な制御を行うことができない。したがって、入力のマッチングを取るために、偏差の和に係数 $F_0 (=0.1)$ を掛けてニューラルネットに入力する^{6),7)}。

3.2 教師信号

ニューラルネットの学習で問題になるのが教師信号であるが、これは以下のように PI 制御の考えに基づいて作成する。PI 制御では、指令値とフィードバック値との差に比例した修正量との差の積分値に比例した修正量の和を操作量としている。 n 回目のサンプリング時の差を $z(n)$ 、操作量を $u(n)$ とすると、PI 制御の操作量は離散

Fig. 1 Schematic diagram of AGV

Table 1 Specification of AGV

Wheel base [m]	1.0
Tread [m]	0.6
Inertial mass of car body [kg]	80
Center of gravity (distance from front wheel) [m]	0.6
Distance from guide sensor to front wheel [m]	0.15

Fig. 2 Control block diagram of AGV

Fig. 3 Neural network

時間で表現すると次式になる.

$$u(n) = K_P \cdot z(n) + K_I \sum_{i=0}^n z(i) \quad (3)$$

ここで, K_P , K_I はそれぞれ比例ゲイン, 積分ゲインである. $(n-1)$ 回目のサンプリングでは,

$$u(n-1) = K_P \cdot z(n-1) + K_I \sum_{i=0}^{n-1} z(i) \quad (4)$$

となり, (3), (4) 式より,

$$u(n) = u(n-1) + K_P \{z(n) - z(n-1)\} + K_I \cdot z(n) \quad (5)$$

を得る. PI 制御では(5)式が操作量となる. これを考慮して教師信号を次式により作成する.

$$T(n) = e(n-1) + \mathcal{K}_P(m) \{z(n) - z(n-1)\} + \mathcal{K}_I(m) \cdot z(n) \quad (6)$$

ここで, $\mathcal{K}_P(m)$, $\mathcal{K}_I(m)$: m 回目試行時の教師信号係数, $e(n-1)$: $(n-1)$ 回目のサンプリングでのニューラルネット出力

なお, (6) 式の第 2, 3 項はニューラルネットの修正の大きさを決定するため, 教師信号係数の値が大きいくほど, ニューラルネットの学習が速く進む.

3.3 評価指標

制御結果, 学習進度の評価指標として, 以下に定義するコース追従率 R_f とステア角変化の平均値 M_w を用いる.

コース追従率 R_f を

$$R_f = \frac{D_a}{D_c} \quad (7)$$

で表わす. ここで, D_a は AGV が 1 回の試行で走行した距離, D_c は AGV がコースに完全に追従したときの走行距離である. R_f はコースに完全に追従した場合には 1 となり, 全く追従できなかった場合には 0 となる.

つぎに, ステア角変化の平均値 M_w を

$$M_w = \frac{S_w}{N_s} \quad (8)$$

で表わす. ここで, S_w はデータサンプリング時間 30 ms

ごとのステア角変化の絶対値の和, N_s はデータサンプリング回数である. AGV がコースに追従しているとき, 操舵が安定であるためにはステアリングの振動が少ないほうがよく, M_w はなるべく小さい値となるのがよい.

3.4 自動調整関数

教師信号係数の値を一定として学習を行うと, 試行成功後も学習が進み, ニューラルネットのゲインが高くなり, 制御失敗が起こる. そこで, 教師信号係数を学習進度に応じて, 次式により変化させる.

$$\mathcal{K}_P(m) = f_{AT}(R_f) \cdot \mathcal{K}_P(m-1) \quad (9)$$

$$\mathcal{K}_I(m) = f_{AT}(R_f) \cdot \mathcal{K}_I(m-1) \quad (10)$$

なお, $f_{AT}(R_f)$ は自動調整関数(AT 関数)で, 次式のシグモイド関数により定義する.

$$f_{AT}(R_f) = \frac{a_H - a_L}{1 + \exp\{b(R_f - 0.5)\}} + a_L \quad (11)$$

ここで, a_H , a_L : AT 関数の上下限を決定する定数, b : AT 関数の傾きを決定する定数

Fig. 4 に(11)式で定義される AT 関数 ($a_H=1.1$, $a_L=0.3$, $b=10$) を示す. 早い時期に試行が成功しない R_f が小さいときには, AT 関数は 1 より大きな値となり, 学習を促進するように $\mathcal{K}_P(m)$, $\mathcal{K}_I(m)$ の値を大きくする. 一方, R_f が大きな値となる試行が成功に近づいた場合や試行が成功した場合には, AT 関数は小さな値となり, 学習は抑制され, 試行の成功が続くと教師信号係数はほぼ零となり, 学習は停止する.

4. シミュレーション

4.1 AT 関数定数

アッカーマン・ジャントの理論⁸⁾を用いた前に報告したシミュレーションの方法⁴⁾によって提案した AT 関数を用いた学習について検討する. AGV の走行コース, 速度, サンプリング時間を Table 2 に示す.

ここでは, AT 関数の定数 a_H , a_L , b の値について検討する. Table 3 に a_H と教師信号係数の初期値に対する最初に成功する試行回数を示す. Table で X は試行が成功しないことを示している. このとき, $a_L=0.3$, $b=10$ である. なお, AGV が左右旋回の試行中に偏差が 0.1 m 以上, または前 2 秒間のステア角変化の平均値が 0.3 deg. 以上となればその回の試行を中止し, つぎの試行に移る. a_H が大きくなると試行が成功しなくなり, 1.25 以

Fig. 4 Auto-tuning function

Table 2 Conditions

Traveling speed [km/h]	3.6
Sampling time [ms]	10
Cornering radius of guide tape [m]	3.0
First straight [m]	2.0
Straight between right and left turning [m]	2.0
Last straight [m]	2.0

Table 3 First successful trial number vs. a_H and initial values of teaching signal coefficients

		$\mathcal{K}_P(1), \mathcal{K}_I(1)$				
		0.0001	0.0005	0.001	0.005	0.01
a_H	1.00	×	15	10	6	×
	1.05	40	18	×	6	×
	1.10	27	19	11	6	×
	1.15	22	15	10	×	×
	1.20	22	×	10	×	×
	1.25	×	×	×	×	×

Fig. 5 Average values of steering angle variation**Table 4** First successful trial number vs. b

b	0.1	0.2	0.5	1	2	5	10	20	50	100
Num. of trials	×	7	7	5	5	7	6	6	8	×

上では全て失敗に終わった。また、教師信号係数の初期値も大きくなると、学習過多となり試行が失敗した。一方、小さいときには学習が遅くなり、成功するまでの試行回数が大きくなっている。これらの結果より以下では、 a_H として1.1、 $\mathcal{K}_P(1), \mathcal{K}_I(1)$ として0.005を用いる。

Fig. 5 に a_L に対するステア角変化の平均値を示す。このとき、 $a_H=1.1$ 、 $b=10$ 、 $\mathcal{K}_P(1)=\mathcal{K}_I(1)=0.005$ である。 a_L が 0.1、0.3 のときは試行 6 回目で成功し、 a_L が 0.5 のときは試行 7 回目で成功した。なお、 a_L が 0.6 以上では学習の抑制ができず、試行は成功しなかった。Fig. 5 より、 a_L が小さいほど急速に学習が抑制され、ステアリングが安定していることがわかる。しかし、試行成功後もより安定な操舵制御を行うために、ある程度学習を行うことが望ましいと考えられる。したがって、 a_L の値として 0.3 を用いる。

Table 4 に b に対する最初に成功する試行回数を示す。このとき、 $a_H=1.1$ 、 $a_L=0.3$ 、 $\mathcal{K}_P(1)=\mathcal{K}_I(1)=0.005$ である。 b の広い範囲で試行の成功することがわかる。以下では、AT 関数が、学習進度とともに学習を抑制するなだらかな飽和関数となる、 $b=10$ を用いる。

(a) regulation of $\mathcal{K}_P(m)$ and $\mathcal{K}_I(m)$ by AT function (b) $\mathcal{K}_P(m)$ and $\mathcal{K}_I(m)$: constant (=0.005)**Fig. 6** Simulation results**Table 5** Constants of AT function and initial values of teaching signal coefficients

a_H	1.1
a_L	0.3
b	10
$\mathcal{K}_P(1)$	0.005
$\mathcal{K}_I(1)$	0.005

4.2 AT 関数を用いた学習

Fig. 6 に提案した AT 関数を用いた場合と教師信号係数を一定とした場合の左右旋回操舵制御における学習経過を示す。AT 関数および教師信号係数の初期値を **Table 5** に示す。Fig. 6(a) が AT 関数を用いた場合であり、 f_{AT} が R_f の増加に伴って減少し、 $\mathcal{K}_P, \mathcal{K}_I$ の値は

最初増加し、その後試行が成功すると急激に減少して試行 10 回目以降では学習をほぼ停止している。その後、試行は失敗することなく、安定な操舵制御が実現できている。

Fig. 6(b) の場合 $\mathcal{K}_P, \mathcal{K}_I$ の値は一定であり、最初に試行が成功するのは Fig. 6(a) の場合と同じ 6 回目である。そして、その後も同様に学習を続けるためニューラルネットのゲインが大きくなり、ステアリングが振動的になり、18 回目には試行が失敗している。そして、それ以降試行は成功することはない。

5. 実験

5.1 実験システム

Fig. 7 に実験システム構成と実験車を示す。Fig. 7 に示すように、走行コントローラへ定速度前進指令を出力し、サンプリング時間ごとに車体前部に固定されたガイドセンサによりコースとのズレ(偏差)を検出し、AD 変換器を通してパーソナルコンピュータ PC 9801 NS/T (CPU: 386 SL (20 MHz) + 387 SX) に取り込む。ガイドセンサで検出した偏差により、ニューラルネットで最適なステアリング操作量を決定し、それをステアリングモータコントローラへ DA 変換器を介して出力する。さらに、サンプリング割込みが行われるまで、ステアリング部に設置したポテンシオメータからのフィードバック

Fig. 7 Experimental system

により、PI 制御でステアリングモータの位置制御を行う。

実験条件は Table 2 のとおりである。実験は平坦なアスファルト上で行い、コースは左右旋回で、旋回半径は 3.0 m、旋回と旋回間の直線は 2.0 m とした。走行速度は直線、旋回時ともに 3.6 km/h で、サンプリング時間(制御周期)は 10 ms である。

5.2 実験結果

教師信号係数を変えずに一定で学習した場合と学習進度に応じて教師信号係数を変えた場合の実験について比較検討する。Fig. 8 に AT 関数を用いた場合と教師信号係数を一定とした場合の学習経過の実験結果を示す。ここで AT 関数の定数および教師信号係数の初期値は、それぞれ $a_H=1.1, a_L=0.3, b=10, \mathcal{K}_P(1)=\mathcal{K}_I(1)=0.001$ である。AT 関数を用いた場合には、試行 7 回目で成功し、その後も安定に操舵制御ができています。教師信号係数も最初増加し、学習が進むに従って減少し、試行 10 回目でほぼ学習が終了している。そして、 M_W も小さな値を示し、振動の少ない安定な操舵制御が実現できている。

一方、Fig. 8(b) の教師信号係数一定の場合には、試行 10 回目で成功し、その後同様に学習を続けると試行 12 回目に試行が失敗した。これは試行成功後も同様に学習

(a) regulation of $\mathcal{K}_P(m)$ and $\mathcal{K}_I(m)$ by AT function

(b) $\mathcal{K}_P(m)$ and $\mathcal{K}_I(m)$: constant

Fig. 8 Experimental results of learning process
 $\mathcal{K}_P(1)=\mathcal{K}_I(1)=0.001$

Fig. 9 Experimental results of right and left turning

することにより、ニューラルネットのゲインが大きくなって、ステアリングが振動的となり、試行が失敗している。これは、試行が成功している11回目の M_w を見ると前の回の試行時よりも大きくなっていることからわかる。

また、両者を比較すると初めて試行が成功するのは、AT関数を用いた場合には7回目、教師信号係数一定の場合は10回目であり、AT関数を用いた場合のほうが早く成功している。これは、最初教師信号係数が大きくなり、ある程度学習が進むと学習を抑制し、安定な操舵制御を実現しているためと考えられる。したがって、提案するAT関数を用いて逐次学習を行う操舵制御法は、少ない試行で安定な操舵が実現できる。

Fig. 9にAT関数を用いた場合の試行12回目の操舵制御結果を示す。偏差は0.05 m以内であり、センサの中心もコース上を滑らかに移動している。そして、ステアリングの振動が少なく、滑らかに変化しており、良好な操舵結果を示している。

Fig. 10にFig. 6に示しているシミュレーションと同じ条件($\mathcal{K}_p(1)=\mathcal{K}_I(1)=0.005$)で行った学習経過の実験結果を示す。AT関数を用いた場合、試行4回目で成功しており、早い学習が実現できている。一方、教師信号係数一定で行ったFig. 10(b)では試行4回目でステアリングの振動が大きくなり、試行は失敗している。

Fig. 11にFig. 9の実験を行ったときのニューラルネットの入出力関係を示す。すなわち、ニューラルネットの出力は偏差の和に対して飽和をもつ非線形特性を示す。また、 $\mathcal{K}_p(1)=\mathcal{K}_I(1)=0.005$ で行ったFig. 10(a)の

(a) regulation of $\mathcal{K}_p(m)$ and $\mathcal{K}_I(m)$ by AT function (b) $\mathcal{K}_p(m)$ and $\mathcal{K}_I(m)$: constantFig. 10 Experimental results of learning process
 $\mathcal{K}_p(1)=\mathcal{K}_I(1)=0.005$

Fig. 11 Relation of input-output of neural network

実験で、学習が終了している試行回数13回目のニューラルネットの入出力関係もFig. 11と同様であった。

6. まとめ

以上、AT関数を用いた逐次学習型ニューラルネットによるAGVの操舵制御法を提案した。まず、シミュレーションにより提案したAT関数および教師信号係数の初期値について検討した。そして、シミュレーションおよび実験により、教師信号係数一定での逐次学習型

ニューラルネットとAT関数を用いた逐次学習型ニューラルネットによる左右旋回走行について検討した。得られた結果を要約すると以下のとおりである。

- (1) 提案したシグモイド関数を用いたAT関数の定数について検討し、左右旋回コースでの最適な値の範囲を求めた。
- (2) 教師信号係数の初期値について検討し、安定かつ迅速に学習が可能な値として、0.005をシミュレーションより決定した。
- (3) 実験より学習経過を比較検討した結果、AT関数を用いたほうが教師信号係数一定の場合に比べ少ない試行回数で操舵制御が成功した。また、教師信号係数一定の場合そのまま試行を続けると失敗するが、AT関数を用いた場合はその後も安定な操舵ができた。
- (4) 教師信号係数一定の場合で試行が成功しない場合でも、AT関数を用いた場合は早い学習で試行が成功した。

参 考 文 献

- 1) 無人搬送システム, 神鋼電機技報, 34-2, 25/27 (1990)
- 2) 牧野, 大泉, 橋本: イメージセンサを用いた無人搬送車の高速制御, 計測自動制御学会論文集, 28-5, 595/603 (1992)
- 3) 船曳, 妹尾: ファジィ推論による無人搬送車の操舵系制御, 電気学会論文誌D, 112-10, 959/965 (1992)
- 4) 船曳, 味野: ニューラルネットによる無人搬送車の操舵制御, 電気学会論文誌D, 113-12, 1363/1370 (1993)
- 5) 船曳, 味野: 自動調整関数を用いた逐次学習型ニューラルネットによるAGVの操舵制御, 平6年電気学会産業応用部門全国大会, 283 (1994)
- 6) 味野, 中塚, 船曳: 逐次学習型ニューラルネットによる無人搬送車の操舵制御(3), 平5年度電気・情報関連学会中国支部連合大会, 010404 (1993)
- 7) 船曳, 味野: 逐次学習型ニューラルネットによる無人搬送車の操舵制御, 電気学会論文誌D, 115-2, 142/148 (1995)
- 8) 影山(克), 影山(一): 自動車工学, 理工図書 (1984)

[著 者 紹 介]

船 曳 繁 之 (正会員)

1979年, 岡山大学大学院工学研究科修士課程修了。同年同大学工学部電気工学科助手, 講師を経て, 現在, 同大学電気電子工学科助教授。パワーエレクトロニクス, ファジィおよびニューラルネットを用いた制御の研究に従事(工学博士)。

味 野 真 生

1994年, 岡山大学大学院工学研究科修士課程修了。同年三井造船(株)入社, 現在に至る。在学中, ニューラルネットによる無人搬送車の走行制御の研究に従事。